UNIVERSIDADE DE SÃO PAULO
INSTITUTO DE GEOCIÊNCIAS

Análise morfométrica e identificação semi-automática de escorregamentos no Brasil utilizando *lidar*, SfM-MVS e *Deep Learning*

GUILHERME PEREIRA BENTO GARCIA

Tese apresentada ao Programa Geociências Recursos Minerais e Hidrogeologia para obtenção do título de Doutor em Ciências

Área de concentração: Recursos Minerais e Meio Ambiente

Orientador: Prof. Dr. Carlos Henrique Grohmann de Carvalho

SÃO PAULO
2023

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Serviço de Biblioteca e Documentação do IGc/USP
Ficha catalográfica gerada automaticamente com dados fornecidos pelo(a) autor(a)
via programa desenvolvido pela Seção Técnica de Informática do ICMC/USP

Bibliotecários responsáveis pela estrutura de catalogação da publicação:
Sonia Regina Yole Guerra - CRB-8/4208 | Anderson de Santana - CRB-8/6658

Pereira Bento Garcia, Guilherme
Análise morfométrica e identificação semi-automática de escorregamentos no Brasil utilizando lidar, SfM-MVS e Deep Learning / Guilherme Pereira Bento Garcia; orientador Carlos Henrique Grohmann de Carvalho. -- São Paulo, 2023.
300 p.

Tese (Doutorado - Programa de Pós-Graduação em Recursos Minerais e Hidrogeologia) -- Instituto de Geociências, Universidade de São Paulo, 2023.

1. Escorregamentos. 2. lidar. 3. Structure-from-Motion - Multi-view-Stereo. 4. Deep Learning. I. Grohmann de Carvalho, Carlos Henrique, orient. II. Título.

UNIVERSIDADE DE SÃO PAULO
INSTITUTO DE GEOCIÊNCIAS

"ANÁLISE MORFOMÉTRICA E IDENTIFICAÇÃO SEMI-AUTOMÁTICA DE ESCORREGAMENTOS NO BRASIL UTILIZANDO LIDAR, SFM-MVS E DEEP-LEARNING"

GUILHERME PEREIRA BENTO GARCIA

Orientador:
Prof. Dr. Carlos Henrique Grohmann de Carvalho

Tese de Doutorado

Nº 665

COMISSÃO JULGADORA

Dr. Carlos Henrique Grohmann de Carvalho

Dr. Ricardo Vedovello

Dr. Rogério Galante Negri

Dra. Carla Correa Prieto

Dr. Edilson Pizzato

SÃO PAULO

2023

Agradecimentos

À minha família por me apoiar em todas as minhas escolhas profissionais e pelo incentivo no desafio que representou esta tese de doutoramento. Sempre acreditaram na minha capacidade e nunca se esquivaram de me oferecer ajuda nos momentos que mais precisei. Não existem palavras capazes de explicar a gratidão que sinto por ser filho de Gerson Camillo Garcia e de Maria Alice Pereira Bento Garcia, e ser irmão da Camila Pereira Bento Garcia;

À Beatriz, minha namorada, que foi um oásis de entusiasmo e felicidade em momentos de angústia, indecisão e crises de ansiedade que ocorreram durante o desenvolvimento da tese e foram agravados devido à pandemia. Sempre muito solícita em me ajudar e me incentivando para conclusão dessa etapa da minha vida. Passamos momentos muitos complicados durante a pandemia e nos fortalecemos tanto como pessoas quanto como casal;

Aos meus sogros Eloci e Miguel que como professores, e doutores, souberam me direcionar e tranquilizar minhas angústias durante todo esse processo. Os conselhos e a experiência de quem já passou por essa situação de desgaste mental que uma tese de doutoramento nos impõe ajudaram a manter o foco no meu projeto. Sentirei muita falta das conversas com meu sogro durante os jogos do Palmeiras e de todo o conhecimento que aprendi com ele;

Ao Professor Dr. Carlos Henrique Grohmann de Carvalho por sua orientação e paciência para ouvir minhas indecisões e ser capaz de me tranquilizar e ajudar a encontrar soluções para os problemas que apareceram. Seu direcionamento foi essencial para o ajuste de rota que foi efetuado durante o projeto, especialmente após a qualificação;

Aos pesquisadores e colegas do laboratório SPAMLAB-IEE USP pelas conversas, descontrações e discussões sempre muito produtivas. Queria agradecer também toda a ajuda no meu projeto e o apoio. Foi importante saber que minhas dificuldades não foram únicas;

À minha grande amiga Camila Duelis Viana que convive comigo há 14 anos apesar da minha personalidade, por vezes, nada amigável. Sua resiliência e paciência são as grandes responsáveis pela manutenção dessa amizade que eu valorizo mais a cada ano;

Aos colegas: Renato Martinez, Renato Contessotto, Guilherme Fernandez, Caio Ribeiro, Marcelo Takei, Sergio Caetano e Dailson Bertassoli pelas conversas descontraídas, discussões intermináveis por temas irrelevantes, pelas risadas e momentos de descontração durante meu doutorado e, principalmente, durante a pandemia.

Resumo

Garcia, G.P.B., 2023, Análise morfométrica e identificação semi-automática de escorregamentos no Brasil utilizando lidar, SfM-MVS e Deep Learning [Tese de Doutorado], São Paulo, Instituto de Geociências, Universidade de São Paulo, 300 p.

Os escorregamentos são processos naturais potencialmente destrutivos para a sociedade, responsáveis por desastres socioambientais devastadores causando perdas humanas e materiais. Ocorrem de forma recorrente no Brasil devido às características físicas e climáticas, e geram prejuízos anuais à sociedade. Dessa forma, os escorregamentos representam um relevante objeto de estudos focados na prevenção e mitigação dos riscos associados a esses eventos. O avanço tecnológico das últimas décadas promoveu importantes melhorias para os estudos de escorregamentos fornecendo novas ferramentas para coleta, manuseio e análise dos dados. Dados de alta resolução (HR - *High Resolution*) e de muito alta resolução (VHR - *Very High Resolution*) tornaram-se referencial de qualidade nos estudos de escorregamentos podendo ser obtidos por diferentes sensores (*lidar – Light Detection and Ranging*, câmeras digitais) e plataformas (RPA – *Remotely Piloted Aircraft*, satélites, aeronaves) e analisados por diferentes técnicas de acordo com o objetivo principal de cada trabalho. O principal objetivo desse projeto foi explorar as principais tecnologias existentes para o estudo de escorregamentos e aplicar em diferentes áreas do território brasileiro para avaliar seus resultados em relação a eficácia, precisão, custo benefício e reprodutibilidade. A tese foi elaborada na forma de dois artigos científicos em que cada artigo se refere a um estudo específico de escorregamento com a utilização de diferentes ferramentas para sua execução, diferentes dados de entrada (topográficos ou espectrais) e diferentes escalas de trabalho. A distinção entre dados topográficos e espectrais é importante pois cada tipo de dado permite a execução de estudos específicos. Nesse projeto, o primeiro artigo utiliza dados topográficos (obtidos por *lidar* e RPA) para a análise morfométrica de um escorregamento enquanto que o segundo artigo utiliza dados espectrais (imagens CBERS4A) para a classificação supervisionada de escorregamentos reliquiares na Serra do Mar. As diferentes ferramentas e técnicas utilizadas em cada artigo são devidamente apresentadas nessa tese. Ambos os artigos obtiveram resultados relevantes sendo capazes de destacar a importância, as especificidades e a aplicabilidade de cada tipo de dado, ferramenta e técnica, além de sugerir a possibilidade de resultados promissores pela integração dos estudos. Os resultados dessa tese corroboram com os estudos mais recentes de escorregamento que demonstram a imensa potencialidade dessas novas ferramentas e técnicas, e indicam a importante contribuição dessas novas tecnologias no aprimoramento dos métodos tradicionais de estudo de escorregamentos. Assim, este trabalho espera contribuir para os estudos de escorregamentos demonstrando formas para aplicação e análise dessas ferramentas e técnicas nas condições específicas apresentadas nos artigos 1 e 2.

Palavras-chave: escorregamentos, lidar, *Structure-from-Motion–Multi-view Stereo*, *Deep Learning*

Abstract

Garcia, G.P.B, 2023, Morphometric analysis and semi-automatic detection of landslides in Brazil using lidar, SfM-MVS and Deep Learning [PhD Thesis], São Paulo, Instituto de Geociências, Universidade de São Paulo, 300 p.

Landlsides are potentially destructive natural processes, responsible for socio-environmental disasters costing many human lives every year. Occur recurrently in Brazil due to terrain and climate conditions. Thus, landslides are an important object of interest for researchers that studies ways to prevent and mitigate the risks caused by these events. Ongoing technological development in the last decades improved landslide studies capability by providing new tools for data collection and analysis. High resolution (HR) and very high resolution (VHR) data have become the benchmark for quality in landslide studies that can be collected by differents plataforms (such as lidar – Light Detection and Ranging, RPA – Remotely Piloted Aircraft, and satellites) and evaluated by distinct techniques according to project goals. The main objective of this study is to explore the most outstanding technologies in landslide studies and apply them in differents areas of the brazilian territory to evaluate their results by precision, accuracy, cost-benefit and reproducibility. This thesis is presented in the form of two scientific papers in which each one refers to a particular landslide study that uses specific tools, input data and scale. Distinction between topographic and spectral data is relevant since each type of data is used for specific landslide studies. The first paper uses topographic data (acquired by lidar and RPA) for landslide morphometric analysis while the second paper uses spectral data (CBERS4A images) for semi-automatic detection of relict landslides. The different tools and techniques used in each paper are properly described in this thesis. Both papers presented great results and were able to highlight the importance, specificity and applicability of each type of data, tool and technique, in addition to suggesting the likelihood of interesting results by integrating the studies. The results achieved in this thesis corroborate with the most recent landslide studies that confirm the potentiality of these new tools and techniques, and indicates the great contribution to the improvement of traditional methods. This thesis hopes to contribute for landslide studies by showing how to handle the tools and techniques in the specific conditions presented in the scientific papers.

Keywords: landslides, lidar, Structure-from-Motion–Multi-view Stereo, Deep Learning

Sumário

Agradecimentos i
Resumo iii
Abstract v
Sumário vii
Lista de Figuras ix
Lista de Tabelas xi

1 Introdução **1**
1.1 Dados Espectrais 3
1.2 Dados Topográficos 4
1.3 Classificação de imagens - Deep Learning 5
1.4 Objetivos e Justificativa 6
1.5 Organização da tese 7

2 Outros Projetos **9**

3 Fundamentação Biliográfica **13**
3.1 Movimentos Gravitacionais de Massa 13
3.1.1 Classificação dos movimentos de massa 14
3.1.2 Identificação de escorregamentos 23
3.2 Artigo 1 - *lidar* e SfM-MVS 25
3.3 Artigo 2 - *Deep Learning* 40
3.3.1 Arquitetura das redes neurais 42
3.3.2 Redes neurais convolucionais (CNN) 44
3.3.3 Retropropagação (*Backpropagation*) 47

4 Artigo 1 **49**

5 Artigo 2 **67**

6 Conclusão **103**

Referências Bibliográficas **107**

Anexos **125**

A Coorientações . . . 125
A.1 *Aplicação de análise de suscetibilidade a movimentos de massa em encostas naturais a partir de modelo digital de terreno de alta resolução* . . . 125
B *Brazilian Journal of Geology* . . . 165
B.1 *Structural analysis of clastic dikes using Structure from Motion - Multi-View Stereo: a case-study in the Paraná Basin, southeastern Brazil* . . . 165
C XIX Simpósio Brasileiro de Sensoriamento Remoto 2019 . . . 181
C.1 *Comparing Terrestrial Laser Scanner and UAV-based photogrammetry to generate a landslide DEM* . . . 181
C.2 *Semi-automatic UAV-based SFM survey of vertical surfaces* . . . 187
D *14th International Congress on Rock Mechanics and Rock Engineering - ISRM 2019* 193
D.1 *Slope stability assessment based on a Digital Outcrop Model: a case-study at Jardim Garcia quarry* . . . 193
E 35º Congresso Brasileiro de Espeleologia - SBE 2019 . . . 203
E.1 Mapeamento e modelagem 3D do setor turístico da Caverna do Diabo (SP) com *laser scanner*: resultados preliminares . . . 203
F *Computers and Geosciences* . . . 211
F.1 *Dune migration and volume change from airborne LiDAR, terrestrial LiDAR and Structure from Motion-Multi View Stereo* . . . 211
G FEA USP . . . 225
G.1 *Os desafios dos escritórios de contabilidade para garantir a conformidade com a Lei Geral de Proteção de Dados Pessoais (LGPD)* . . . 225
H *Remote Sensing* . . . 247
H.1 *Landslide Segmentation with Deep Learning: Evaluating Model Generalization in Rainfall-Induced Landslides in Brazil* . . . 247
I *MethodsX* . . . 265
I.1 *Remotely piloted aircraft -based automated vertical surface survey* . . . 265
J *Earth Observation Applications to Landslide Mapping, Monitoring and Modelling* 273
J.1 *Landslide 3D reconstruction and monitoring using drone aerial imagery* . 273

Lista de Figuras

3.1 Figura de quedas de blocos. 17
3.2 Figura de rastejo. 18
3.3 Figura de escorregamento translacional. 20
3.4 Figura de escorregamento rotacional. 21
3.5 Figura de escorregamento em cunha. 21
3.6 Figura de corridas de massa. 23
3.7 Tipos de equipamentos de escaneamento a laser. 27
3.8 Método de escaneamento pelo pulso. 28
3.9 Imagem dos múltiplos retornos de um pulso de laser. 29
3.10 Método de escaneamento pela diferença de fase. 30
3.11 Mecanismos de escaneamento. 32
3.12 Tipos de escaneamento 33
3.13 Workflow SFM-MVS 36
3.14 CMVS. 39
3.15 CNN. 45
3.16 Convolução. 45
3.17 Camadas de pooling. 47

Lista de Tabelas

3.1 Classificação e características dos principais tipos de movimentos de massa segundo Varnes (1978). Modificado de Summerfield (1991). 15
3.2 Principais tipos de movimentos gravitacionais de massa associados a encostas. Modificado de Augusto Filho (1992). 16

Capítulo 1

Introdução

Os escorregamentos são processos naturais potencialmente destrutivos para a sociedade, responsáveis por desastres socioambientais devastadores, principalmente quando ocorrem próximos a áreas habitadas, causando expressiva perda de vidas e econômica (Metternicht et al., 2005; Glenn et al., 2006; Lee e Pradhan, 2006; Kasai et al., 2009; Guzzetti et al., 2012; Jebur et al., 2014). No período entre os anos 2008 e 2012 os desastres socioambientais no planeta afetaram mais de 25 milhões de pessoas e causaram perdas de aproximadamente US$ 1.3 trilhões (UNISDR, 2015).

O desenvolvimento urbano sem planejamento adequado, com a ocupação de áreas de encosta, potencializou os riscos para escorregamentos com consequências ambientais e sociais desastrosas (Tominaga et al., 2009). A capacidade de devastação de um escorregamento depende de diversos fatores como o local de ocorrência, o tipo de processo, a frequência e sua magnitude (Densmore e Hovius, 2000). Recentemente, é possível observar um aumento na frequência de ocorrência de desastres socioambientais decorrentes das altas taxas de desmatamento, urbanização acelerada e das mudanças climáticas (Tominaga et al., 2009; Gariano e Guzzetti, 2016; Nohani et al., 2019).

No Brasil, a ocorrência de escorregamentos é frequente, principalmente devido às características morfológicas do terreno e ao regime de chuvas. No verão de 2011, ocorreram centenas de escorregamentos em diversos locais da Serra do Mar, principalmente nas cidades serranas do Rio de Janeiro, devido a fluxos pluviométricos atípicos resultando no maior desastre natural documentado no país, causando grande devastação e milhares de mortes (Netto et al., 2011). Em fevereiro de 2022 diversos eventos de escorregamentos ocorreram em várias regiões do país devido a fluxos intensos de chuvas (Nonato, 2022). Em Petrópolis (RJ), por exemplo, foram registradas precipitações históricas para a região, causando dezenas de vítimas e destruição por toda a cidade (Neves, 2022; Poder360, 2022).

O alto poder destrutivo e o aumento na frequência de ocorrência dos escorregamentos justifica a grande variedade de estudos sobre o tema, sempre com o objetivo de ajudar na prevenção e mitigação dos riscos associados a esses eventos. Os sensores remotos são importantes ferramentas para coleta de dados para esses estudos, considerando a dificuldade de acesso às áreas de estudo, principalmente após a ocorrência dos eventos. Nesse contexto, o avanço tecnológico das últimas

décadas promoveu diversos benefícios para os estudos de terreno, propiciando melhores ferramentas para a coleta e manuseio de dados, o que melhorou significativamente a capacidade de análise dos pesquisadores (Metternicht et al., 2005; Jaboyedoff et al., 2012; Scaioni et al., 2014).

Scaioni et al. (2014) considera que os avanços subsequentes aos trabalhos sobre os primeiros satélites, lançados na década de 1970, foram fundamentais para transformar o sensoriamento remoto em uma ferramenta indispensável nos estudos de escorregamentos. Nesse contexto, as análises apresentam objetivos variados que podem ser divididos em três classes, basicamente (Mantovani et al., 1996; Metternicht et al., 2005; Scaioni et al., 2014):

1. Identificação, classificação e análise pós ocorrência dos escorregamentos
2. Monitoramento dos escorregamentos
3. Avaliação de suscetibilidade e de risco.

Existe uma grande variedade de estudos que se enquadram em cada uma dessas classes, como os estudos sobre mecanismos de deflagração (Florinsky, 1998; Eeckhaut et al., 2009; Ventura et al., 2011; Jebur et al., 2014), análise morfométrica (Hsiao et al., 2004; McKean e Roering, 2004; Chen et al., 2006; Glenn et al., 2006; Du e Teng, 2007; Corsini et al., 2009; Liu et al., 2009; Kasai et al., 2009; Iwahashi et al., 2012) e identificação (Marcelino, 2004; Ardizzone et al., 2007; Eeckhaut et al., 2007; Burns e Madin, 2009; Eeckhaut et al., 2011, 2012; Mondini et al., 2013; Wang et al., 2013; Chen et al., 2014; Li et al., 2015; Heleno et al., 2016; dos Santos Correa et al., 2017; Knevels et al., 2019) referentes à classe 1; estudos de monitoramento (Baldo et al., 2009; Burns et al., 2010; Derron e Jaboyedoff, 2010; Ghuffar et al., 2013; Casagli et al., 2016) referentes à classe 2; e estudos de análise de suscetibilidade (Shikada et al., 1997; Schulz, 2007; van Westen et al., 2008; Kawabata e Bandibas, 2009; Chen et al., 2013; Martins et al., 2017; Ba et al., 2017; Oliveira et al., 2018; Meena e Nachappa, 2019; Nohani et al., 2019; Brock et al., 2020) e análise de estabilidade (Brideau et al., 2012) referentes à classe 3.

O processo de identificação de escorregamentos é efetuado por especialistas responsáveis pela elaboração e atualização de mapas de inventário de escorregamentos que, por sua vez, são fundamentais para estudos de gerenciamento de riscos, suscetibilidade de encostas e predição de novos escorregamentos (Sameen e Pradhan, 2019; Dias et al., 2021; Yu et al., 2021). O conhecimento preciso da localização dos escorregamentos é um fator fundamental para a execução de análises específicas para respostas de emergências e ações preventivas (Chen et al., 2018).

Tradicionalmente, a identificação dos escorregamentos pode ser feita por dois métodos distintos que, geralmente, na prática, são efetuados de modo combinado: de forma manual a partir de observações *in situ* com coleta de dados topográficos e através da interpretação visual de fotografias aéreas e/ou de composições coloridas de imagens multiespectrais de satélite capaz de detectar padrões texturais decorrentes de dados espectrais (Burns e Madin, 2009; Burns et al., 2010; Guzzetti et al., 2012). Os métodos tradicionais são fundamentais para os estudos de identificação

de escorregamentos devido a sua eficiência e eficácia, porém são caracterizados como processos demorados e exaustivos, e seus resultados dependem tanto da qualidade dos dados como da experiência prévia dos especialistas (Eeckhaut et al., 2007). Até o início dos anos 2000, as fotografias aéreas foram os principais dados utilizados na identificação de escorregamentos, enquanto as imagens multiespectrais de satélite eram ainda pouco exploradas (Mantovani et al., 1996).

No entanto, é importante ressaltar que, atualmente, tanto os dados topográficos como os dados espectrais são ferramentas indispensáveis para o devido processo de identificação dos escorregamentos principalmente considerando a melhora na qualidade dos dados e sua disseminação promovida pelo desenvolvimento tecnológico. Dados topográficos e espectrais podem ser utilizados separados ou em conjunto, dependendo dos objetivos de cada projeto, e servem como dados primários para estudos morfológicos e morfométricos de escorregamentos. Dada a importância desses formatos de dados, eles serão apresentados separadamente nas próximas seções.

1.1. Dados Espectrais

O conhecimento dos locais de ocorrência de escorregamentos é essencial para estudos sobre os mecanismos e as características físicas que desencadearam esse tipo de movimento de massa, permitindo também estudos para previsão de eventos futuros e para estruturação de políticas preventivas (Sameen e Pradhan, 2019; Li et al., 2021). A suscetibilidade do terreno para escorregamentos costuma ser maior nas áreas próximas às cicatrizes de escorregamentos, permitindo estabelecer uma relação entre as condições do terreno necessárias para a ocorrência de escorregamentos (Schulz, 2007; Shahabi e Hashim, 2015; Chen et al., 2018).

A coleta de dados espectrais a partir de sensores remotos logo após a ocorrência dos escorregamentos apresenta algumas vantagens importantes como facilitar a identificação dos escorregamentos a partir das composições coloridas das bandas espectrais, uma vez que os escorregamentos ficam destacados na encosta com a retirada de material e vegetação (Guzzetti et al., 1999; Metternicht et al., 2005; Booth et al., 2009; Liu et al., 2009; Guzzetti et al., 2012); e permitir a coleta de dados de modo seguro, pois a destruição causada normalmente torna as áreas inacessíveis para análises *in situ* (Du e Teng, 2007; Booth et al., 2009; Burns et al., 2010). Em encostas naturais, normalmente compostas por vegetação nativa, a tendência é que ocorra uma gradual recuperação da vegetação na área degradada, dificultando assim a identificação e monitoramento das cicatrizes de escorregamento com o passar do tempo (Lehmann, 2008; Portela, 2014; Scaioni et al., 2014).

As fotografias aéreas e as imagens multiespectrais de satélite são essenciais no processo de identificação dos escorregamentos, porém possuem algumas especificações técnicas que podem prejudicar sua eficácia e precisão, além de limitações visuais como presença de nuvens ou de cobertura vegetal (Carrivick et al., 2016). A resolução espacial das imagens é um fator determinante para a qualidade do resultado do processo de identificação, uma vez que maiores resoluções permitem análises mais detalhadas e precisas do terreno. No entanto, imagens com alta resolução

espacial não existem para todas as áreas de estudo e não estão disponíveis a todos os pesquisadores.

1.2. Dados Topográficos

Os dados topográficos, que representam as características físicas do terreno, também são importantes no processo de identificação de escorregamentos, e a partir deles são calculados os parâmetros morfométricos do terreno como hipsometria, declividade, curvaturas e rugosidade, igualmente importantes nesse processo (Franklin, 1987; Wilson e Gallant, 2000; Guzzetti et al., 2012; Scaioni et al., 2014). Podem ser obtidos pela interpolação de cartas topográficas geradas por métodos tradicionais, com utilização de teodolitos e DGPS/GNSS (*Differential Global Positioning System / Global Navigation Satellite System*) em campo (Carrivick et al., 2016), ou através de modelos digitais de elevação (MDE) gerados a partir de dados de sensores como o SRTM (*Shuttle Radar Topography Mission*) (Farr et al., 2007), ou derivados de nuvens de pontos de *lidar* (*Light Detection and Ranging*) ou RPA (*Remotely Piloted Aircraft*) (McKean e Roering, 2004; Glenn et al., 2006; Roering et al., 2013; Wang et al., 2013; Tarolli, 2014).

lidar

Nas duas últimas décadas, diversos estudos sobre escorregamentos estão sendo realizados a partir de dados topográficos de alta resolução obtidos pela tecnologia *lidar* (ver seção 3.1.1) (Shan e Toth, 2009; Vosselman e Maas, 2010; Jaboyedoff et al., 2012; Tarolli, 2014; Telling et al., 2017). A maior quantidade de dados, a elevada precisão e a possibilidade de extrair a vegetação e outros objetos que interfiram na topografia da área, permite a geração de Modelos Digitais de Terreno (MDT) com ótima resolução espacial facilitando observar as distorções no relevo causadas pelos escorregamentos (Buckley et al., 2008; Shan e Toth, 2009; Vosselman e Maas, 2010; Telling et al., 2017). Estudos de suscetibilidade (van Westen et al., 2008; Chen et al., 2013; Jebur et al., 2014), análise de parâmetros morfométricos (Hsiao et al., 2004; McKean e Roering, 2004; Glenn et al., 2006; Dewitte et al., 2008; Kasai et al., 2009; Liu et al., 2009; Burns et al., 2010; Ventura et al., 2011; Brideau et al., 2012), cálculo de volume (Du e Teng, 2007; Baldo et al., 2009), identificação e classificação de escorregamentos (Shikada et al., 1997; Schulz, 2007; Eeckhaut et al., 2007; Ardizzone et al., 2007; Eeckhaut et al., 2009; Burns et al., 2010; Eeckhaut et al., 2012; Wang et al., 2013), monitoramento (Sterzai et al., 2010; Ventura et al., 2011) e mapeamento de cicatrizes (Burns e Madin, 2009; Guzzetti et al., 2012) são alguns dos exemplos de aplicação do *lidar* nos estudos de escorregamentos. Jaboyedoff et al. (2012) apresentam uma importante revisão compilando os principais estudos na área das geociências utilizando *lidar*, abordando suas diversas aplicações.

Mesmo se tratando de uma tecnologia relativamente recente, estudos utilizando *lidar* para mapeamento do relevo e para identificação de movimentos de massa são frequentes. Contudo,

estudos com essas ferramentas ainda são escassos no território brasileiro devido aos altos custos para a utilização da tecnologia, o que inviabiliza a coleta de dados em grandes áreas de forma periódica.

SfM-MVS

Ainda mais recentemente, de 2010 em diante, aparelhos de RPA começaram a ser amplamente utilizados para obtenção de imagens de escorregamentos, sendo os dados coletados utilizados para diversos estudos. Os dados topográficos normalmente são obtidos a partir do processamento do conjunto de imagens coletadas por RPA, mediante aplicação da técnica de *Structure from motion - Multi View Stereo* (SfM-MVS) (seção 3.1.2). O SfM-MVS foi desenvolvido a partir da década dos anos 1980 e se tornou uma ferramenta valiosa para a geração de modelos tridimensionais (3D) a partir de imagens bidimensionais (2D) conjuntamente com o desenvolvimento de softwares com GUIs (*Graphical User Interfaces)*.

A partir de 2010 diversos trabalhos começaram a utilizar imagens coletadas por RPAs para o estudo de escorregamentos, como a utilização de MDEs gerados pelo processo SfM-MVS para análise morfométrica (Niethammer et al., 2010; Casagli et al., 2017), monitoramento dos escorregamentos (Lucieer et al., 2014; Carey et al., 2019), modelagem topográfica (Yu et al., 2017a), análise temporal (Rossi et al., 2018), cálculo de volume (Chang et al., 2020), entre outros. A grande maioria dos trabalhos demonstram que os dados obtidos por RPA SfM-MVS apresentam precisão e resolução comparáveis aos dados de escaneamento a laser de alta resolução para determinadas situações, sendo prejudicados por características da área de estudo como a presença de cobertura vegetal ou outros obstáculos que dificultem a visualização direta do terreno.

1.3. Classificação de imagens - Deep Learning

A utilização integrada dos dados espectrais, dados topográficos e das observações em campo é considerada como o método mais eficiente para os estudos de identificação de escorregamentos (Eeckhaut et al., 2005; Burns e Madin, 2009; Roering et al., 2013; Murillo-García et al., 2015; Schmaltz et al., 2017). Recentemente, ocorreu um aumento expressivo de estudos para identificação semi-automática e automática de escorregamentos, a partir de dados espectrais e/ou topográficos coletados por sensores remotos, e sem a necessidade de levantamentos *in situ* (Kawabata e Bandibas, 2009; Burns e Madin, 2009; Passalacqua et al., 2010; Jaboyedoff et al., 2012; Guzzetti et al., 2012; Stumpf et al., 2013; Kurtz et al., 2014; Li et al., 2015; Heleno et al., 2016). Métodos como análise baseada em objeto (OBIA - *Object Based Image Analysis*) (Eeckhaut et al., 2012; Knevels et al., 2019), o Aprendizado de Máquina (*Machine Learning*) (Gualtieri e Robert, 1999; Pal e Mather, 2006; Pal, 2007; Liu et al., 2017; Maxwell et al., 2018; Wang et al., 2020) e o Aprendizado Profundo (*Deep Learning*) (Luus et al., 2015; Zhao et al., 2015; Zhang et al., 2016; Zhong et al., 2016; Cheng et al., 2017; Kussul et al., 2017; Ienco et al., 2017; Maggiori et al.,

2017; Scott et al., 2017; Yu et al., 2017a; Zhao et al., 2017; Interdonato et al., 2019; Ma et al., 2019; Zhong et al., 2019; Diakogiannis et al., 2020; Prakash et al., 2020; Soares et al., 2022) são muito explorados em estudos de classificação de imagens de sensores remotos, sendo também aplicados para os estudos de escorregamentos.

A detecção semi-automática de escorregamentos permite um mapeamento mais rápido das áreas de interesse, com aplicações no gerenciamento de desastres, ações de mitigação pós eventos e na produção de mapas de inventário de escorregamentos (Guzzetti et al., 2012; Dias et al., 2021). Estudos de classificação semi-automática de escorregamento com algoritmos de *Machine Learning* e principalmente redes neurais profundas, ainda são incipientes, porém tem apresentado resultados promissores.

1.4. Objetivos e Justificativa

Considerando a relevância do tema para o contexto brasileiro, uma vez que os escorregamentos são recorrentes em diversas regiões do país, e a disponibilidade de novas tecnologias e ferramentas para estudos do terreno, o principal objetivo deste projeto foi explorar as principais tecnologias existentes para o estudo de escorregamentos e avaliar seus resultados em relação a eficácia, precisão, custo benefício e reprodutibilidade.

O projeto que culminou nesta tese focou na utilização do escaneamento a laser, coleta de imagens com drones (RPA) e a classificação supervisionada de escorregamentos através de modelos de *Deep Learning*. A intenção foi propor uma discussão sobre esses métodos, apresentar possíveis soluções para problemas inerentes ao contexto brasileiro no estudo dos escorregamentos e avaliar a contribuição dessas novas ferramentas e técnicas para os métodos tradicionais de modo a melhorar os resultados dos estudos.

Apesar de recorrentes e de serem responsáveis por diversos desastres no Brasil, os estudos de escorregamentos utilizando essas ferramentas ainda são incipientes, principalmente devido á falta de recursos tanto financeiros quanto humanos. São poucas as universidade ou orgãos governamentais que têm acesso à essas ferramentas e, portanto, são poucos os pesquisadores capacitados para efetuar esses estudos. Com o propósito de capacitar profissionais envolvidos diretamente nessa área de atuação, o CEMADEN/MCTI (Centro Nacional de Monitoramento e Alertas de Desastres Naturais - Ministério de Ciência, Tecnologia e Inovação) efetuou chamadas públicas em Novembro de 2022 através de seus Programas de Capacitação Institucional (PCI). Entre elas está a chamada 12 (CEMADEN, 2022) intitulada "**Avaliação da base de dados cartográficos aplicados nos cenários e alertas de risco de deslizamento do CEMADEN"** que foca especificamente na realização de inventário de dados topográficos e no mapeamento de movimentos de massa a partir de imagens aéreas de sensoriamento remoto. De certa forma, esta chamada do CEMADEN/MCTI atesta a importância do presente projeto que apresenta em seu escopo exata-

mente a utilização de dados topográficos e espectrais obtidos por sensoriamento remoto para a análise e mapeamento de escorregamentos.

1.5. Organização da tese

Esta tese está estruturada na forma de coletânea de artigos científicos sendo composta por uma Introdução, Levantamento Bibliográfico, apresentação dos artigos (Artigo 1 e Artigo 2) e Conclusão. Os artigos apresentam estudos de escorregamentos que demandam a utilização de dados e métodos específicos. Esta estruturação cumpre o objetivo principal desta tese que consiste na aplicação de ferramentas e tecnologias emergentes no estudo de escorregamentos.

O intuito dessa tese foi explorar a utilização de dados topográficos e espectrais nos estudos de escorregamento. Dessa forma, cada artigo consiste na aplicação de métodos e tecnologias para o manuseio desses tipos de dados separadamente.

O primeiro artigo, intitulado "*Using Terrestrial laser Scanner and RPA based Photogrammetry for Surface Analysis of Landslide: A Comparison*"diz respeito a um estudo morfométrico para avaliação de um escorregamento que ocorreu em uma encosta próxima a cidade de Cunha, São Paulo. O estudo consiste na comparação entre os dados do escaneamento à laser terrestre com os dados de imagens coletadas por drones (RPA) e que foram submetidas ao processo de *Structure from Motion Multi-View Stereo* (SfM-MVS) para geração de modelos tridimensionais. O objetivo foi avaliar a precisão de cada sensor e sua eficiência para a análise proposta, de modo a definir se há a superioridade de um método em relação ao outro. Apesar de algumas discordâncias, ambos os métodos foram considerados eficazes e precisos para a análise morfométrica do escorregamento nas condições presentes na área de estudo, inclusive foi constatada uma grande similaridade entre os resultados provenientes dos conjuntos de dados de cada método. O artigo foi publicado de forma digital em Outubro de 2022 no periódico *Bulletin of Geodetic Sciences* com o DOI: 10.1590/s1982-21702022000300016. Este artigo é uma expansão do trabalho apresentado no XIX Simpósio Brasileiro de Sensoriamento Remoto denominado "*Comparing terrestrial laser scanner and UAV-based photogrammetry to generate a landslide DEM*"(Anexo C.1).

O segundo artigo, intitulado "*Relict landslide detection using Deep-Learning architectures for image segmentation in rainforest areas: A new framework*"consiste na tentativa de identificação semi-automática de cicatrizes de escorregamentos no município de Caraguatatuba, São Paulo, a partir de redes neurais convolucionais (CNN). Nesse estudo foi proposta uma nova abordagem para a utilização de CNNs que efetuam a segmentação semântica de imagens multiespectrais, sendo os resultados comparados com o procedimento padrão de utilização das CNNs. Imagens do satélite CBERS4A foram utilizadas como dados de entrada para três redes de *Deep Learning*: Unet, FPN e Linknet. Os resultados obtidos demonstraram que o método proposto e o método padrão apresentam similaridades principalmente em relação aos valores de *recall* e *precision*. Porém, as predições de escorregamentos do método proposto foram superiores permitindo identificar a

quase totalidade de cicatrizes de escorregamentos presentes na área de estudo. Os resultados não foram melhores devido as limitações identificadas relacionadas principalmente às especificações das imagens CBERS4A utilizadas e pelas características da área de estudo. O artigo foi submetido ao periódico *International Journal of Remote Sensing* sendo aprovado e publicado em formato digital em Março de 2023 (DOI: 10.1080/01431161.2023.2197130).

Capítulo 2

Outros Projetos

Foram efetuados outros projetos junto ao laboratório SPAMLab (*Spatial Analysis and Modelling Lab*) do Instituto de Energia e Ambiente (IEE) da USP - Universidade de São Paulo, durante o período do doutorado, com o objetivo de manusear os equipamentos e técnicas utilizados nos estudos apresentados nessa tese (artigos 1 e 2). Esses projetos envolveram a utilização de aparelhos de escaneamento a laser (*lidar*), de RPA para obtenção de imagens, na aplicação da técnica SfM-MVS para geração de modelos digitais, de aparelhos de GPS/GNSS diferencial para coleta de coordenadas geográficas, de estações totais para irradiação de coordenadas e de modelos de *Deep Learning* para classificação de imagens.

A participação nesses projetos foi fundamental para a elaboração dos estudos que constituem essa tese, pois possibilitou a aquisição das competências necessárias para o manuseio das principais ferramentas disponíveis utilizadas nos estudos de escorregamentos. Demonstra ainda o cárater colaborativo do laboratório SPAMLab, sob coordenação do Prof. Dr. Carlos Henrique Grohmann de Carvalho, que permite, e incentiva, a interação dos orientandos com diversos projetos visando a aquisição de novos conhecimentos.

Os estudos de Gomes (2018), Viana et al. (2018), Grohmann et al. (2019a), Grohmann et al. (2019b), Grohmann et al. (2020), Grohmann et al. (2023a) e Grohmann et al. (2023b) permitiram o manuseio de equipamentos de escaneamento a laser (*lidar*) e drones (RPA) para coleta de dados topográficos e espectrais que possibilitaram diferentes análises a partir das nuvens de pontos geradas, esse conhecimento foi essencial para a elaboração do estudo apresentado no artigo 1. Por sua vez, o estudo de Soares et al. (2022) permitiu trabalhar com redes neurais convolucionais para a segmentação semântica de imagens que serviu de alicerce para a elaboração do estudo apresentado no artigo 2.

- Gomes (2018)

  Coorientação de um trabalho de conclusão de curso do Instituto de Geociência da USP que efetuou uma análise de suceptibilidade a movimentos de massa em uma encosta na cidade de Cunha - SP (Gomes, 2018) (Anexo A.1). Os dados utilizados nessa análise foram coletados

por um aparelho de escaneamento a laser terrestre (TLS) que permitiu a geração de modelos digitais de terreno (MDT) e possibilitiu a análise morfométrica da área de estudo. Também foram utilizados um aparelho de GPS/GNSS e uma estação total para coleta de coordenadas que foram utilizadas no georreferenciamento da nuvem de pontos. Os dados obtidos nesse estudo foram posteriormente utilizados para a elaboração do artigo 1 (Seção 4).

- Viana et al. (2018)

  No estudo de Viana et al. (2018) (Anexo B.1) foi utilizada a técnica de *Structure from Motion - Multi-View Stereo* para geração de modelos digitais de um corte de talude, a partir de imagens obtidas por uma câmera fotográfica digital, que permitiu a análise estrutural de diques clásticos. Além da utilização de um aparelho de GPS/GNSS diferencial para georreferenciamento preciso da nuvem de pontos gerada.

- Viana et al. (2019), Grohmann et al. (2019b) e Grohmann et al. (2023a)

  Em Viana et al. (2019) (Anexo D.1), Grohmann et al. (2019b) (Anexo C.2) e Grohmann et al. (2023a) (Anexo I.1) foram efetuadas anáises verticais de uma pedreira localizada em São Paulo utilizando um RPA para coleta de imagens e o processo de SfM-MVS para geração de modelos digitais. Com os dados obtidos foram efetuadas análises de susceptibilidade a queda de blocos e estrutural do talude. Para o georreferenciamento da nuvem de pontos foram utilizados um aparelho de GPS/GNSS diferencial e uma estação total que permitiu a coleta de coordenadas nas paredes do talude em estudo.

- Grohmann et al. (2019a)

  O estudo de Grohmann et al. (2019a) (Anexo E.1) consistiu na modelagem tridimensional da Caverna do Diabo (SP) a partir de nuvens de pontos obtidas por escaneamento a laser terrestre (TLS). Esse projeto permitiu o intenso manuseio do aparelho de escaneamento a laser em campo, assim como o aprendizado no tratamento das nuvens de pontos no software FARO Scene. Um GPS/GNSS diferencial e uma estação total foram utilizados para coleta de coordenadas e para o deslocamento da coordenada para dentro da caverna, permitindo o georreferenciamento das nuvens de pontos.

- Grohmann et al. (2020)

  No estudo de Grohmann et al. (2020) (Anexo F.1) foi efetuada a modelagem tridimensional de um campo de dunas eólicas em Garopaba (SC) utilizando, e comparando, os dados de escaneamento a laser terrestre e aerotransportado com os do RPA SfM-MVS. O georreferenciamento das nuvens de pontos e dos modelos gerados foi efetuado pelas coordenadas obtidas por um GPS/GNSS diferencial. Os métodos de coleta e tratamento de dados desse estudo são similares aos métodos utilizados no artigo 1 (Seção 4).

- Soares et al. (2022)

O estudo de Soares et al. (2022) (Anexo H.1) utilizou modelos de *Deep Learning*, mais precisamente redes neurais convolucionais (CNN), com imagens de satélite para a classificação semi-automática de escorregamentos em diferentes áreas da Serra do Mar. Todo o processamento de dados, treinamento e validação da rede foram efetuados utilizando algoritmos programados em linguagem Python (Pedregosa et al., 2011) e a CNN utilizada foi a UNet (Ronneberger et al., 2015). Muitas das técnicas utilizadas nesse estudo embasaram a elaboração do artigo 2 (Seção 5).

- Grohmann et al. (2023b)

  Por fim, no estudo de Grohmann et al. (2023b) (Anexo J.1) foram utilizados dados de drone para a geração de modelos digitais de um escorregamento em uma encosta na região de São Sebastião - SP, e para o monitoramento da atividade dessa encosta. Diferentes planos de vôos foram efetuados afim de analisar se a direção de vôo do drone é significativa para a geração dos modelos.

Ainda que não tenha relação com essa tese, é relevante informar que concomitante ao período do doutorado foi efetuada uma graduação em Ciências Contábeis pela FEA-USP (Faculdade de Economia, Administração, Contabilidade e Atuária). Iniciada em 2017 e finalizada em 2020 com a obtenção do título de bacharel em ciências contábeis com o trabalho de conclusão de curso intitulado "*Os desafios dos escritórios de contabilidade para garantir a conformidade com a Lei Geral de Proteção de Dados Pessoais (LGPD)*"(Garcia, 2020) (Anexo G.1).

Capítulo 3

Fundamentação Biliográfica

A tese foi elaborada com o editor de textos LaTeX, assim como os dois artigos aqui apresentados. No entanto, os artigos foram formatados para se adequar às normas das revistas às quais foram submetidos, sendo convertido para outros programas de edição de textos quando necessário. Esta seção apresenta uma pesquisa preliminar para delimitar o objeto de estudo da tese e em seguida é dividida de acordo com cada artigo, de modo a facilitar a compreensão dos métodos empregados em cada estudo.

3.1. Movimentos Gravitacionais de Massa

Os desastres socioambientais podem ser considerados como um dos principais problemas socioeconômicos enfrentados pelo nossa sociedade atualmente, com destaque para eventos como terremotos, inundações e movimentos de massa (Florenzano, 2008; Tominaga et al., 2009; Lopes e de Arruda Junior, 2015). São processos altamente destrutivos que fazem parte da dinâmica natural do planeta, e que sempre aconteceram independente da ação do homem (Lopes e de Arruda Junior, 2015). Tominaga et al. (2009) apontam que devido às mudanças climáticas ocorreu um aumento de extremos climáticos, assim eventos de temporais, de chuvas intensas, de tornados e de estiagens severas podem se tornar mais frequentes o que aumenta a possibilidade de desastres socioambientais.

Os movimentos de massa atuam na dinâmica das vertentes sendo agentes importantes na evolução geomorfológica das encostas (Summerfield, 1991; Densmore e Hovius, 2000; Tominaga et al., 2009; Florenzano, 2008; Guzzetti et al., 2012). Podem ser considerados como um dos processos erosivos mais importantes na modelagem do relevo atuante na escala de tempo do homem (Wolle, 1988), capazes de alterar a geometria e forma do relevo através de sucessivos ciclos de diferentes movimentos de massa (Lopes e de Arruda Junior, 2015).

No cenário brasileiro, a combinação das condições climáticas com a geomorfologia regional proporciona uma alta suscetibilidade para a ocorrência de movimentos de massa (Florenzano, 2008). Estes eventos ainda são acentuados pela ação antrópica caracterizada pela ocupação

urbana indiscriminada das encostas, sem o adequado planejamento do uso do solo e sem a adoção de técnicas adequadas de estabilização (Tominaga et al., 2009; Kawabata e Bandibas, 2009). Lopes e de Arruda Junior (2015) consideram o clima como um dos fatores mais importantes para a ocorrência dos movimentos de massa, pois podem atuar tanto como agentes predisponentes (potencial de instabilização) quanto como agentes deflagradores (causadores da instabilização).

A definição dos movimentos de massa está consolidada pela comunidade acadêmica sendo considerados como movimentos induzidos pela aceleração gravitacional exceto aqueles que são transportados por algum meio como água, gelo, neve e ar (Hutchinson, 1968; Summerfield, 1991; Tominaga et al., 2009). Os movimentos ocorrem no sentido descendente da vertente e podem ser compostos de solo, rocha e/ou vegetação, a contribuição de algum outro meio (água, gelo) ocorre com a redução da resistência dos materiais ou pela indução do comportamento plástico dos fluidos (Costa e Baker, 1981; Tominaga et al., 2009).

Segundo Summerfield (1991), a diferenciação entre os movimentos de massa e o transporte de material não é óbvia ou intuitiva na prática, uma vez que movimentos de massa que possuem uma grande quantidade de água variam, gradacionalmente, para eventos de transporte fluvial em drenagens que carregam grande quantidade de sedimentos.

3.1.1. Classificação dos movimentos de massa

A classificação dos movimentos de massa é efetuada a partir de características específicas de cada evento, porém, devido a complexidade dos processos e a pluralidade dos ambientes de ocorrência, não existe uma classificação universal satisfatória para todos os contextos terrestres (Summerfield, 1991; Tominaga et al., 2009; Lopes e de Arruda Junior, 2015). Consequentemente, existem diversas classificações para os movimentos de massa, algumas mais restritas e locais que outras, com destaque para a classificação de Varnes (1978) que abrange a maioria dos movimentos e é a mais amplamente utilizada mundialmente, e destaque também para as classificações de Guidicini e Nieble (1984) e Augusto Filho (1992) para o território brasileiro.

Dentre os atributos utilizados como critério para identificação dos movimentos, Varnes (1978) destaca o tipo de movimento, tipo de material, taxa de movimento (velocidade), geometria da área de ruptura, depósito resultante, idade, causas, grau de ruptura da massa deslocada, relação entre a geologia estrutural e a geometria do evento, grau de desenvolvimento, localização geográfica e estado da atividade. Augusto Filho (1992), por sua vez, considera em sua classificação fatores como velocidade do movimento, tipo de material envolvido, a estrutura da rocha, a cinemática do movimento, o volume do material deslocado e sua geometria. Em todas as classificações os atributos de classificação são bastante similares e baseados no trabalho de Varnes (1978); as divergências ocorrem devido aos diferentes contextos dos locais de estudos em que alguns atributos são mais apropriados que outros.

Varnes (1978) apresenta uma classificação em seis tipos de movimentos principais: quedas, tombamentos, escorregamentos, espalhamentos, corridas e movimentos complexos. Esses tipos

de movimentos serviram de base para a maioria dos estudos sobre esse tema e ainda sofreram alterações e melhorias conforme ocorria o avanço do conhecimento sobre esses eventos (Tabela 3.1). Por exemplo, Hungr et al. (2014) propõem diversas modificações na classifcação de Varnes (1978) como forma de atualização dos conceitos a partir do conhecimento adquirido e dos eventos observados desde a década de 1970. Highland (2004) efetuou uma compilação dos principais processos de movimentos de massa que foram observados nos Estados Unidos, baseado quase que exclusivamente na classificação proposta por Varnes (1978).

Tabela 3.1. Classificação e características dos principais tipos de movimentos de massa segundo Varnes (1978). Modificado de Summerfield (1991).

Mecanismos Primários	Tipos de Movimentos de Massa	Materiais em movimento	Taxa de Umidade	Tipo de Tensão e natureza do movimento	Taxa de Movimento
Rastejo	Rastejo de rochas	Rochas (litotipos deformáveis como xistos e argilas)	Baixa	Deformação plástica das rochas e/ou solo	Muito lento a extremamemte lento
	Rastejo Contínuo	Solo	Baixa		
Corridas	Corrida seca	Areia ou Silte	Muito baixa	Corridas em forma de funil encostas íngremes compostas sedimentos não coesos	Rápido a extremamente rápido
	Soliflucção	Solo	Alta	Corrida difundida em solos saturados sobre encostas com declives baixos a moderados	Muito lento a extremamente lento
	Geliflucção	Solo	Alta	Corrida difundida em solos esporadicamente saturados sobre um subsolo permanentemente congelado	Muito lento a extremamente lento
	Corrida de lama	Predominantemente argilas (≥80%)	Extremamente alta	Corrida confinada e alongada	Lento
	Corrida de terra (lenta)	Predominantemente areia (≥80%)	Baixa	Corrida confinada e alongada	Lento
	Corrida de terra (rápida)	Solo composto por argilas	Muito alta	Colapso rápido do solo após algum distúrbio, normalmente precedindo um escorregamento	Muito rápido
	Corrida de detritos	Mistura de metariais finos e grosseiros (20%-80% das partículas maiores que areia)	Alta	Normalmente ocorrem em canais de drenagem pré existentes	Muito rápido
	Avalanche de detritos	Fragmentos de rochas, gelo ou neve	Baixa	Movimento catastrófico de baixa fricção com vários quilômetros de extenão	Extremamente rápido
	Avalanche de neve	Neve e gelo, alguns casos com fragmentos de rocha	Baixa	Movimento catastrófico de baixa fricção deflagrado por quedas ou escorregamentos	Extremamente rápido
	Avalanche de lama	Neve saturada	Extremamente alta	Corridas ao longo de canais de drenagens existentes	Muito rápido
Escorregamentos Translacionais	Escorregamento de rocha	Rochas não fraturada	Baixa	Escorregamento raso paralelo à superfície de rocha coesa ao longo de uma fratura	Muito lento a extremamente rápido
	Escorregamento de blocos	Rochas fraturadas	Baixa	Escoregamento aproximadamente paralelo à superfície da rocha fraturada	Moderado
	Escorregamentos de terra	Fragmentos de rocha e solo	Baixa a moderada	Escorregamento raso de solo deformado	Muito lento a rápido
	Escorregamento de blocos de terra	Fragmentos de rocha e solo	Baixa a moderada	Escorregamentos raso de grande massa de solo deformado	Lento
Escorregamentos Rotacionais	Rock Slump	Rochas	Baixa	Movimento rotacional ao longo de uma superfície de ruptura côncava	Extremamente lento a moderado
	Debris/earth slump	Fragmentos de rocha e solo	Moderada	Movimento rotacional ao longo de uma superfície de ruptura côncava	Lento
Heave	Rastejo de solo	Solo	Baixa	Movimento encosta abaixo de solo ou fragmentos de rocha	Extremamente lento
	Rastejo de tálus	Fragmentos de rocha	Baixa		Lento
Quedas	Queda de rochas	Rochas destacadas por juntas	Baixa	Queda de blocos individuais de paredes verticais	Extremamente rápido
	Queda de detritos/solo (Tombamento)	Unidades coesas de solo	Baixa	Tombamento de unidades coesas de solo de paredes verticais	Muito rápido
Subsidência	Colapso de cavidade	Rocha ou solo	Baixa	Colapso de rocha ou solo em cavidades subterrâneas	Muito rápido
	Abatimento	Solo	Baixa	Abatimento da superfície devido a compactação causada pela retirada de água	Lento

No contexto brasileiro, Augusto Filho (1992) divide os movimentos de massa em apenas quatro grupos (Tabela 3.2) : quedas, rastejos, escorregamentos e corridas.

Tabela 3.2. Principais tipos de movimentos gravitacionais de massa associados a encostas. Modificado de Augusto Filho (1992).

Processos	Dinâmica/Geometria/Material	Tipologia
Quedas	Sem planos de deslocamento	
	Movimentos do tipo queda livre ou em plano inclinado	
	Velocidade muito alta (vários m/s)	
	Material rochoso	
	Pequenos a médios volumes	
	Geometria variável: lascas, placas, blocos, etc	Rolamento de matacão
		Tombamento
Rastejos	Vários planos de deslocamento	
	Velocidade muito baixa (cm/ano) a baixa e decrescente com a profundidade	
	Movimentos constantes, sazonais ou intermitentes	
	Solo, depósitos, rocha alterada/fraturada	
Escorregamentos	Pouco planos de deslocamento (externos)	
	Velocidade média (m/h) a alta (m/s)	
	Pequenos a grandes volumes de material	
	Geometria e materiais variáveis	Planares: solos poucos espessos, solos e rochas com um plano de fraqueza
		Circulares: solos espessos homogêneos e rochas muito fraturadas
		Em cunha: solos e rochas com dois planos de fraqueza
Corridas	Muitas superfícies de deslocamento	
	Movimento semelhante ao de um líquido viscoso	
	Desenvolvimento ao longo das drenagens	
	Velocidade média a alta	
	Mobilização de solo, rocha, detritos e água	
	Extenso raio de alcance, mesmo em área planas	

- Quedas

  As quedas ocorrem quando uma massa, de qualquer tamanho, se desprende de um penhasco ou de uma encosta com alta declividade, sendo caracterizados como movimentos rápidos, sem superfície de movimentação definida e em que os blocos podem se deslocar por queda livre, saltação ou rolamento (Fig. 3.1) (Varnes, 1978; Guidicini e Nieble, 1984; Summerfield, 1991; Augusto Filho, 1992; Florenzano, 2008; Tominaga et al., 2009).

As quedas podem ser divididas em dois tipos de acordo com o tipo de material deslocado, sendo denominadas de quedas de rocha ou de solo (Varnes, 1978; Guidicini e Nieble, 1984; Summerfield, 1991; Augusto Filho, 1992; Florenzano, 2008; Tominaga et al., 2009). As quedas de rocha ocorrem quando blocos de rocha sã, normalmente do embasamento, se desprendem de um penhasco ou da encosta, sendo este o tipo mais comum do movimento. As quedas de solo ocorrem da mesma forma que as quedas de rochas, porém são mais raras, uma vez que em locais muito íngremes a espessura de solo é praticamente inexistente (Summerfield, 1991).

O desprendimento dos blocos da encosta pode ocorrer por diversos fatores, muitos deles relacionados ao intemperismo físico, como alívio de tensão, variação térmica do maciço rochoso, espaçamento de juntas pela ação térmica ou da água, presença de descontinuidades, entre outros (Guidicini e Nieble, 1984; Summerfield, 1991; Augusto Filho, 1992; Florenzano, 2008; Tominaga et al., 2009).

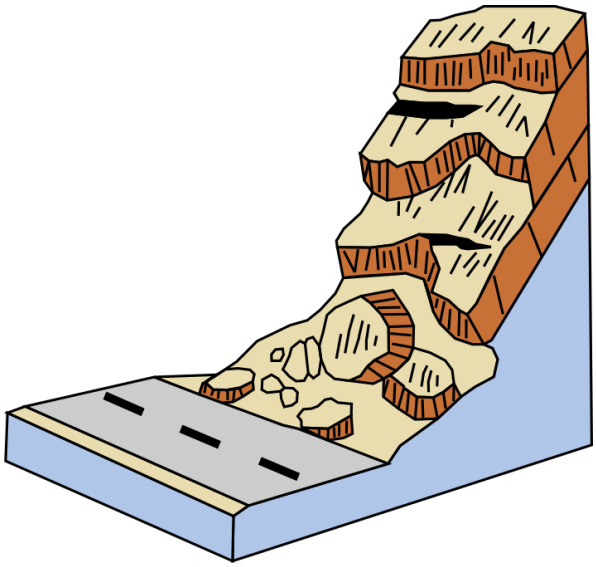

Figura 3.1. Movimento do tipo queda de blocos. Modificado de Highland (2004).

- Rastejos

  Os rastejos são basicamente descritos como movimentos lentos e contínuos que ocorrem nas vertentes e podem deslocar grandes volumes de material (Fig. 3.2) (Varnes, 1978; Guidicini e Nieble, 1984; Summerfield, 1991; Augusto Filho, 1992; Florenzano, 2008; Tominaga et al., 2009). Sua movimentação normalmente é provocada pela ação da gravidade e pode ocorrer tanto em rocha como no solo, sendo que a deformação plástica desses materiais ocorre devido ao estresse gerado pela sobrecarga de material (Summerfield, 1991; Florenzano, 2008; Tominaga et al., 2009). Efeitos de variação de temperatura e umidade, que provocam contração e expansão do material, também podem procovar a movimentação do material.

Segundo Varnes (1978), são movimentos geralmente imperceptíveis e são divididos em três estágios: primário, secundário e terciário. Nos estágios finais, os rastejos apresentam evidentes deformações que são precursoras de eventos maiores e mais potentes como escorregamentos (Summerfield, 1991).

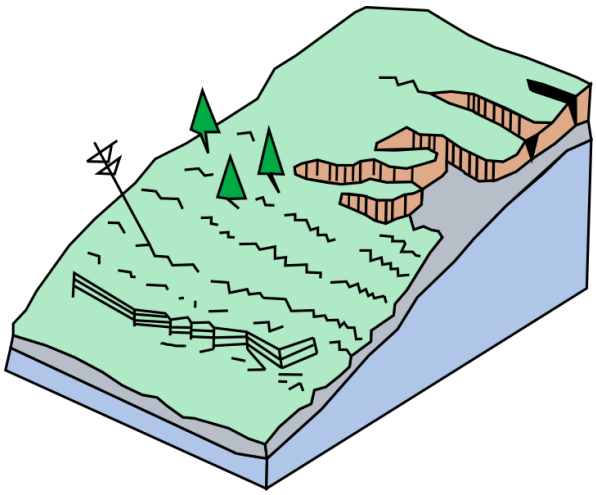

Figura 3.2. Movimento do tipo rastejo. Modificado de Highland (2004).

- Escorregamentos

  Os escorregamentos são caracterizados como movimentos rápidos (metros/segundo), de curta duração, com limites bem definidos, que se deslocam pela ação da gravidade ao longo de uma ou mais superfícies de ruptura definidas (Varnes, 1978; Guidicini e Nieble, 1984; Summerfield, 1991; Augusto Filho, 1992; Florenzano, 2008; Tominaga et al., 2009; Lopes e de Arruda Junior, 2015). A movimentação ocorre quando a tensão de cisalhamento aumenta consideravelmente em relação à resistência ao cisalhamento do material, e o deslocamento encosta abaixo permanece até que ocorra um aumento da resistência normalmente relacionado com a diminuição da declividade (Guidicini e Nieble, 1984; Summerfield, 1991).

  Segundo Lopes e de Arruda Junior (2015) os escorregamentos podem apresentar diversas classificações, no entanto as classificações mais comuns levam em consideração atributos como a geometria do plano de ruptura e a natureza do material instabilizado (Tominaga et al., 2009). Varnes (1978), Summerfield (1991) e Florenzano (2008) dividem os escorregamentos em dois tipos, translacionais e rotacionais, enquanto Guidicini e Nieble (1984) e Augusto Filho (1992) apresentam uma classificação em três tipos, planares, circulares e em cunha.

  - *Escorregamentos Translacionais*

  Os escorregamentos translacionais são os mais frequentes entre todos os tipos de movimentos de massa, considerando o contexto brasileiro (Guidicini e Nieble, 1984; Wolle, 1988;

Tominaga et al., 2009; Lopes e de Arruda Junior, 2015). São basicamente caracterizados por apresentarem um plano de ruptura abrupto, bem definido e planar (Fig. 3.3) (Varnes, 1978; Guidicini e Nieble, 1984; Wolle, 1988; Summerfield, 1991; Florenzano, 2008; Tominaga et al., 2009).

Normalmente, são escorregamentos pequenos, rasos, com profundidades inferiores a 5 metros, e com comprimentos superiores à sua largura (Guidicini e Nieble, 1984; Summerfield, 1991; Tominaga et al., 2009). Podem ocorrer em encostas com diferentes declividades, tanto baixa quanto alta, e podem percorrer centenas ou até milhares de metros de distância (Guidicini e Nieble, 1984; Tominaga et al., 2009). Segundo Varnes (1978), um escorregamento translacional irá prosseguir indefinidamente se a encosta for devidamente inclinada e a resistência ao cisalhamento do plano de ruptura for sempre inferior à força motriz constante.

A movimentação geralmente apresenta um controle estrutural por superfícies de fraqueza como falhas/juntas, acamamentos, heterogeneidades de solos e rochas, variações na força de cisalhamento entre camadas depositadas e pelo contato entre rocha e detritos (Varnes, 1978; Tominaga et al., 2009).

Guidicini e Nieble (1984) adotaram uma subdivisão para os escorregamentos translacionais de acordo com o tipo de material deslocado, se ocorre em rocha ou solo, ou uma combinação de ambos. No primeiro caso, a movimentação ocorre nos planos de fraqueza da rocha relacionados à sua estrutura como fraturas, xistosidades, acamamento, estratificação, gnaissificação, entre outros. No segundo caso, que são predominantes na Serra do Mar (Wolle, 1988), a movimentação ocorre ao longo de superfícies planas preexistentes e condicionadas a alguma feição estrutural do substrato, como o próprio contato entre os diferentes horizontes de alteração que apresentam forma tabular com espessuras que variam de acordo com a litologia, o clima e o relevo. Os escorregamentos translacionais em solo são de curta duração, com velocidade elevada e com alto poder destrutivo (Tominaga et al., 2009). O terceiro caso, a combinação de rocha e solo, pode ser devidamente representado pela movimentação de massa de colúvio, costumam deslocar um grande volume de material encosta abaixo e são mais profundos envolvendo rocha alterada e fragmentada.

A ocorrência dos escorregamentos translacionais normalmente está relacionada com períodos de alta pluviosidade, pois as chuvas representam o principal agente deflagador dessas instabilizações, capazes de aumentar a poropressão em uma superfície de descontinuidade que aumenta a tensão cisalhante do solo e a tensão normal, o que gera instabilidade (Florenzano, 2008; Tominaga et al., 2009; Lopes e de Arruda Junior, 2015).

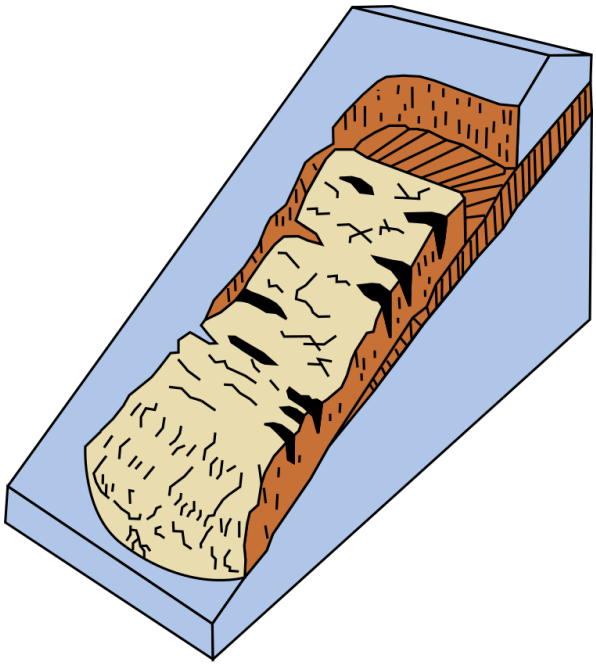

Figura 3.3. Movimento do tipo escorregamento translacional. Modificado de Highland (2004).

- *Escorregamentos Rotacionais*

Os escorregamentos rotacionais se caracterizam pela movimentação rotacional que ocorre sobre uma superfície de ruptura côncava e normalmente desloca uma grande quantidade de material (Fig. 3.4) (Varnes, 1978; Guidicini e Nieble, 1984; Summerfield, 1991; Augusto Filho, 1992; Florenzano, 2008; Tominaga et al., 2009). São movimentações pouco comuns na Serra do Mar (Wolle, 1988), pois sua ocorrência está relacionada com pacotes de solos saporlíticos bem desenvolvidos geralmente espessos e homogêneos, como argilas, e em encostas naturais raramente os materiais são uniformes (Varnes, 1978; Summerfield, 1991; Florenzano, 2008; Tominaga et al., 2009).

A ocorrência deste tipo de movimentação se inicia com o desgaste da base da encosta tanto por ação da erosão fluvial no sopé da vertente quanto por instabilizações geradas por obras civis como corte de talude para abertura de estradas (Varnes, 1978; Fernandes e Amaral, 1996; Florenzano, 2008; Tominaga et al., 2009).

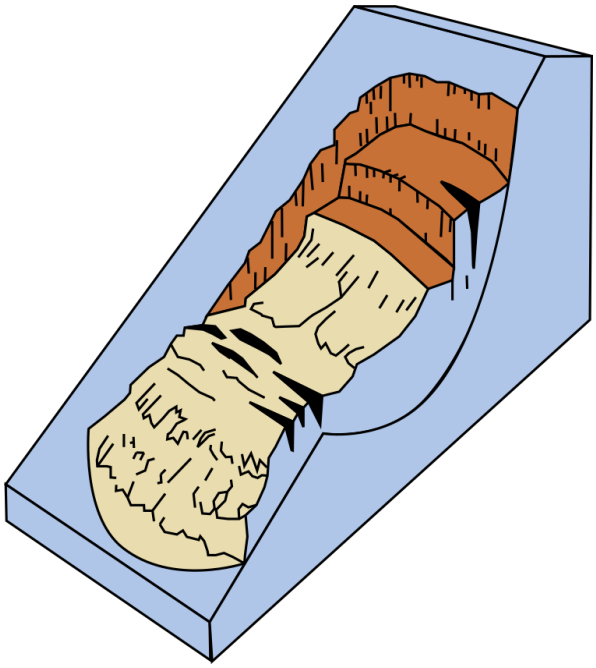

Figura 3.4. Movimento do tipo escorregamento rotacional. Modificado de Highland (2004).

- *Escorregamento em Cunha*

Os escorregamentos em cunha são fortemente controlados pelas estruturas geológicas, estão relacionados com maciços rochosos alterados em que ocorre a intersecção de duas ou mais estruturas planares (falhas/fraturas) ocasionando o deslocamento de um bloco com forma de prisma (Fig. 3.5) (Guidicini e Nieble, 1984; Tominaga et al., 2009). Sua ocorrência é bastante restrita e se dá, principalmente, em taludes de corte ou em encostas que soferam um desconfinamento (Infanti Jr e Fornasari Filho, 1998).

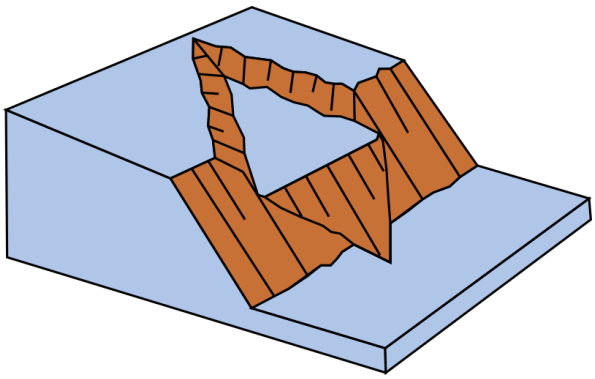

Figura 3.5. Movimento do tipo escorregamento em cunha. Modificado de Augusto Filho (1992).

- Corridas

As corridas representam movimentações que são geradas pelo grande aporte de materiais como solo, rocha e árvores, canalizados nas drenagens formando uma massa com elevada viscosidade e densidade, movimetando-se de forma rápida, e a instabilização é causada pela perda do atrito interno das partículas do solo devido ao excesso de água (Fig. 3.6) (Guidicini e Nieble, 1984; Augusto Filho, 1992; Florenzano, 2008). A massa deslocada pode atingir grandes distâncias mesmo em áreas relativamente planas e possuem um poder destrutivo superior ao dos escorregamentos.

Varnes (1978) explica que geralmente os materiais inconsolidados se movimentam na forma de corridas podendo ocorrer em diversas velocidades e com diferentes taxas de umidade. As corridas podem ser subdivididas de acordo com a composição do material deslocado seja neve, gelo, fragmentos de rochas ou areia e outros sedimentos finos, sendo clasificadas por Varnes (1978) e Summerfield (1991) em avalanches, corrida de massa, corridas de terra e corridas de lama. Essas classficações são bastante específicas e locais, fortemente baseadas nos objetivos do autor e sua experiência (Gramani, 2001). No caso do Brasil, as corridas não apresentam uma divisão e são denominadas como corridas de massa, ou fluxo de detritos.

Normalmente as corridas são iniciadas a partir de outros movimentos de massa como quedas e, principalmente, escorregamentos que acumulam material na drenagens em períodos de chuvas intensas (Costa e Fleisher, 1984; Summerfield, 1991; Lopes e de Arruda Junior, 2015). Segundo Varnes (1978), existe uma evidente gradação de escorregamentos para corridas de massa, dependendo da quantidade de água disponível, mobilidade e característica da movimentação.

Summerfield (1991) considera as corridas como agentes erosivos efetivos na modelagem das encostas, especialmente os tipos mais enérgicos e destrutivos como as corridas de massa e as avalanches.

Gramani (2001) define os principais fatores internos e externos que contribuem para eventos de corridas de massa. Os fatores internos, ou agentes predisponentes, representam as características intrínsecas do ambiente como geometria das encostas e das drenagens, enquanto que os fatores externos, ou agente deflagador, representam eventos naturais como precipitações pluviométricas, degelo, entre outros.

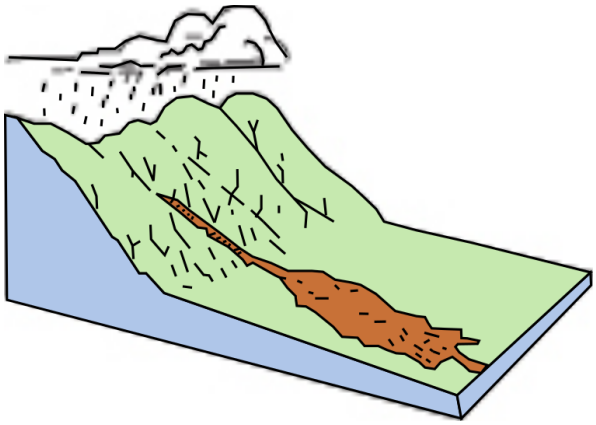

Figura 3.6. Movimento do tipo corridas de massa. Modificado de Highland (2004).

3.1.2. Identificação de escorregamentos

Scaioni et al. (2014) consideram que os estudos para identificação dos escorregamentos englobam todas as atividades relacionadas ao reconhecimento de eventos de escorregamentos do passado que ocorreram em uma determinada região.

O método convencional para identificação dos escorregamentos consiste em um conjunto de técnicas que efetuam a digitalização e interpretação de mapas topográficos, a execução de trabalhos de campo e análises de fotografias aéreas (Guzzetti et al., 1999; Eeckhaut et al., 2005; Booth et al., 2009; Burns e Madin, 2009; Guzzetti et al., 2012; Roering et al., 2013; Scaioni et al., 2014). No entanto este método apresenta limitações capazes de prejudicar o escopo e a precisão dos produtos finais (Booth et al., 2009):

- Trabalhos de campo

  As principais dificuldades dos trabalhos de campo são devido à inacessibilidade das áreas de estudo (encostas), ao tamanho das áreas de ocorrência dos eventos e ao tempo requerido para a coleta dos dados (Eeckhaut et al., 2005; Booth et al., 2009; Scaioni et al., 2014). Além do difícil acesso às áreas que sofreram escorregamentos, Guzzetti et al. (2012) ponderam ainda outras dificuldades para a identificação de escorregamentos em trabalhos de campo como: as dimensões dos escorregamentos, normalmente muito extensos, impedindo uma análise *in situ* completa; o ponto de visada do pesquisador que geralmente é inadequado para a análise de todas as feições de um escorregamento; o recobrimento parcial ou total de escorregamentos antigos pela vegetação; a atuação de processos erosivos; a sobreposição por um evento de escorregamento mais recente, e atividades antrópicas (agricultura, aterramento).

- Fotografias aéreas

Atualmente as fotografias aéreas ainda permanecem como importantes ferramentas para a identificação e mapeamento de escorregamentos (Guzzetti et al., 2012). Isso se deve ao fato de suas características estereoscópicas propiciarem o fácil reconhecimento de variações morfológicas no terreno (Guzzetti et al., 1999; Ardizzone et al., 2007; Pike et al., 2009; Scaioni et al., 2014); suas escalas e dimensões são convenientes para o manuseio e interpretação do relevo (Guzzetti et al., 2012); e por possuir um vasto banco de dados, uma vez que a obtenção de fotografias aéreas é uma prática muito difundida entre diversas nações, permitindo a realização de análises temporais (Guzzetti et al., 2005, 2012). Apesar da ampla utilização de fotografias aéreas, esta técnica exige muita prudência já que a análise visual de escorregamentos requer experiência, conhecimento empírico, treinamento, critérios de avaliação bem definidos e uma metodologia sistemática de análise (Zuidam, 1986; Guzzetti et al., 2012).

A vegetação também representa um problema na análise de fotografias aéreas, pois a cobertura vegetal encobre as feições morfológicas indicativas de escorregamentos (Eeckhaut et al., 2005; Booth et al., 2009; Scaioni et al., 2014). Guzzetti et al. (2012) afirmam que o tipo, altura, densidade e variações temporais da vegetação influenciam diretamente a capacidade visual de identificação dos escorregamentos, bem como acrescentam que, em regiões tropicais, o crescimento acelerado da vegetação pode suprimir as feições morfológicas em questão de meses.

- Modelos Digitais de Elevação

  Segundo Derron e Jaboyedoff (2010) desde o surgimento das técnicas de escaneamento a laser na década de 1990, houve um significativo aumento nos estudos de escorregamentos utilizando modelos digitais de elevação de alta resolução (HRDEM - *High Resolution Digital Elevation Model*), sendo esse aumento impulsionado pela liberação dos dados para a comunidade de geocientistas há cerca de duas décadas. Os autores ainda apresentam um breve histórico da utilização dos modelos digitais de elevação de alta resolução, sendo primeiramente utilizados como suporte para mapeamento geomorfológico e análises qualitativas do relevo (McKean e Roering, 2004; Eeckhaut et al., 2005; Corsini et al., 2009; Passalacqua et al., 2010; Ghuffar et al., 2013), para estimativa do volume dos materiais deslocados (Hsiao et al., 2004; Du e Teng, 2007; Baldo et al., 2009), para estudos de estabilidade a partir de descontinuidades e fraturas (Brideau et al., 2012; Stumpf et al., 2013) e, mais recentemente, para monitoramento e identificação de escorregamentos e outros movimentos de massa (Shikada et al., 1997; Metternicht et al., 2005; Glenn et al., 2006; Ardizzone et al., 2007; Schulz, 2007; Eeckhaut et al., 2007; Booth et al., 2009; Burns e Madin, 2009; Haneberg et al., 2009; Burns et al., 2010; Eeckhaut et al., 2011; Jaboyedoff et al., 2012; Chen et al., 2013; Wang et al., 2013; Scaioni et al., 2014).

3.2. Artigo 1 - *lidar* e SfM-MVS

O artigo 1 tem como principal objetivo efetuar uma comparação entre os dados topográficos obtidos pelos métodos de *lidar* e SfM-MVS para a análise morfométrica de um escorregamento. Essa comparação é fundamental para avaliação da qualidade dos dados gerados pelo processo SfM-MVS em relação aos dados de *lidar* que representam o padrão ouro nos estudos de terreno. Os dados gerados pelo processo SfM-MVS ganharam popularidade nos últimos anos devido a facilidade de manuseio, maior acessibilidade em áreas instáveis, melhor custo-benefício e programas com interfaces mais amigáveis ao usuário (Viana, 2021). Dessa forma, constatar a eficácia dos dados SfM-MVS para o objetivo proposto significa um grande avanço nos estudos de escorregamentos, reduzindo o tempo necesssário para coleta de dados em campo e no processamento dos mesmos.

Outros estudos efetuaram comparações semelhantes utilizando os dados obtidos por esses métodos (Yu et al., 2017a; Eker et al., 2018; Carey et al., 2019; Hung et al., 2019; Mokhtar et al., 2019; Morocho et al., 2019; Pellicani et al., 2019; Tsunetaka et al., 2020). No geral, os resultados obtidos nesses trabalhos demonstraram que os dados gerados pelo processo SfM-MVS são similares e, por vezes, melhores que os dados *lidar* dependendo das características específicas do terreno e do objeto de estudo. As comparações entre os dados de *lidar* e de SfM-MVS podem ser efetuados de três modos: ponto com raster (PR), raster com raster (RR) e ponto com ponto (PP). Cada modo de comparação apresenta vantagens e desvantagens sendo sua escolha determinada por fatores como resolução espacial dos dados, escala de trabalho e características da área de estudo (Carrivick et al., 2016).

A comparação PR é realizada entre os pontos precisos obtidos pela medição de estações totais (ET) e/ou dGPS (GPS diferencial) com um MDS gerado pelos dados SfM-MVS. Normalmente, o MDS é gerado pela interpolação dos dados SfM-MVS utilizando o valor médio, ou valor mínimo, para classificar os pixels podendo assim gerar erros quando comparados com os pontos das ET/dGPS. Dessa forma, a eficiência do método de comparação PR depende do tamanho do pixel escolhido para o MDS, sendo que quanto menor o pixel menor o erro de comparação.

A comparação RR representa a comparação entre MDS gerados com dados obtidos por diferentes técnicas como ET, dGPS, TLS e SfM-MVS. A qualidade da comparação RR depende exclusivamente da disponibilidade de levantamentos com resoluções espaciais comparáveis, uma vez que o tamanho do pixel dos MDS é fundamental para a qualidade da comparação. Carrivick et al. (2016) considera que a comparação RR é a mais apropriada na maioria das aplicações em que existem dados de TLS e de SfM-MVS disponíveis. É a comparação mais comumente utilizada em trabalhos que envolvem análise, identificação ou monitoramento de escorregamentos.

Por fim, a comparação PP é normalmente efetuada entre nuvens de pontos de TLS e SfM-MVS. Este tipo de comparação é usualmente considerada a mais apropriada e que deveria apresentar os menores erros, no entanto algumas considerações são necessárias: 1 - as nuvens de pontos raramente representam o produto final das análises topográficas sendo mais utilizadas apenas para visualização; 2 - a localização específica dos pontos nas nuvens de pontos é definida pelo

espaçamento angular no TLS e pela localização de pontos-chave nas imagens do RPA, de modo que não é possível pressupor que a localização dos pontos é concordante. Consequentemente, essas divergências podem enviesar as comparações PP dimunindo sua eficiência e causando erros.

No artigo 1, considerando a escala de detalhe da área de estudo, foram efetuadas as comparações entre as nuvens de pontos do TLS e do SfM-MVS (comparação PP) e entre os índices morfométricos derivados dos MDS (declividade e rugosidade) gerados para cada método (comparação RR).

Nessa seção são apresentadas as descrições técnicas de cada processo utilizado de modo a esclarecer o seu funcionamento.

lidar terrestre

Segundo Telling et al. (2017), os dados topográficos de alta resolução são considerados indispensáveis para as pesquisas relacionadas às ciências da terra, sendo os dados provenientes de escaneamento a laser, ou *lidar*, os mais utilizados nos últimos anos. A fotogrametria foi pioneira na transição entre os métodos convencionais de levantamento e processamento de dados para métodos mais modernos com a utilização de câmeras digitais e *software* (Chandler, 1999), que juntamente com o advento do GPS (*Global Positioning System*) causou grande impacto na coleta de dados topográficos (Buckley et al., 2008).

Buckley et al. (2008) apontam que, desde o começo da década de 2000, o escaneamento a laser representa a vanguarda das técnicas de levantamento de dados topográficos, uma vez que permite uma aquisição rápida e detalhada da superfície terrestre por diversas plataformas sejam aerotransportadas (ALS - *Airborne Laser Scanning*) ou terrestres (TLS - *Terrestrial Laser Scanning*) (Fig. 3.7). Os sensores ALS foram os primeiros a serem amplamente utilizados pela comunidade científica para estudos da superfície terrestre. Wehr e Lohr (1999) e Baltsavias (1999) foram pioneiros em descrever e apresentar os métodos para utilização desses sensores. Apenas com o acelerado desenvolvimento tecnológico que ocorreu nas últimas décadas que o uso dos sensores TLS começou a ser mais difundido e explorado pelos pesquisadores das ciências da terra (Buckley et al., 2008; Baldo et al., 2009; Telling et al., 2017).

As técnicas de coleta de dados por escaneamento à laser tiveram um desenvolvimento bastante significativo ao ponto de o escaneamento aerotransportado se tornar o sistema de levantamento de dados padrão para diversas agências governamentais que efetuam estudos relacionados ao terreno como tectônica (Meigs, 2013), profundidade de camadas de neve (Deems et al., 2013) e monitoramento de escorregamentos (McKean e Roering, 2004; Glenn et al., 2006; Ardizzone et al., 2007; Eeckhaut et al., 2009, 2011; Jaboyedoff et al., 2012). No caso do escaneamento TLS, as inovações tecnológicas proporcionaram sua viabilidade em praticamente todos os ambientes e ecossistemas, assim como a evolução dos programas computacionais possibilitou o processamento das densas e complexas nuvens de pontos tridimensionais (Buckley et al., 2008).

No escaneamento a laser, os dados topográficos são obtidos pelo cálculo de distância percorrida entre a fonte e o sensor utilizando raios de laser, que só é possível devido a propriedade fundamental da energia eletromagnética em relação a sua velocidade de propagação (Vosselman e Maas, 2010). Em um determinado meio a velocidade da onda tem valor finito e constante possibilitando calcular a distância percorrida pelo laser através do intervalo de tempo de seu deslocamento (Wehr e Lohr, 1999; Baltsavias, 1999).

Apesar dos aparelhos de escaneamento à laser poderem ser acoplados em aeronaves (ALS), em tripés fixos no chão (TLS), ou mesmo em veículos móveis como carros ou barcos (MLS - *Mobile Laser Scanner*) (Fig. 3.7), os métodos utilizados para o cálculo da distância e coleta dos dados são similares (Hetherington, 2010; Vosselman e Maas, 2010; Telling et al., 2017). Vosselman e Maas (2010) explicam que existem basicamente dois métodos para a mensuração óptica de superfícies tridimensionais: o cálculo do tempo de deslocamento da radiação eletromagnética (*time-of-flight*) e por triangulação. O método de cálculo pelo tempo de deslocamento é o mais usual entre os sensores à laser e pode efetuar os levantamentos tanto pelo pulso do feixe de laser como pela diferença de fase da energia eletromagnética gerada.

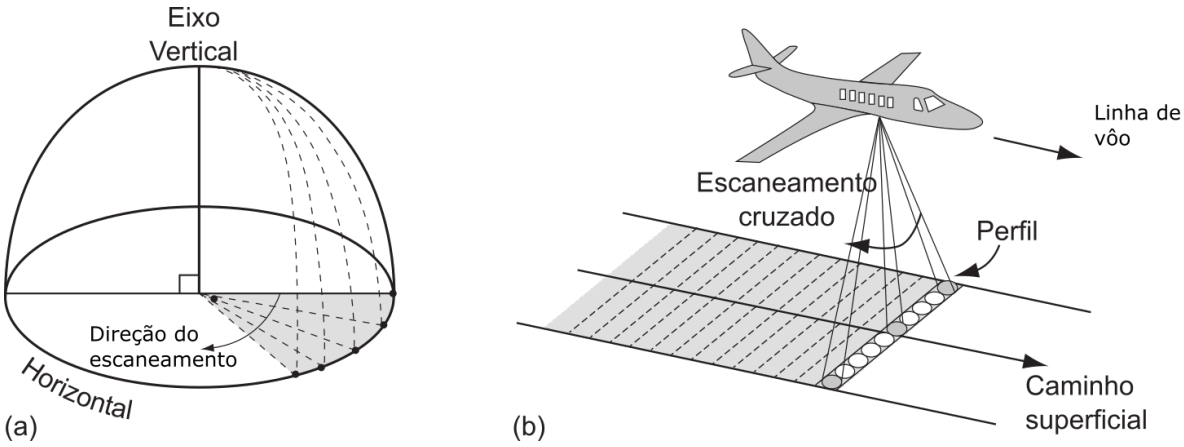

Figura 3.7. a) Equipamento terrestre (TLS), b) Equipamento aerotransportado (ALS). Modificado de Shan e Toth (2009).

Método de cálculo do tempo de deslocamento da luz pelo pulso

No método de cálculo pelo pulso do feixe, um pulso pequeno (1 a 10 ns) e intenso é gerado e a distância entre o sensor e um objeto é determinada através da mensuração do tempo decorrido entre o feixe de laser ser emitido pela fonte e retornar ao sensor (Fig. 3.8) (Baltsavias, 1999; Shan e Toth, 2009; Vosselman e Maas, 2010; Carrivick et al., 2016; Telling et al., 2017). Esse procedimento é repetido milhares ou mesmo dezenas de milhares de vezes por segundo, garantindo a alta precisão e resolução espacial dos dados (Carrivick et al., 2016). Por efetuar o cálculo

da distância de forma direta, este é o método mais comumente utilizado pelos aparelhos de escaneamento à laser (Shan e Toth, 2009; Telling et al., 2017).

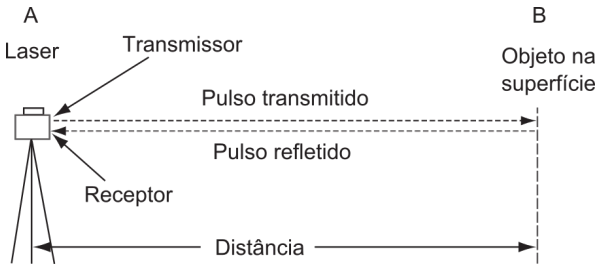

Figura 3.8. Princípio básico de um equipamento de escaneamento que utiliza o método de cálculo pelo pulso. Modificado de Shan e Toth (2009).

O cálculo preciso da distância pelo método do pulso é determinado pela equação 3.1, que relaciona a velocidade de propagação do laser em um meio com o intervalo de tempo para o raio emitido atingir um objeto e ser refletido (Baltsavias, 1999; Shan e Toth, 2009; Vosselman e Maas, 2010; Telling et al., 2017). Este método de levantamento, pelo cálculo da distância percorrida pelo pulso emitido, ocorre de maneira similar tanto para o escaneamento ALS como para o TLS sendo que suas divergências existem relacionadas a outros aspectos técnicos do aparelho, como distância do sensor até o objeto.

$$r = \frac{c\Delta t}{n2} \tag{3.1}$$

Sendo *r* a distância, *c* a velocidade da luz no vácuo, *n* é o índice de refração do meio pelo qual a radiação eletromagnética está viajando e Δt é o tempo de viagem de ida e volta do laser até o alvo (Baltsavias, 1999; Shan e Toth, 2009; Vosselman e Maas, 2010; Telling et al., 2017).

Múltiplos retornos de pulsos podem ser detectados dependendo das características da área de estudo, especialmente se houver a presença de cobertura vegetal (Fig. 3.9) (Pfeifer e Briese, 2007). O comprimento do pulso emitido pelo sensor é uma característica fundamental para a análise dos dados refletidos coletados, pois interfere diretamente na quantidade de retornos de um pulso que podem ser identificados e diferenciados (Shan e Toth, 2009). Cada retorno representa a reflectância do laser por um objeto diferente, por exemplo, o primeiro e o último retorno capturados por sensores aerotransportados em áreas com cobertura vegetal, normalmente representam o dossel e a superfície do terreno, respectivamente (Baltsavias, 1999; Shan e Toth, 2009; Vosselman e Maas, 2010).

Shan e Toth (2009) e Vosselman e Maas (2010) consideram que o método de detecção do tempo de deslocamento do pulso, e consequentemente da distância, é essencial para estabelecer a precisão do sensor. O aparelho detector irá apenas iniciar seu cronômetro dependendo dos critérios pré estabelecidos, sendo que alguns métodos de detecção utilizam posições características da trajetória do pulso como, por exemplo: detecção na crista da pulso eletromagnético, detecção

a partir de um limiar de amplitude da onda pré estabelecido, e detecção por uma fração constante de amplitude. Jutzi (2007) ressalta que cada método de detecção apresenta seus prós e contras, porém o método por fração constante de amplitude demonstra ser o mais adequado.

A capacidade de detectar a mesma posição relativa nos pulsos eletromagnéticos transmitidos e retornados é essencial para calcular o intervalo de tempo de deslocamento do laser, porém existem vários fatores limitantes como a presença de ruídos, a intensidade do sinal, a sensibilidade do aparelho, a brevidade e reprodutibilidade do pulso transmitido (Baltsavias, 1999).

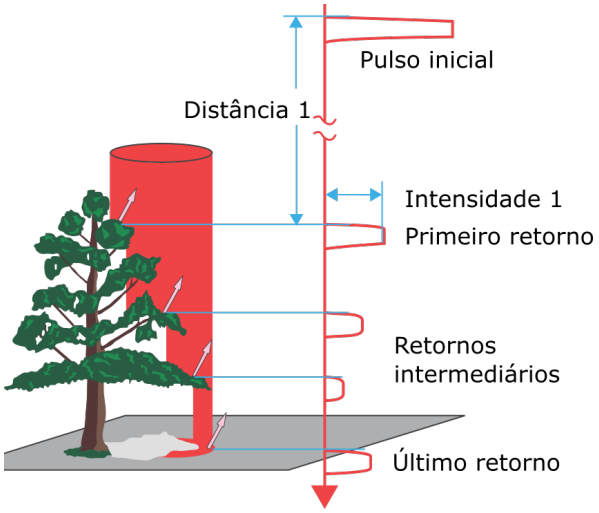

Figura 3.9. Retornos múltiplos recebidos pelo sensor. Modificado de Vosselman e Maas (2010).

Portanto, é correto considerar que a resolução e precisão de um sensor à laser são determinados por diferentes fatores com destaque para o comprimento do pulso emitido e pela capacidade (ou sensibilidade) do aparelho para detecção dos retornos de um pulso (Baltsavias, 1999; Shan e Toth, 2009). A qualidade do cronômetro utilizado pelo sensor é fundamental para determinar essa precisão. Vosselman e Maas (2010) constatam que a maioria dos sensores de escaneamento à laser disponíveis no mercado possuem uma precisão que varia entre 5 - 15 mm, alguns até 50 mm, a taxa de coleta de dados varia entre aproximadamente 50.000 - 500.000 pontos por segundo, e o alcance dos sensores terrestre pode ultrapassar os 1000 metros.

Método de cálculo do tempo de deslocamento da radiação eletromagnética pela diferença de fase

O tempo de deslocamento do laser pode ser obtido de forma indireta através das medições de fase em sensores de ondas contínuas (Shan e Toth, 2009; Vosselman e Maas, 2010). Neste método, ao invés de um pulso de laser, o sensor utiliza uma modulação de onda contínua sendo que o tempo de deslocamento do feixe de laser pode ser obtido pela modulação da amplitude, pela modulação da frequência e por formas de ondas caóticas geradas por um semicondutor à

laser (Wehr e Lohr, 1999; Vosselman e Maas, 2010). Usualmente o feixe de laser é modulado pela amplitude, em que adquire uma forma de onda senoidal com período e comprimento de onda conhecidos, e então a distância entre o sensor e o objeto é derivada pela comparação entre os sinais emitidos e refletidos de acordo com os padrões da onda senoidal e pela diferença de fase entre eles (Fig. 3.10) (Shan e Toth, 2009; Vosselman e Maas, 2010; Telling et al., 2017).

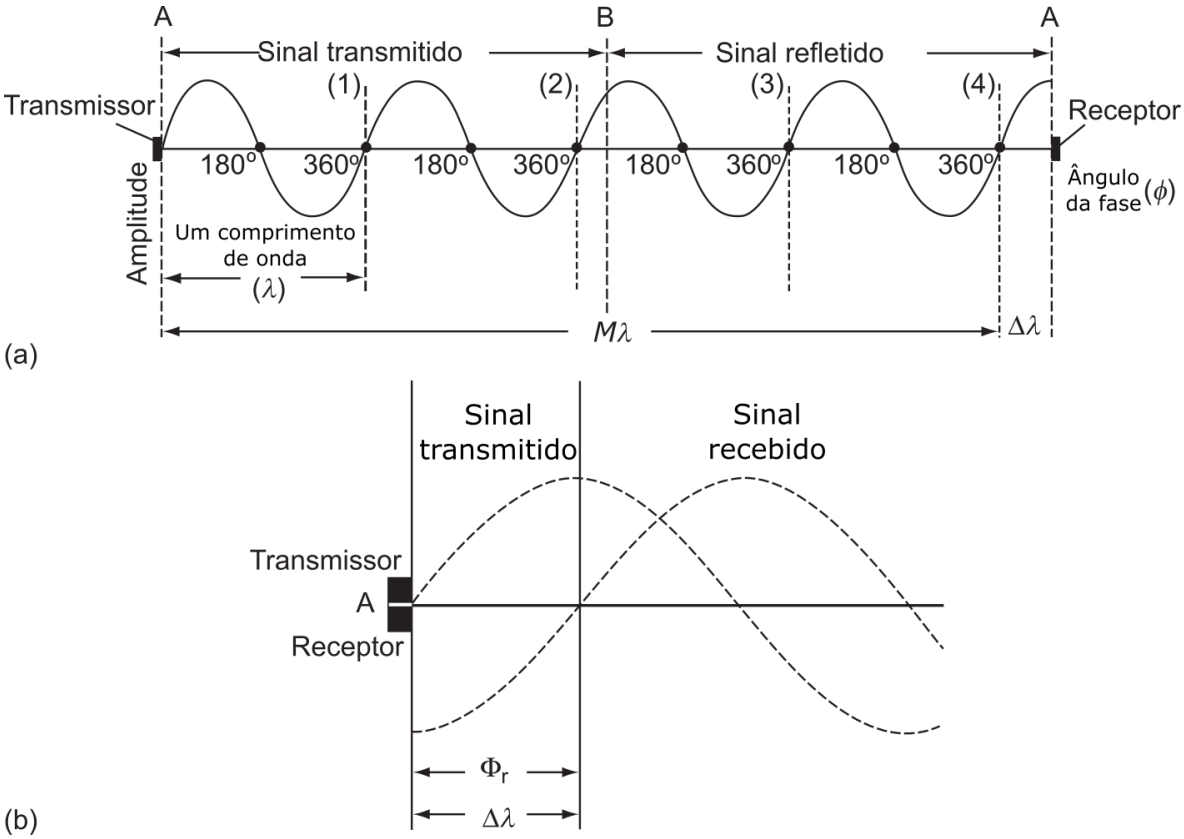

Figura 3.10. a) comparação de fases entre o sinal emitido e o refletido por um laser com comprimento de onda contínuo; b) comparação de fase entre os sinais ocorrem em um único equipamento localizado no ponto A. Modificado de Shan e Toth (2009).

A diferença de fase entre as ondas emitidas e refletidas está diretamente relacionada com o intervalo de tempo entre a emissão e o retorno da onda (Equação 3.2) (Telling et al., 2017). Para o cálculo da distância, é necessário substituir o intervalo de tempo obtido pela equação 3.2 na equação utilizada no método pelo pulso (Equação 3.1). Dessa forma, a definição da distância é efetuada a partir de uma medição precisa da diferença de fase entre os sinais emitidos e refletidos, e esse cálculo é usualmente realizado por uma técnica de contagem digital de pulsos (Shan e Toth, 2009).

A precisão do alcance do laser pelo método da fase depende principalmente de fatores como a frequência da modulação, estabilidade do oscilador de modulação, quantidade de ciclos obtidos, variações do índice de refração e sensibilidade do aparelho de medida da fase (Baltsavias, 1999).

$$\Delta t = \frac{\Delta\phi\lambda_m}{2\pi c} \tag{3.2}$$

Sendo Δt o intervalo de tempo, $\Delta\phi$ a diferença de fase, λ_m o comprimento de onda modulado de amplitude e c a velocidade da luz no vácuo.

Vosselman e Maas (2010) alertam sobre a ocorrência da ambiguidade de fase. Não é possível calcular a distância absoluta, pois o sinal original emitido não apresenta uma relação direta com a onda refletida e as medições de fase são incapazes de identificar os múltiplos dos comprimentos de onda, assim ocorre a denominada ambiguidade de fase. Os autores afirmam que uma solução para este problema seria a utilização de ondas com múltiplas frequências.

Os sensores que modulam a amplitude normalmente apresentam uma alta taxa de coleta de dados (aproximadamente 1 milhão de pontos por segundos) e uma precisão melhor (entre 1 - 10 mm) porém seu alcance é limitado a algumas centenas de metros devido a potência necessária para a manutenção das ondas contínuas e os requisitos para executar a modulação da amplitude em fase única para evitar a ambiguidade de fase (Vosselman e Maas, 2010; Telling et al., 2017).

Mecanismos de Escaneamento

O escaneamento significa desviar um feixe de laser seguindo um padrão de modo que objetos na superfície sejam amostrados com uma alta densidade de pontos (Wehr e Lohr, 1999). Essa deflexão do feixe de laser é efetuada pela utilização de espelhos que se movimentam desviando o laser em direção a superfície e aumentando assim sua área de cobertura.

Os principais mecanismos de escaneamentos são apresentados nos trabalhos de Wehr e Lohr (1999), Shan e Toth (2009) e Vosselman e Maas (2010). Basicamente são quatro mecanismos os mais utilizados (Fig. 3.11): espelhos oscilantes, espelho poligonal rotativo, *scanner* Palmer e *scanner* de fibra de vidro. Cada mecanismo desvia o laser de maneira distinta, dessa forma o padrão do levantamento será diferente podendo ocorrer com pontos coletados em direções paralelas, em zigue zague ou mesmo em elipsóides.

- TLS (*Terrestrial Laser Scanner*)

  Os sensores TLS podem ser utilizados de duas maneiras: estático, quando o equipamento é montando em um tripé fixo no chão; ou móvel, quando o equipamento é montado em um meio de transporte podendo ser terrestre, como um carro, ou mesmo aquático, quando montado em barcos (Shan e Toth, 2009; Vosselman e Maas, 2010; Carrivick et al., 2016; Telling et al., 2017). Normalmente os sensores terrestres estáticos são mais utilizados para levantamentos, uma vez que os sensores móveis são mais complexos, necessitando utilizar sistemas integrados de GPS/IMU (*Global Positioning System/Inertial Measurement Units*) para um contínuo georreferenciamento do deslocamento do veículo, assim como ocorre com sensores aerotransportados (Vosselman e Maas, 2010).

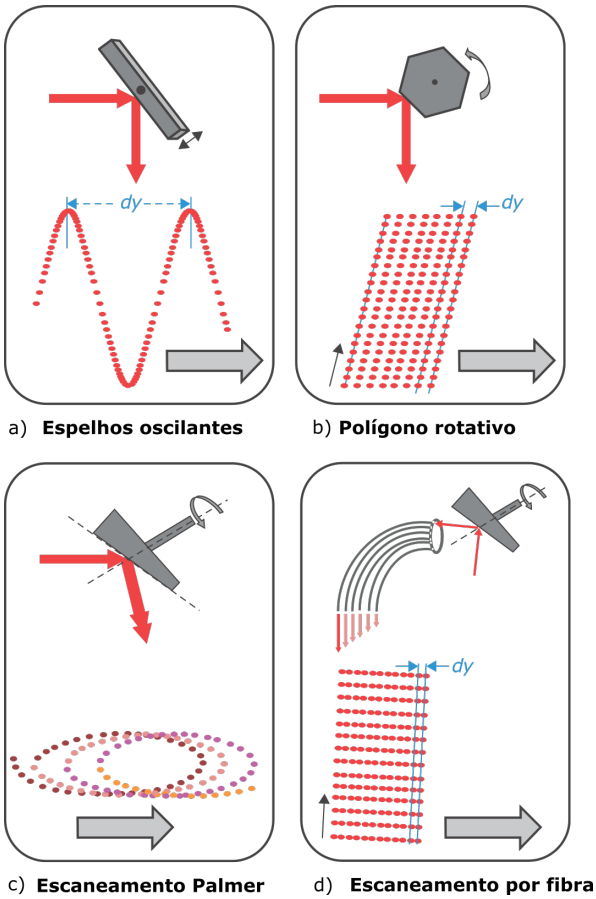

Figura 3.11. Mecanismos de escaneamento. Modificado de Vosselman e Maas (2010).

A utilização de sensores TLS em estudos de escorregamentos só foi ocorrer anos após a adoção de sensores ALS, provavelmente devido aos altos custos dos aparelhos de escaneamento à laser quando comparado aos equipamentos de levantamentos topográficos tradicionais como estação total, receptores GNSS, teodolitos e niveladores (Shan e Toth, 2009; Telling et al., 2017). Em muito casos, os usuários pioneiros de TLS eram profissionais que utilizavam sensores ALS para levantamentos topográficos e, portanto, já estavam acostumados a trabalhar com equipamentos de escaneamento à laser.

Segundo Carrivick et al. (2016), os sensores terrestres são otimizados para ter uma precisão específica com um determinado alcance, uma vez que o feixe de laser é espalhado com o aumento da distância entre o objeto e o aparelho, causando o aumento da área de cobertura do sensor e diminuindo a precisão. Usualmente, o alcance dos sensores varia desde dezenas de metros até a alguns quilômetros. Dessa forma, os sensores terrestres normalmente são classificados de duas maneiras: pelo seu princípio fundamental de medição e pelo campo de visão para coleta dos dados (Shan e Toth, 2009; Telling et al., 2017). A classificação pelo príncipio fundamental diferencia os equipamentos que utilizam o método do pulso,

ou tempo de deslocamento da radiação eletromagnética, e os que utilizam o método por diferença de fase. Shan e Toth (2009) ressaltam que para o caso específico dos sensores terrestres estáticos, o método pela diferença de fase produz uma série de sucessivas medições com uma alta taxa de coleta e alta precisão, porém apenas para distâncias pequenas que não ultrapassam algumas dezenas de metros. Já os sensores que utilizam o método do pulso permitem efetuar levantamentos em distâncias maiores porém com taxas de coleta e precisões inferiores.

A classificação pelo campo de visão (*field of view* - FOV) considera tanto o mecanismo quanto o padrão de escaneamento do terreno (Shan e Toth, 2009). Com o sensor fixado em um tripé, o mecanismo de escaneamento deve direcionar os feixes de laser em ao menos duas direções para ser possível gerar a nuvem de pontos tridimensionais (Telling et al., 2017). Assim os sensores terrestres apresentam três classificações quanto ao campo de visão (Fig. 3.12) : (1) escaneamento tipo câmera, (2) escaneamento híbrido e (3) escaneamento panorâmico (Shan e Toth, 2009; Vosselman e Maas, 2010; Telling et al., 2017).

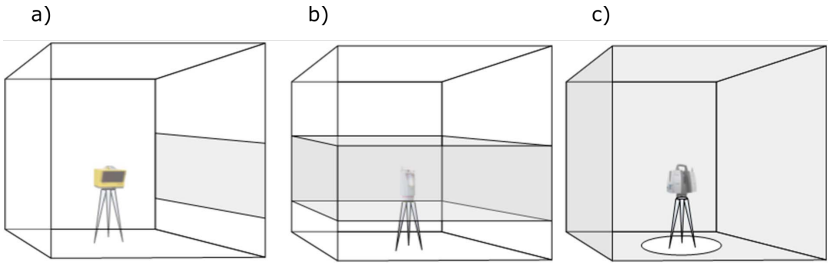

Figura 3.12. Em cinza, os diferentes tipos de campos de visão do equipamento *lidar*. Modificado de Telling et al. (2017); a) escaneamento tipo câmera, b) escaneamento híbrido, e c) escaneamento panorâmico.

1. Escaneamento tipo câmera

   Este tipo de escaneamento executa o levantamento de dados com um alcance angular muito restrito (40° x 40°) e uma visada específica, de forma semelhante ao imageamento obtido com a utilização de câmeras digitais (Shan e Toth, 2009; Telling et al., 2017).

2. Escaneamento híbrido

   No escaneamento híbrido, o escaneamento em si ocorre de forma irrestrita ao redor do eixo de rotação do equipamento, sendo normalmente um movimento horizontal de escaneamento na direção azimutal devido a rotação do equipamento em seu eixo vertical (Shan e Toth, 2009; Telling et al., 2017). Os movimentos verticais do equipamento são restritos podendo formar ângulos que variam entre 50° e 60° em relação ao eixo horizontal. Muito utilizado para levantamentos topográficos em que não há a necessidade de coletar pontos sobre o equipamento ou em ângulos muito agudos.

3. Escaneamento panorâmico

   Este tipo de escaneamento efetua o levantamento de pontos sistematicamente, permitindo uma cobertura angular de 360° na horizontal e de ao menos 180° na vertical (Shan e Toth, 2009). A única porção da área de interesse que não é imageada pelo sensor é a superfície da base do equipamento, ocupada pelo tripé. Este tipo de equipamento tem seu uso mais difundido para estudos em ambientes fechados e em áreas industriais.

SfM-MVS (*Structure-from-motion Multi-View Stereo*)

A fotogrametria tradicional é uma técnica consagrada nos estudos das geociências ainda que existam diversas restrições ao seu uso, como a necessidade de estereopares paralelos de imagens com cerca de 60% de sobreposição, a calibração dos parâmetros da câmera, medidas precisas de localização 3D e da posição da câmera em cada imagem (Carrivick et al., 2016). Todos esses requisitos resultam em tarefas que demandam muito tempo e podem atrapalhar a execução do projeto.

Atualmente, as técnicas de fotogrametria digital são comparáveis às técnicas de *lidar* (Assali et al., 2014), sendo que ambas produzem uma nuvem de pontos que é utilizada como dado de entrada para diversas aplicações (Carrivick et al., 2016). A fotogrametria apresenta algumas vantagens em relação ao *lidar* como a capacidade de variação da resolução espacial, o alinhamento automático da nuvem de pontos permitindo uma interpolação de alta qualidade de superfície, a versatilidade para o uso, o baixo custo e a facilidade no manuseio do equipamento que consiste em uma câmera digital que pode ser utilizada manualmente ou acoplada em diversas plataformas (Viana, 2021).

Os avanços recentes da fotogrametria tradicional, impulsionados pela fotogrametria digital, permitiram o desenvolvimento de técnicas de fotogrametria mais flexíveis e robustas, caso da combinação entre os algoritmos SfM (*Structure-from-Motion*) e MVS (*Multi-View Stereo*) que misturam elementos da fotogrametria tradicional com técnicas de visão computacional 3D (Carrivick et al., 2016; Viana, 2021). A popularização da fotografia digital, a maior disponibilidade de imagens e a facilidade de implementação em meio computacional causaram um aumento significativo nas aplicações de algoritmos de SfM-MVS na área da geociências (Viana, 2021).

O algoritmo SfM identifica pontos notáveis (*Keypoints*) em cada imagem do conjunto e utiliza a posição desses pontos para calcular as coordenadas no espaço tridimensional. A repetição desse procedimento para diversos pontos permite a reconstrução tridimensional da cena. Dessa forma, o SfM representa um método rápido, eficiente e de baixo custo para a aquisição de dados topográficos quando comparado as técnicas convencionais como teodolitos e GPS diferencial.

A estrutura típica do processo SfM-MVS é constituída por oito etapas (Fig. 3.13), tal como proposto por Snavely (2008) e Carrivick et al. (2016), e que podem ser descritas resumidamente em três etapas (Viana, 2021): 1- reconhecimento de pontos em comum (*keypoints*) entre as imagens do conjunto e o cálculo da posição de cada ponto; 2- construção de uma nuvem esparsa;

3- geração de uma nuvem densa. As duas primeiras etapas são efetuadas pelo algoritmo SfM enquanto que a última etapa é realizada pela técnica MVS, ou seja, a combinação SfM-MVS representa o processo completo.

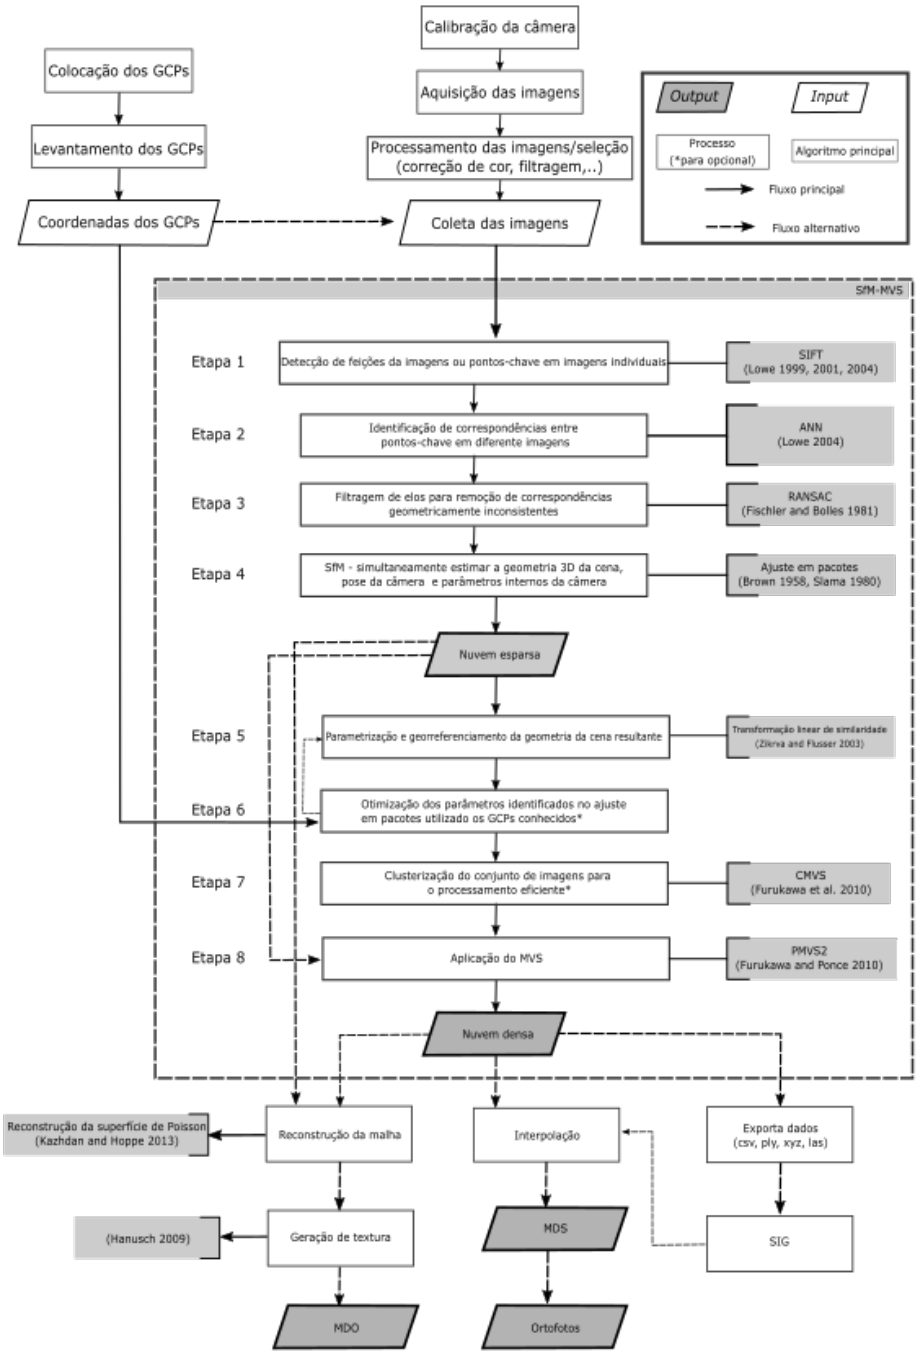

Figura 3.13. Estrutura típica do processo SfM-MVS aplicado em oito etapas como proposto por Snavely (2008) e Carrivick et al. (2016). Modificado de Busarello (2017)

A primeira etapa, que consiste no reconhecimento dos pontos-chaves (*keypoints*), engloba as etapas 1, 2 e 3 do processo descrito por Carrivick et al. (2016). Incialmente são identificados os pontos-chave em diferentes fotografias permitindo a combinação de imagens e posterior reconstrução da cena (Viana, 2021). No entanto, a identificação dos pontos-chave é bastante complexa e diversas técnicas foram desenvolvidas para tentar solucionar esse problema como a combinação estatística da imagem (Lucas e Kanade, 1981), a identificação de feições de borda (Moravec, 1983) ou a utilização de autovalores de produtos suavizados do gradiente (Forstner, 1986; Harris e Stephens, 1988). A solução mais popular é a utilização do sistema de reconhecimento de objeto *Scale-Invariant Feature Transform* (SIFT) que é capaz de identificar os pontos-chave mesmo após mudanças drásticas de suas posições relativas enquanto que o descritor sofre poucas mudanças (Lowe, 1999, 2001, 2004).

O algoritmo SIFT é implementado em quatro etapas que serão descritas resumidamente:

1. **Detecção dos extremos espaciais**. A primeira etapa do processo SIFT consiste na identificação das escalas e dos locais das imagens que podem ser obtidos de diferentes posições de visada. A eficiência dessa etapa se deve a utilização da função de diferença Gaussiana que identifica potenciais pontos de interesse que são invariantes.

2. **Localização dos pontos-chave**. Um modelo detalhado é ajustado para determinar a localização e escala de todos os pontos-chave potenciais identificados na etapa anterior. Uma filtragem é efetuada e os pontos-chave são definidos por medidas de estabilidade.

3. **Atribuição de orientações**. São atribuídas orientações para cada ponto-chave através do gradiente de intensidade local que utiliza a imagem suavizada pela função Gaussiana mais próxima da escala do ponto-chave. Todas as operações seguintes serão efetuadas nas imagens transformadas em invariantes nessa etapa.

4. **Descritor dos pontos-chave**. Cada ponto-chave necessita de um descritor que seja distinto e invariante à mudanças tridimensionais de iluminação e visada. Os descritores são gerados pelo cálculo da magnitude do gradiente e orientação de cada ponto ao redor do ponto-chave. Os descritores são normalmente arranjos 4 x 4 dos histogramas com oito vetores de orientação em cada célula.

O código para implementação do SIFT com orientações está disponível em http://www.cs.ubc.ca/lowe/keypoints/.

Após a identificação dos pontos-chaves são determinadas as correspondências dos pontos entre as diferentes imagens (Viana, 2021). Essas correspondências são efetuadas através da distância euclidiana entre os vizinhos mais próximos para cada ponto-chave contido na base de dados composta pelos pontos identificados anteriormente (Lowe, 2004). No entanto, há uma expressiva dificuldade de implementação desse método, uma vez que a complexidade dos descritores e a

grande quantidade de dados exigem uma intensa procura por vizinhos próximos em um espaço de alta dimensão.

Em seguida, é efetuada uma filtragem dos dados para garantir que apenas as correspondências corretas permaneçam, eliminandos as correspondências geometricamente inconsistentes. O método *random sample consensus* (RANSAC) é o mais rápido, preciso e robusto para o reconhecimento de objetos (Fischler e Bolles, 1981; Choi et al., 2009). O RANSAC permite encontrar as correspondências geometricamente consistentes utilizadas para resolver a matriz fundamental entre pares de imagens (da Silva, 2012). A matriz fundamental é uma matriz 3 x 3 que contém a localização dos pontos-chave corretamente identificados entre duas imagens e pode ser calculada de modo simples pelo algoritmo de oito pontos (Longuet-Higgins, 1981). Calcula-se a matriz fundamental de cada candidato através de diversas iterações que filtram os falsos correspondentes e retornam a matriz com maior número de correspondências. Com os pontos-chave definidos apenas por correspondentes geometricamente consistentes, os vínculos entre cada par de imagens podem ser identificados e organizados em faixas que são constituídas por pelo menos 2 pontos-chave localizados em 3 imagens distintas (Snavely, 2008).

A segunda etapa (etapa 4 de Carrivick et al. (2016)) consiste na aplicação do algoritmo *Structure-from-Motion* que basicamente estima a pose (posição e orientação) da câmera para cada imagem e produz um conjunto de pontos 3D nas imagens codificados como um *track* (Viana, 2021). Furukawa e Hernández (2015) definem o *track* como as coordenadas tridimensionais de um ponto reconstruído e a lista das coordenadas 2D correspondentes em um subconjunto das imagens de entrada. O SfM utiliza os pontos correspondentes da etapa anterior para estimar, simultaneamente, a estrutura 3D da cena, a pose da câmera (parâmetros extrínsecos) e os parâmetros intrínsecos de calibração da câmera que são calculados pela Matriz K (Equação 3.3). A definição dos parâmetros intrínsecos é efetuada a partir do processo de ajustamento de feixes perspectivos denominado de *bundle adjustment*, que estima os parâmetros inciais e produz uma estrutura 3D ideal através do refinamento simultâneo da estrutura e do movimento pela minimização do erro de reprojeção entre os pontos observados e previstos na imagens (Brown, 1958; Slama, 1980; Silveira e Brito, 2005). Por fim, o processo SfM tem como resultado uma nuvem de pontos esparsa e as posições reconstruídas da câmera.

$$K = \begin{bmatrix} a_u & s & u_0 \\ 0 & a_v & v_0 \\ 0 & 0 & 1 \end{bmatrix} \tag{3.3}$$

Matriz **K** de calibração da câmera utilizada para definir os parâmetros intrínsecos. Em que a_u e a_v representam a escala da imagem nas direções x e y, respectivamente; s representa a inclinação; e o ponto principal representado pelo par u_0, v_0 define o local na imagem que intercepta o eixo óptico.

O processo SfM fornece apenas posições relativas da câmera e da geometria da cena, sendo que a nuvem de pontos resultante é gerada em um sistema de coordenadas arbitrário, assim se faz necessário efetuar o georreferenciamento, ou registro, da nuvem de pontos (etapa 5 de Carrivick

et al. (2016)). O gerreferenciamento completo necessita de ao menos três pontos de controle (*Ground Control Points* - GCP) com coordenadas X, Y e Z para efetuar a transformação de similaridade linear de sete parâmetros constituído por três parâmetros de rotação, três parâmetros globais de translação e um parâmetro de escala (Carrivick et al., 2016; Viana, 2021). A obtenção das coordenadas dos pontos de controle pode ser efetuado em campo por GPS diferencial (dGPS) ou com estações totais.

A etapa 6 (Carrivick et al., 2016) é opcional e consiste em utilizar os GCPs pare refinar os valores dos parâmetros obtidos pelo processo SfM, ou seja, com essas novas informações o processo de *bundle adjustment* pode ser novamente executado para otimizar o alinhamento das imagens. Apesar de ser opcional esta etapa deve ser efetuada com bastante cuidado devido aos erros que podem ser gerados pelo posicionamento e abrangência dos GCPs.

Assim como a etapa anterior, a etapa 7 também é opcional, mas é altamente recomendada para projetos com grande quantidade de imagens e deve ser realizada antes da aplicação da técnica MVS. Esta etapa efetua o agrupamento das imagens em subconjuntos pelo processo denominado de *clustering views for MVS* (CMVS) (Fig. 3.14) (Furukawa et al., 2010), o que permite que a reconstrução da nuvem densa seja feita por partes, em cada subconjunto, melhorando o desempenho computacional para esse processo.

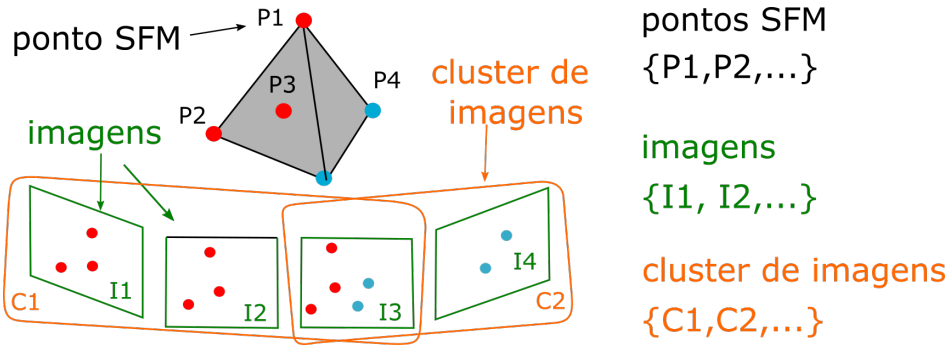

Figura 3.14. Representação do algoritmo CMVS que utiliza as imagens (I), os pontos obtidos pelo processo SfM (P) e a informação de visibilidade desses pontos para gerar conjuntos (*clusters*) de imagens (C). Modificado de Furukawa et al. (2010)

Por fim, a última etapa do processo SfM-MVS consiste na aplicação do algoritmo MVS que é responsável pela reconstrução completa de uma cena 3D a partir de imagens com parâmetros intrínsecos e extrínsecos conhecidos, gerando assim a nuvem de pontos densa. A nuvem de pontos densa apresenta uma maior densidade de pontos, aumento de ao menos duas ordens de magnitude, em relação a nuvem de pontos esparsa, sendo comparável a nuvem de pontos produzida pelo escaneamento a laser terrestre (Viana, 2021). Os métodos MVS baseados em pacotes (*patch-based methods*) são os mais utilizados e com resultados melhores (Lhuillier e Quan, 2005; Ahmadabadian et al., 2013), e são implementados em três etapas (Furukawa e

Ponce, 2010): correspondência de feições, expansão de pacotes e filtragem de correspondências incorretas.

Após a realização do processo SfM-MVS os produtos gerados são as nuvens de pontos esparsa (resultado do SfM) e densa (resultado do MVS) que representam os dados de entrada para as análises com SIG (Sistemas de Informação Geográfica) ou podem ser tratados com *software* específicos, como é o caso do CloudCompare (CloudCompare, 2018). A nuvem de pontos densa é a mais utilizada nos estudos das geociências que devido a maior densidade de pontos possibilita uma melhor resolução espacial final. Normalmente, as nuvens de pontos são interpoladas para a geração de modelos digitais de superfície (MDS) ou modelos digitais de elevação (MDE), bem como podem ser convertidas em malhas poligonais como um TIN (*Triangulated Irregular Network*) (Kazhdan e Hoppe, 2013).

Resumindo, a combinação SfM-MVS transforma um conjunto de imagens bidimensionais em um modelo digital 3D representado por nuvens de pontos que podem ser transformadas em MDE, MDS ou malhas triangulares, além de permitir a geração de ortomosaicos com as imagens (Viana, 2021).

3.3. Artigo 2 - *Deep Learning*

Ji et al. (2020) consideram que a detecção de escorregamentos utilizando dados de sensores remotos deve ser tratada como um problema de processamento de imagens. Nesse sentido, analisam que métodos estatísticos como lógica difusa (Gokceoglu, 2002), regressão logística (Lee, 2005), processos de hierarquia analítica (Kayastha et al., 2013), função de crença evidencial (Althuwaynee et al., 2012), método de combinação linear ponderada (Ayalew et al., 2004), análise estátistica multivariada (Komac, 2006), e operadores algébricos difusos (Lee, 2007) foram desenvolvidos para discriminar regiões com escorregamentos. Recentemente, métodos de *Machine Learning* como SVM (*Support Vector Machine*) (Marjanović et al., 2011), *Random Forest* (RF) (Catani et al., 2013) e redes neurais artificiais (ANN - *Artificial Neural Network*) (Ermini et al., 2005) também têm sido exploradas para a detecção de escorregamentos, sendo os modelos de *Deep Learning*, mais precisamente as redes neurais convolucionais (CNN - *Convolutional Neural Network*) (LeCun e Bengio, 1995), os principais e mais expressivos métodos utilizados na última década (Zhang et al., 2016; Cheng et al., 2017; Maggiori et al., 2017; Yu et al., 2017b; Chen et al., 2018; Li et al., 2018; Ghorbanzadeh et al., 2019; Ma et al., 2019; Diakogiannis et al., 2020; Ji et al., 2020; Li et al., 2021; Wang et al., 2021).

A revolução causada pelos modelos de *Deep Learning* demonstrou que estes são ferramentas bem adaptadas para manusear e classificar automaticamente dados de sensoriamento remoto, sendo sua principal característica a habilidade de aprender e extrair feições em um regime *end-to-end* sem a necessidade de intervenção manual baseada na experiência humana (Interdonato et al., 2019). Os algoritmos de *Deep Learning* obtiveram resultados relevantes em diversas tarefas de

análises de imagens como para a delimitação do uso e ocupação do solo, classificação de cenas, detecção de objetos e segmentação semântica (Chen et al., 2014; Zou et al., 2015; Chen et al., 2015; Romero et al., 2016; Cheng et al., 2016; Marmanis et al., 2016; Yu et al., 2017b; Kussul et al., 2017; Sharma et al., 2017; Vetrivel et al., 2018; Ma et al., 2019). A segmentação semântica de imagens de sensoriamento remoto representa a tarefa de assinalar uma categoria para cada pixel de uma imagem, sendo aplicada em diversas áreas em que a classificação automática de imagens é um processo fundamental, não ficando restrita apenas à área da visão computacional (Matikainen e Karila, 2011; Zhang e Seto, 2011; Lu et al., 2017; Goldblatt et al., 2018; Diakogiannis et al., 2020).

Ding et al. (2016) propuseram uma metodologia em quatro etapas para a identificação automática de escorregamentos com o uso de redes convolucionais (CNN) e algoritmos para detecção de alterações texturais. O modelo proposto obteve resultados espressivos como um *recall* de 100% (todos os escorregamentos foram detectados) e uma precisão de 82%.

Chen et al. (2018) apresentaram uma abordagem automática para detecção de escorregamentos a partir da análise temporal de imagens de sensoriamento remoto. O método proposto é completamente automático com a detecção baseada no conhecimento aprendido pelo modelo das alterações da cobertura do terreno ocasionadas pelos escorregamentos, sem que haja intervenção manual para delimitação das amostras de treinamento. Foram utilizados três grupos de imagens com diferentes resoluções: GF-1 com 8 m; Landsat-8 OLI com 30 m e Formosat-2 com 8 m. O modelo foi capaz de extrair e identificar mais de 70% dos escorregamentos da área de estudo.

Ghorbanzadeh et al. (2019) analisaram e compararam métodos de *Machine Learning* e redes convolucionais para a detecção de escorregamentos a partir de diferentes conjuntos de amostras para treinamento e diferentes parâmetros como o tamanho das janelas dos dados de entrada. As amostras de treinamento foram constituídas por dados espectrais e topográficos. Os melhores resultados foram obtidos pela rede convolucional com amostras constituídas apenas por dados espectrais e com tamanho de janela de 16x16 pixels. Os autores ainda concluem que os resultados da rede convolucional não superam necessariamente os resultados dos métodos de *Machine Learning* a não ser em casos ideais.

Sameen e Pradhan (2019) comparam os resultados de três redes CNN e uma rede ResNet para a detecção de escorregamentos utilizando dados espectrais e espaciais, além de testar dois métodos de fusão de imagens para criar os conjuntos de amostras. A rede ResNet apresentou o melhor desempenho com uma precisão de 90.24%, atingindo esses valores quando utilizou as amostras geradas pelo processo de fusão *feature-level*. Os melhores resultados de todas as redes testadas ocorreram quando foram utilizadas amostras apenas com as informações espectrais. Em nenhum dos experimentos houve melhora nos resultados com a introdução dos dados topográficos neste estudo específico.

Wang et al. (2020) compararam a eficácia de algoritmos de *Machine Learning* e *Deep Learning* na identificação automática de escorregamentos na ilha Lantau em Hong Kong. Ao todo foram

utilizados seis algoritmos de *Machine Learning* e dois de *Deep Learning*. Dados topográficos (hipsometria, declividade, orientação de vertentes, curvaturas, TWI (*Topographic Wetness Index*)), dados geológicos e dados pluviométricos foram os parâmetros utilizados para a classificação dos escorregamentos. A rede DCNN-11 apresentou o melhor resultado com precisão de 92.5%, enquanto que os parâmetros de declividade, orientação de vertentes, curvatura e TWI foram os mais significativos para a identificação dos escorregamentos.

Ji et al. (2020) apresentaram um mecanismo de atenção 3D, o 3D SCAM, para aprimorar os resultados de redes neurais consagradas. O 3D SCAM foi integrado com as redes VGG Net, ResNet, Inception e Xception. A rede ResNet-50 integrada com o 3D SCAM atingiu resultados de precisão, *recall*, acurácia e *F1-score* acima de 95%, superando os resultados de todos os outros modelos testados.

Li et al. (2021) avaliaram nove modelos de *Deep Learning* para a detecção automática de escorregamentos incluindo modelos consagrados na literatura como as redes VGG Net, ResNet, DenseNet e UNet. Também foram utilizados três conjuntos de amostras com quantidades diferentes para treinamento das redes afim de determinar a quantidade ideal de amostras. Todos os modelos testados apresentaram precisão acima dos 80%. As redes VGG Net, ResNet e DenseNet tiveram melhores desempenho com os maiores conjuntos de amostras enquanto que a rede UNet apresentou melhor desempenho com conjuntos menores de amostras. Para os autores, no caso de não haver muitas amostras disponíveis, a utilzação de 1000 amostras para treinamento das redes é suficiente para a detecção automática de escorregamentos.

Yu et al. (2021) propuseram uma metodologia para segmentação semântica com uma rede Matrix SegNet com dois ramos de entrada. O modelo proposto foi utilizado para detectar escorregamentos em quatro áreas distintas da China através de uma análise temporal com imagens retiradas do Google Earth pré e pós eventos. A rede Matrix SegNet proposta apresentou resultados superiores de *F1-score* e IOU (*Intersection Over Union*) que os das redes UNet e SegNet, no entanto os valores de *recall* foram inferiores a 70%.

Em relação ao Brasil, é conhecido até o momento apenas o trabalho de Soares et al. (2022) que efetuou a identificação semi-automática de escorregamentos utilizando a rede U-Net em três áreas distintas do território brasileiro. Imagens RapidEye, dados SRTM e o índice NDVI (*Normalized Difference Vegetation Index*) foram utilizados sozinhos e em conjunto como dados de entrada para a rede neural. Utilizou ferramentas de visão computacional para efetuar o pós processamento das imagens resultantes o que melhorou a precisão do modelo que foi inicialmente prejudicado pela complexidade espectral das áreas. Em alguns casos, a melhora na precisão do modelo com o pós processamento atingiu 17%.

3.3.1. Arquitetura das redes neurais

Os modelos de *Deep Learning* foram desenvolvidos a partir das redes neurais artificiais (ANN) que são inspiradas no processo de aprendizagem dos seres humanos. Consiste na afirmação

biológica que, para os sistemas visuais dos primatas, o cérebro é organizado em uma arquitetura profunda e que a percepção também é representada em múltiplos níveis de abstração (Li et al., 2018; Zhong et al., 2019).

O mecanismo de aprendizagem dos organismos biológicos ocorre através das sinapses (Aggarwal, 2018). A força das sinapses varia de acordo com os estímulos externos e essa variação de força que é responsável pelo processo de aprendizagem. Todo esse processo de aprendizado é simulado pelas redes neurais através de unidades computacionais denominadas de neurônios que são interligados entre si por pesos que representam a força das conexões da sinapses e, portanto, permitem o aprendizado.

As redes neurais representam abstrações de modelos clássicos de *Machine learning*, sendo suas unidades básicas de computação inspiradas em algoritmos tradicionais como regressão logística e método dos mínimos quadrados (Aggarwal, 2018; Skansi, 2018). Apresentam a capacidade de juntar muitas unidades básicas de computação e efetuar o processo de aprendizagem simultânea dos pesos dessas unidades, minimizando o erro de predição. A grande vantagem das redes neurais sobre os métodos tradicionais de *Machine Learning* é a combinação das unidades básicas de computação e o posterior treinamento dos pesos utilizando as dependências dessas unidades. No entanto, o processo de treinamento necessita de uma quantidade suficiente de dados para o aprendizado de um grande número de pesos. No caso da identificação de escorregamentos, tanto os métodos de *Deep Learning* supervisionados como os métodos estatísticos necessitam de amostras rotuladas para o treinamento dos pesos (Ji et al., 2020). As amostras para treinamento são extraídas e rotuladas por especialistas através da interpretação de imagens (Chen et al., 2018), o que caracteriza os métodos como supervisionados. Dessa forma, a elaboração de um conjunto de dados rotulados é fundamental para o sucesso dos modelos de *Deep Learning*, melhorando a precisão do modelo (Soares et al., 2022).

As redes neurais são organizadas em duas ou mais camadas computacionais, assim o termo *Deep Learning* se refere a quantidade de camadas escondidas que uma rede neural possui, ou seja, a profundidade da rede neural (Interdonato et al., 2019). Normalmente, os modelos de *Deep Learning* são compostos por diversas camadas que aprendem as feições de alto nível progressivamente (*feed-forward*) e transformam os dados de entrada (*input*) em dados de saída (*output*) (Litjens et al., 2017). Diferentemente do algoritmo *Perceptron* (Rosenblatt, 1958), que contém apenas uma camada de entrada e uma de saída e que a transmissão dos dados é visível, nas redes neurais multicamadas existem as camadas adicionais intermediárias, entre a camada de entrada e a de saída, que não são visíveis para o usuário e por isso são denominadas de camadas escondidas (Aggarwal, 2018).

A arquitetura da rede neural é definida pelo número de camadas e de nós em cada camada, sendo possível modificá-la de acordo com os objetivos da pesquisa. Dentre as diversas arquiteturas existentes, Aggarwal (2018) destaca as seis principais: 1- Simulação de *Machine Learning* com modelos rasos; 2 - Redes de função de base radial; 3 - Máquina de Boltzman Restrita (*Restricted*

Boltzman Machines); 4 - Redes neurais recorrentes (RNN); 5 - Redes neurais convolucionais (CNN); e 6 - Modelos pré-treinados e engenharia de recursos hierárquica (*Feature Engineering*). Nesse projeto foram utilizadas apenas as redes CNN para o processo de segmentação semântica de imagens.

3.3.2. Redes neurais convolucionais (CNN)

Historicamente, as CNNs representam as redes neurais de *Deep Learning* mais bem sucedidas para estudos como o reconhecimento de imagens, detecção de objetos, processamento de texto e segmentação semântica. A AlexNet (Krizhevsky et al., 2012) representa um marco para as CNNs na área de visão computacional, pois foi pioneira em demonstrar a superioridade das CNNs em relação os métodos tradicionais de *Machine Learning* para a classificação de imagens.

As CNNs são inspiradas no funcionamento do cortex visual dos gatos (Hubel e Wiesel, 1959) e são utilizadas em visão computacional para a classificação de imagens e detecção de objetos. A primeira arquitetura baseada nesse conceito biológico foi a *NeoCognitron* (Fukushima, 1980), posteriormente generalizada para a rede *LeNet-5* (Lecun et al., 1998). As CNNs são construídas para funcionar com dados estruturados em formato de grade, como uma imagem 2D, devido à dependência espacial desse formato de dados que possui as dimensões de largura e altura definidas. No caso das imagens multiespectrais, uma terceira dimensão é adicionada, a profundidade, que representa as bandas RGB e é capaz de capturar as faixas espectrais presentes na imagem.

A característica fundamental das CNNs é o processo de convolução, responsável pela interação entre um conjunto de pesos em formato de grade (normalmente um filtro 3 x 3) e o dado de entrada (imagem) (LeCun e Bengio, 1995). Assim, as CNNs são definidas como redes neurais que utilizam filtros de convolução em pelo menos uma camada, ainda que normalmente esses filtros sejam utilizados em diversas camadas. As camadas de uma CNN apresentam relações espaciais que são herdadas das camadas anteriores, sendo que cada valor da nova camada é obtido a partir da convolução de uma pequena região da camada anterior (Aggarwal, 2018). O processo de convolução é dependente dessas relações espaciais entre camadas.

O funcionamento das CNNs é similar ao de outras redes neurais pré-alimentadas (*feed-forward*), exceto pela organização espacial das relações entre camadas. Basicamente, as CNNs são compostas por três tipos de camadas: convolucionais, que efetuam o processo de convolução e geram as camadas seguintes; as camadas de *pooling* e as camadas de ReLU (*Rectified Linear Units*) (Fig 3.15).

Camadas convolucionais

Nas CNNs, os parâmetros, ou pesos, são organizados em conjuntos de estruturas tridimensionais denominadas de filtros ou *kernels*, que são posicionados pela imagem de entrada da rede e produzem um ponto como resultado da interação do filtro com a imagem (Aggarwal, 2018)

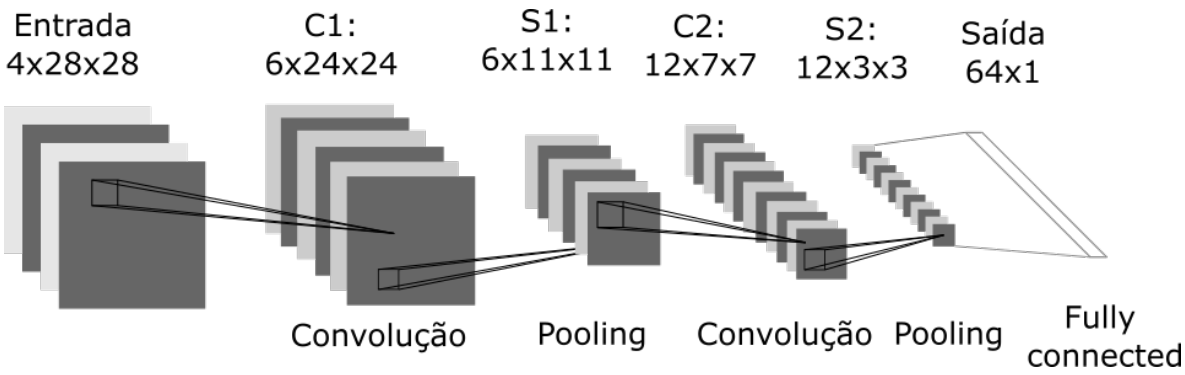

Figura 3.15. Representação de uma CNN. Modificado de Ding et al. (2016)

(Fig 3.16). A quantidade de alinhamentos possíveis entre o filtro e a imagem irá definir as dimensões da camada seguinte.

A profundidade da camada resultante do processo de convolução é definida pela quantidade de filtros que são utilizados na camada convolucional, assim o aumento no número de filtros irá aumentar a profundidade da camada. Cada filtro possui um conjunto independente de pesos que é responsável por identificar padrões espaciais específicos da imagem. A utilização de diversos filtros diferentes permite detectar uma grande variedade de formas combinadas (Aggarwal, 2018).

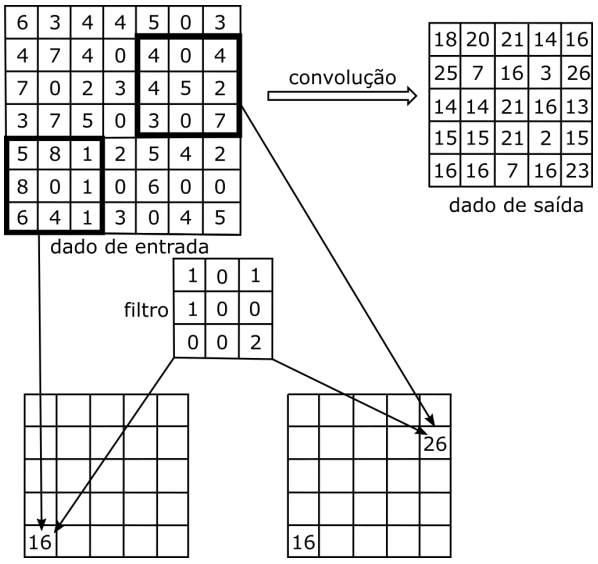

Figura 3.16. Operação de convolução utilizando um filtro 3x3. O filtro percorre todas as posições da imagem de entrada e gera como resultado um ponto para cada posição, reduzindo as dimensões da camada da saída. Modificado de Aggarwal (2018)

O processo de convolução remete ao experimento de Hubel e Wiesel (1959) que estimula pequenas regiões do campo visual para ativar neurônios específicos. No caso das CNNs, o campo visual é representado pelo tamanho do filtro e a ativação é feita pela interação do filtro com

a imagem. Os filtros aplicados nas primeiras camadas da CNN são capazes de detectar formas mais primitivas na imagem enquanto que os filtros aplicados nas camadas posteriores detectam composições mais complexas (Aggarwal, 2018).

Uma propriedade importante do processo de convolução, e que contribui para o sucesso das CNNs, é ser invariante ao movimento de translação, ou seja, uma forma particular da imagem será processada de forma similar pelos filtros convolucionais independentemente da sua orientação e posição (Aggarwal, 2018). A invariância ao movimento de translação permite aumentar o número de dados de treinamento pelo processo de *augmentation* (Ronneberger et al., 2015), considerando que existe uma escassez de dados rotulados para treinamento, principalmente para os estudos de detecção de escorregamentos.

Camadas de ReLU

A ativação efetuda pelas camadas de ReLU nas CNNs ocorre de forma similar à efetuada na redes neurais tradicionais, criando valores limiares das camadas e que serão transmitidos para as camadas seguintes (Aggarwal, 2018). A função ReLu é aplicada após a convolução e antes da camada de *pooling*.

A utilização da função ReLU representa um avanço recente nos estudos envolvendo redes neurais. Krizhevsky et al. (2012) demonstraram que a utilização da função ReLU apresenta uma vantagem expressiva em termos de precisão e velocidade de processamento em relação a outras funções de ativação como sigmóide e hiperbólica. A velocidade de processamento e a precisão estão diretamente relacionadas, de modo que uma maior velocidade de processamento permite utilizar redes neurais mais profundas e com mais tempo de treinamento, aumentando a precisão da rede. Por essas características, a função ReLU substituiu completamente as funções tradicionais no desenvolvimento das CNNs.

Camadas de *pooling*

Por fim, após a camada de convolução e a ativação pela função ReLU, é aplicada a camada de *pooling*. O processo de *pooling* consiste em utilizar uma grade quadrada que percorre a camada resultante da função ReLU e produz uma nova camada com a mesma profundidade, diferentemente dos filtros convolucionais que modificam a profundidade das camadas (Aggarwal, 2018) (Fig 3.17). Comumente é utilizada uma grade quadrada que retorna apenas o valor máximo de cada região da imagem. Esse processo é denominado de *max-pooling*.

É possível definir um valor de passo (*stride*) para a grade de *pooling* que irá percorrer a camada. Esse *stride* permite reduzir drasticamente as dimensões (largura e altura) da camada resultante e, por isso, o processo de *pooling* é utilizado em menor número que as camadas convolucionais e de ReLU (Aggarwal, 2018). Usualmente, a grade quadrada tem o tamanho 2x2 e *stride* de 1, reduzindo o tamanho da camada pela metade. Assim como ocorre com a convolução, as camadas

resultantes do *pooling* são invariantes ao movimento de translação, uma vez que o deslocamento de objetos da imagem não modifica necessariamente o resultado (Aggarwal, 2018).

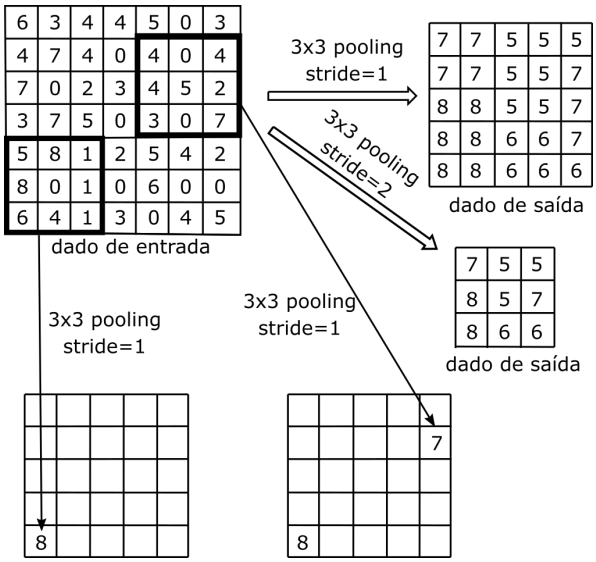

Figura 3.17. Operação de *max-pooling* utilizando um filtro 3x3 com valor de *stride* 1 e 2. O filtro percorre todas as posições da imagem de entrada seguindo *stride* e retorna apenas o maior valor de cada posição. Quanto maior o valor do *stride*, maior será a redução das dimensões da camada de saída. Modificado de Aggarwal (2018)

3.3.3. Retropropagação (*Backpropagation*)

O grande objetivo das redes neurais é encontrar um conjunto de pesos e vieses que permitam a classificação dos nós e isso é possível apenas pelo treinamento dos dados com retropropagação dos erros calculados (*backpropagation*) Skansi (2018). Basicamente, a ideia é calcular o erro gerado pela rede neural durante o processo de classificação e então utilizar esse erro calculado para ajustar os pesos de modo a tornar o erro cada vez menor.

O processo de treinamento das redes neurais se inicia com a inicialização aleatória de pesos e vieses que são multiplicados com os dados de entrada. Em seguida são agrupados e é efetuado um nivelamento entre valores de 0 a 1 pelo processo de regressão logística, isso tudo é repetido mais de uma vez (Skansi, 2018). Ao fim, cada neurônio da camada final estará classificado com um valor entre 0 e 1. Usualmente utiliza-se um limiar de 0.5 para a classificação final, ou seja valores acima de 0.5 são classificados como 1 enquanto que os valores abaixo de 0.5 são classificados como 0. Os erros produzidos pela rede (função E da eq. 3.4) são detectados quando um neurônio é classificado de forma equivocada, por exemplo se ele tiver valor acima do limiar de 0.5 e ser classificado como 0.

O algoritmo de retropropagação é composto por duas fases que ocorrem em sentidos opostos: (1) a fase de ida (*forward phase*) e (2) a fase de retorno (*backward phase*) (Aggarwal, 2018).

$$w_{update} = w_{old} - \eta \nabla E \tag{3.4}$$

Sendo *w* o peso, η a taxa de aprendizagem (*learning rate*) e *E* a função de custo que mensura o desempenho da rede.

1. **Fase de ida**: Os dados de entrada são fornecidos à rede neural para o início do treinamento e desencadeia uma sucessão de cálculos pelas camadas usando o conjunto de pesos inicial. O dado de saída previsto pode ser comparado com o dado de entrada no processo de treinamento e é efetuado o cálculo da derivada da função de perda (*loss function*) do dado de saída. Esta fase estabelece a inicialização para a programação dinâmica e as variáveis intermediárias que serão utilizadas na fase de retorno.

2. **Fase de retorno**: Utiliza a recorrência de programação dinâmica baseada na regra da cadeia multivariada do cálculo diferencial. O grande objetivo dessa fase é aprender o gradiente da função de perda dos diferentes pesos e depois utilizar os gradientes encontrados para atualizar os pesos. Nessa fase o processo de aprendizado se inicia no dado de saída.

O processo de atualização dos nós é repetido até a convergência percorrendo reiteradamente os dados de treinamento em épocas (Aggarwal, 2018). A quantidade de épocas necessárias para o treinamento dos dados não é padrão dependendo do tamanho da rede, quantidade de dados para treinamento, entre outros. Algumas redes podem precisar de milhares de épocas para aprender os pesos dos diferentes nós.

Os trabalhos de Aggarwal (2018) e Skansi (2018) apresentam explicações detalhadas sobre todo o processo de retropropagação, assim como toda a formulação matemática necessária para a devida aplicação desta técnica.

Capítulo 4

Artigo 1

Garcia GPB, Carlos Grohmann H, Viana CD, Gomes EB. Using terrestrial laser scanner and RPA-basedphotogrammetry for surface analysis of a landslide: a comparison. Bulletin of Geodetic Sciences. 28(3): e2022016, 2022.

DOI 10.1590/s1982-21702022000300016

ORIGINAL ARTICLE

Using terrestrial laser scanner and RPA-based-photogrammetry for surface analysis of a landslide: a comparison

Guilherme Pereira Bento Garcia[1] - ORCID: 0000-0003-1209-7842

Carlos Henrique Grohmann[2] - ORCID: 0000-0001-5073-5572

Camila Duelis Viana[3] - ORCID: 0000-0001-7093-0244

Elton Barbosa Gomes[1] - ORCID: 0000-0002-1077-2659

[1]Instituto de Geociências - Universidade de São Paulo, São Paulo - São Paulo, Brasil
E-mails: guilherme.pereira.garcia@usp.br; elton.gomes@alumni.usp.br

[2]Instituto de Energia e Ambiente - Universidade de São Paulo, São Paulo - São Paulo, Brasil
E-mail: camila.viana@usp.br

[3]Prefeitura do Município de São Paulo, Defesa Civil, São Paulo - São Paulo, Brasil
E-mail: guano@usp.br

Received in 06th July 2021.
Accepted in 19th June 2022.

Abstract:

Gravitational mass movements are natural destructive processes that can cause enormous losses. New technologies such as laser scanning and remotely piloted aircrafts (RPA) along with Structure-from-Motion–Multi-View Stereo (SfM-MVS) photogrammetry technique provides an alternative to conventional mapping methods. A hill with a landslide located in the city of Cunha - SP was surveyed by terrestrial laser scanner (TLS) and RPA-based SfM-MVS. SfM-MVS point cloud covers a larger area and point distribution is more homogeneous while TLS points have an uneven distribution. Small distances between point clouds were predominant in the vicinity of the landslide and greater differences only occurred on the scene edges. DEMs (Digital Elevation Model) were generated from both point clouds. The volume of material displaced from the upper part (scarp) of the landslide was 70.05 m^3 for the TLS DEM and 77.15 m^3 for the SfM-MVS while the volume of material accumulated in the lower part (body) of the landslide was 66.85 m^3 and 62.68 m^3 respectively. Slope and roughness were calculated and showed very similar results for TLS and SfM-MVS.

Keywords: LiDAR; SfM-MVS; Landslides; TLS; DEM; Photogrammetry.

How to cite this article: Garcia GPB, Carlos Grohmann H, Viana CD, Gomes EB. Using terrestrial laser scanner and RPA-based-photogrammetry for surface analysis of a landslide: a comparison. *Bulletin of Geodetic Sciences*. 28(3): e2022016, 2022.

This content is licensed under a Creative Commons Attribution 4.0 International License.

1. Introduction

Hill slopes, mainly unvegetated ones, undergo several erosive processes that can compromise their stability. The occurrence of gravitational mass movements in these slopes is usually triggered by natural phenomena such as rains and earthquakes, which when near to highways or inhabited areas can cause enormous economic losses, environmental harm and life loss (Guerra et al. 2007). Therefore, identification and monitoring of such areas are of high importance.

Landslide mapping methods have changed little throughout the years, with the combination of aerial photography and/or multispectral imagery interpretation, and fieldwork verification still being the standard for the majority of studies (McKean and Roering 2004). A limitation of these 'traditional methods' (Metternicht et al. 2005) is its use in rugged terrain with dense vegetation cover, where the true topography is generally unrecognizable on aerial photographs and multispectral images (van den Eeckhaut et al. 2007). In recent years, more precisely the last two decades, new remote sensing techniques were developed providing more accurate and efficient landslide information.

Both terrestrial (TLS) and airborne (ALS) laser scanning applied to landslides mapping offers many advantages over traditional methods such as fieldwork, topographic map digitization and aerial photography (Booth et al. 2009; Burns and Madin 2009; Shan and Toth 2009; Telling et al. 2017; Vosselman and Maas 2010). It allows generation of high resolution three-dimensional topographic models, being a more accurate method and with little human interference in data acquisition (Rowlands et al. 2003). Rapid data processing with repeated scans and high precision highlights morphometric changes in topography which may indicate sliding process, thus facilitating its identification and monitoring.

The combination of Remotely Piloted Aicrafts (RPAs) and Structure-from-Motion–Multi-view Stereo (SfM-MVS) photogrammetry is becoming an increasingly effective tool to gather outcrop data, particularly in the small- to intermediate-scale range and in areas of difficult access (Chesley et al. 2017).Comparisons between state-of-art lidar data and photogrammetry in landslide studies are recurrent (Carey et al. 2019; Chang et al. 2020; Hung et al. 2019; Mokhtar et al. 2019; Pellicani et al. 2019; Tsunetaka et al. 2020; Yu et al. 2017). Both TLS and RPA-based SfM-MVS have been used for landslide monitoring, mapping and 3D surface reconstruction (Burns et al. 2010; Giordan et al. 2015; Glenn et al. 2006; Godone et al. 2020; Gupta and Shukla 2018; Karantanellis et al. 2019; Rossi et al. 2018; van den Eeckhaut et al. 2011; Xu et al. 2020; Yeh and Chuang 2020). These methods show great advantages over conventional, costly and time consuming ones but also have their own cons which can compromise the entire project.

In this work we compare raw and interpolated point clouds generated by TLS and RPA-based SfM-MVS for the same landslide and evaluate the accuracy of each method by performing a surface analysis. This work is an expansion from Garcia et al. (2019) that only compared the point clouds obtained from TLS and SfM-MVS for the same study area.

1.1. Study area

The surveyed area is located in the City of Cunha (São Paulo State, southeastern Brazil), at the roadside of km 40 of the Paulo Virgínio Highway (SP-171), and has approximately 15.000 m^2 in area (Fig. 1). The landslide is around 14.5 m long and around 10 m wide, totaling an area of 145 m^2. The hillslope has a height amplitude of around 50 m, and is facing S and SW, which makes it more exposed to orographic rainfall from the coast. The area presents sparse vegetation, mainly constituted by tall grass, and soil is partially exposed.

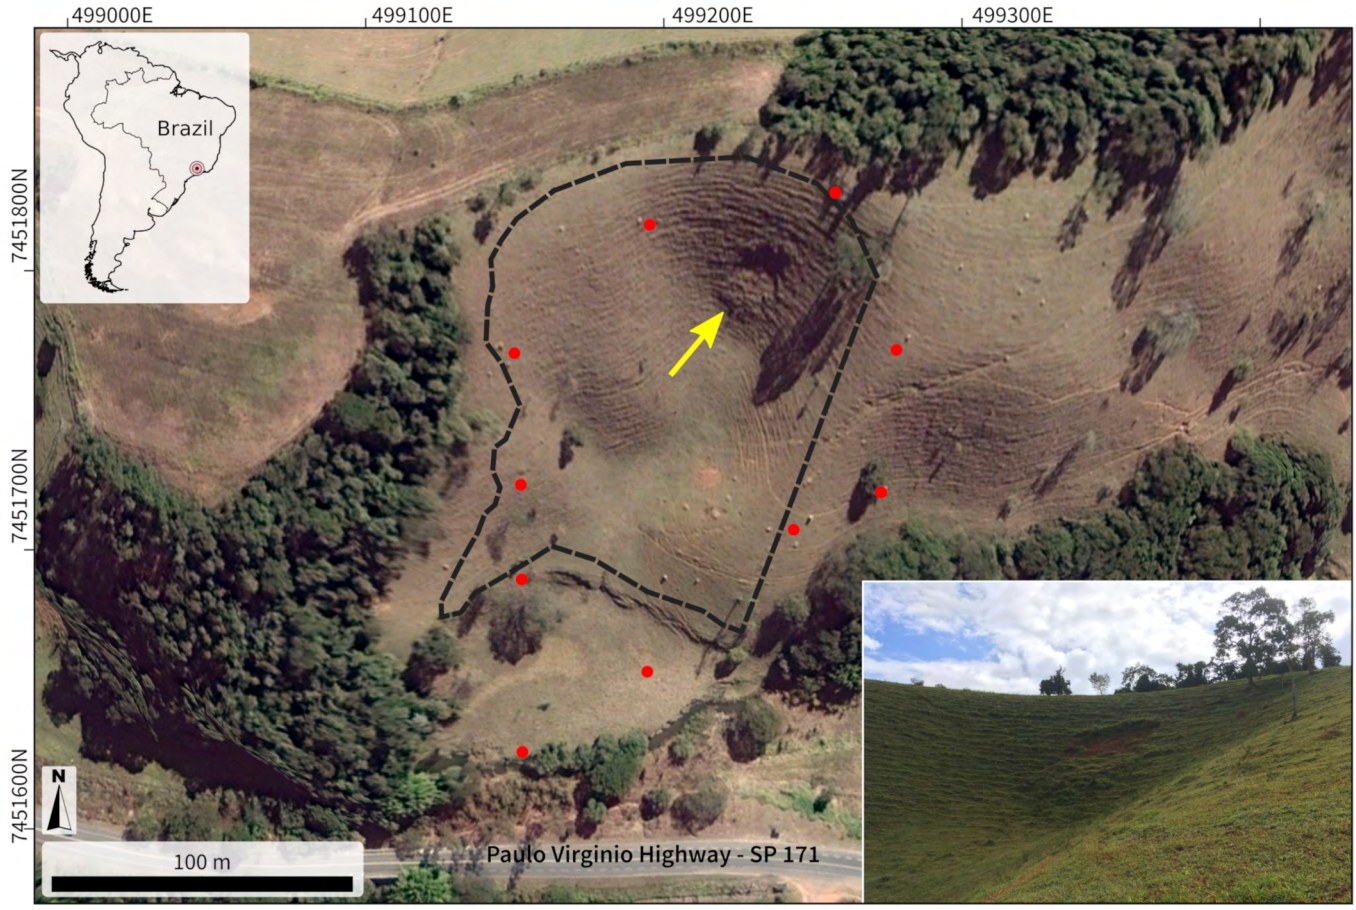

Figure 1: Location map of the Cunha City (upper left) and of the study area . Field view of the landslide (right). The dashed line represents the survey boundary,the arrow indicates the area affected by the landslide and the red dots indicates the GCP (Ground Control Points) used for georeferencig. Satellite imagery Digital Globe, powered by Google. UTM coordinates, zone 23 (South), WGS84.

The study area is within the Serra do Mar mountain range, more precisely in the Atlantic Highlands (Planalto Atlantico) Province (Almeida 1964; Ponçano et al. 1981) which is mainly characterized by a rough terrain with high elevation and slopes. The elevations are usually higher than 800 m a.s.l. with local amplitudes up to 300 m, and the slopes are often higher than 20 degrees. These features along with a rainfall pattern higher than 250 mm/month in the wet season, especially in the summer, make this area very susceptible to mass movements, mainly deep-seated and shallow landslides (Perrota et al. 2005).

The municipality of Cunha suffered from several occurrences of mass movements during the summer of 2010-2011, mainly shallow landslides similar to the landslide selected in this study, which was triggered during this period. It was an atypical intense rainfall season that also caused losses in nearby cities within Serra do Mar (Netto et al. 2011).

The geological setting is comprised basically by precambrian basement rocks, mainly metamorphic rocks such as migmatites and gneiss that belongs to the Capivari Complex (Perrota et al. 2005), which occurs as narrow and elongated bands limited by shear zones (Heilbron et al. 2004).

2. Methods

2.1. Lidar – Terrestrial Laser Scanner

Light Detection and Ranging (lidar) emerge as the main technology and benchmark for landslide studies that uses High-Resolution Digital Elevation Models (HR-DEM) and can be performed in three ways: terrestrial laser scanning (TLS), airborne laser scanning (ALS) and satellite-based laser scanning (Jaboyedoff et al. 2012). Some differences are related to range method, resolution, amount of points gathered and multiple returns (Shan and Toth 2009; Vosselman and Maas 2010).

Terrestrial laser Scanner (TLS) data collection and processing workflows are flexible procedures that are largely controlled by the information desired from the scene being imaged, the physical characteristics of the scene and the surrounding environment (Telling et al. 2017). The selection of the equipment, scan positions, scan registration, georeferencing and point resolution are key elements for the TLS data collection (Shan and Toth 2009; Vosselman and Maas 2010).

The data collection occur with the scanner normally mounted on a tripod and held fixed for the duration of measurements for each position. A single lidar scan collects a large amount of 3D data, several million point measurements, each with x, y and z coordinates and intensity value, which produces a point cloud. To create a point cloud for the entire scene it is necessary to merge all the point clouds from each scan position.

The TLS field survey was performed on May 06, 2018 from 11 stations allocated around the landslide area to generate the TLS point cloud, using a FARO Focus^S 150 LiDAR equipment. The TLS survey took almost all day due to weather conditions and difficult access to positioning/levelling the equipment around the landslide. For georeferencing and point cloud registration, 10 printed targets were evenly distributed around the landslide and surveyed by irradiation using a total station. Coordinates were collected in field by a Spectra Precision 60 (SP60) geodetic GNSS. Post-processing in SPoffice software was used to obtain precise coordinates..

2.2. RPA-Based SFM-MVS

SfM-MVS is a workflow employing multiple algorithms developed from 3D computer vision, traditional photogrammetry and conventional survey techniques (Carrivick et al. 2016).

The typical workflow is composed by several steps, each one with specific processing procedures and algorithms, from the detection of image features or keypoints in the photographs to the application of MVS algorithms and point cloud generation (Carrivick et al. 2016). These are standard procedures for 3D scene reconstruction from image sets and are adopted for all SfM-MVS approaches.

The image acquisition was made using a DJI Phantom 4 Pro RPA. The onboard digital camera has an 1” CMOS 20MP sensor, with FOV of 84˚ and 8.8 mm focal distance (24 mm at 35 mm equivalent). The RPA autonomous mission was programmed with the MapPilot App (Drones Made Easy 2017) which allows the flight height to be set as a constant value above a reference DEM (SRTM), resulting in more consistent pixel size values across the imaged area, even in situations of high relief displacement.Two missions were flown on May 06, 2018 to cover the entire hillside, both at 40 m above the terrain, with lateral and frontal overlap of 80% between photos and camera positioned at nadir. For georeferencing and point cloud registration, the same targets and coordinates used for the TLS point cloud were applied. No check points were used in the SfM-MVS process. Each mission lasted around 20 min, the entire RPA survey took about 1 hour.

In this work, we used Agisoft Photoscan Professional version 1.4.5 (Agisoft 2018) software for the 3D reconstruction. The SfM-MVS reconstruction process was set to align images with 'High' accuracy, camera optimization with 0.005 m marker accuracy, 'High' quality and 'aggressive' depth filtering.

The use of the RPA SfM-MVS high resolution data for topographic studies in Brazil is an alternative to expensive and poorly available lidar data. As the landscapes susceptible to landslides in Brazil are predominantly covered by vegetation such as grass and bushes, it is worthwhile to evaluate the potential uses of RPA data compared to state-of-art lidar data in such terrain conditions.

2.3. Geomorphometry

For the morphological analysis, both TLS and SfM-MVS point clouds were used to generate DEMs and terrain derivatives. The TLS point cloud was filtered to remove above-surface points that do not represent the terrain, such as tree trunks and termite mounds. The Cloth Simulation Filter (CSF) (Zhang et al. 2016) from CloudCompare software was used to remove points 50 cm above the surface.

Both point clouds were imported in GRASS GIS (GRASS Development Team 2019; Neteler et al. 2012) with the r.in.lidar module, which imports lidar data in LAS format and creates a raster based on univariate statistics of the data. Intermediate rasters were created from the minimum value of LiDAR points within 10 cm cells. These rasters were then interpolated using bilinear splines (r.resamp.bspline – (Brovelli et al. 2004)), to fill any void areas and to produce DEMs with spatial resolutions of 10 cm, 50 cm, 1 m and 2 m, which were used to evaluate the capacity of each surface in resolving fine to medium scale landslide features.

The landslide analysis is comprised by a morphometric analysis and an estimation of the volume of displaced material. Morphometric parameters commonly used in landslide analysis were computed, namely slope and surface roughness (Glenn et al. 2006; Grohmann et al. 2011; McKean and Roering 2004), and used for comparison of TLS and SfM-MVS results.

The volume estimation can be performed by subtracting DEMs created before and after the landslide event. The 'before' DEM is usually generated by the interpolation of topographic maps prior the landslide (Du and Teng 2007); however, there are no high-resolution topographic data available for the study area before 2011 to enable the creation of a DEM representing the terrain before the landslide.

Thus, the surface was manually reconstructed based on a contour map with 50 cm interval derived from the current 10 cm spatial resolution DEM: the contour lines deformed by the landslide were reconstructed following the intact contour lines from surrounding areas (Fig. 2). This reconstructed contour map was interpolated with bilinear splines to generate a new DEM with 50 cm spatial resolution, representing the surface before the landslide. The manual reconstruction of the surface was performed only for the 10 cm TLS interpolated DEM and the reconstructed surface DEM was used as the reference data for the volume estimation.

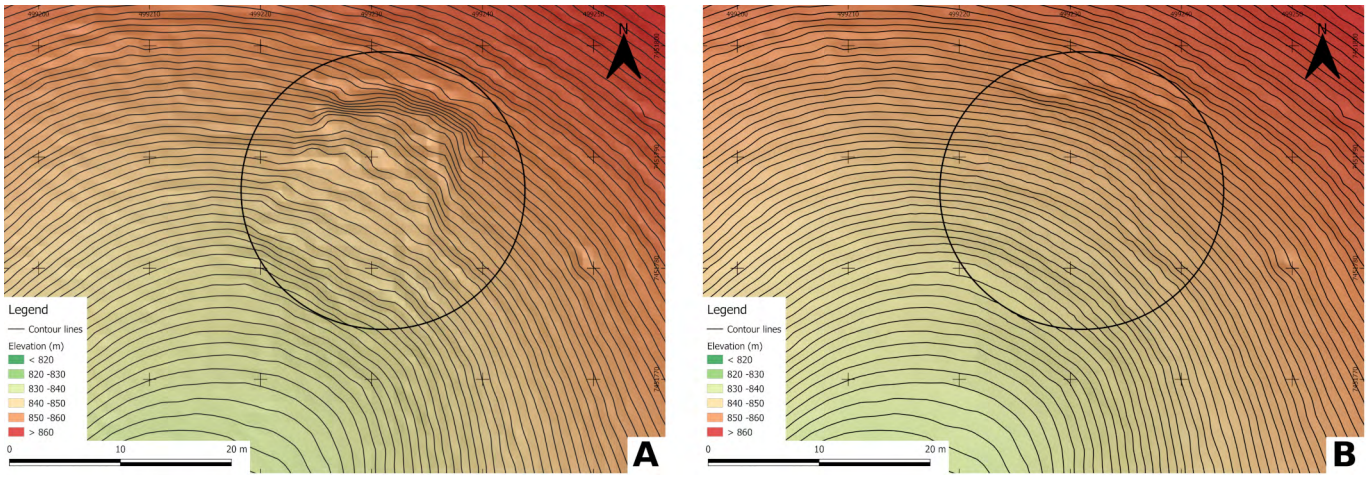

Figure 2: Reconstruction of topography for volume calculation. A) Contour lines deformed by the slide event; B) Contour lines reconstruction. Example from the TLS point cloud DEM with 50 cm spatial resolution and contour lines with 50 cm interval.

Surface roughness measures the variability of the topographic surface at a given scale (e.g., Berti et al. 2013; Grohmann et al. 2011) and it has been widely used in landslide studies. There are several algorithms to compute surface roughness with the Terrain Ruggdness Index (TRI) (Riley et al. 1999) and the standard deviation of elevation (Glenn et al. 2006; McKean and Roering 2004) being the most popular. Grohmann et al. (2011) computed and compared different surface roughness algorithms in various scales and with different sizes of moving windows; the standard deviation of slope was the most accurate surface roughness algorithm in detecting fine scale/regional relief and showed the best performance at a variety of scales.

In this study, surface roughness was calculated as the standard deviation of slope for both TLS and SfM-MVS DEMs with four different spatial resolutions (10 cm, 50 cm, 1 m and 2 m) with a 3x3 window size. This combination was meant to determine which scale is more accurate for the landslide analysis.

The generation of DEMs, contour maps and terrain derivatives were all performed using the Free and Open Source Software QGIS (QGIS Development Team 2019) grass and

3. Results and discussion

3.1. Point cloud comparison

FARO SCENE was used for processing the raw TLS data and create a single point cloud from the individual scans. All markers were automatically recognized by FARO SCENE. The resulting TLS point cloud has 128,513,743 points (Fig. 3A).

The TLS point cloud, despite having a larger number of points, does not represent the entire area equally. The point distribution is denser near the scans positions, gradually decreasing with distance. Voids are common, mainly further from the slide area where less information was captured. Even the landslide area has some occlusions which would require more scans from different viewpoints to fill them.

The SfM-MVS point cloud (Fig. 3B) was generated with Agisoft Photoscan (Agisoft 2018) using 315 images. The complete SfM-MVS workflow, using the 'high quality' settings of Photoscan, produced a dense cloud with

93,245,315 points. Only 7 markers were identified in the image set, as the vertical position of some markers – specially one at a tree trunk that was covered by its crown on the images – makes it difficult to locate them in the vertical RPA images.

The SfM-MVS point cloud has a more uniform appearance, as points are homogeneously distributed and there are no significant voids. The slope is entirely comprised within the point cloud and the landslide can be clearly identified. This point cloud has approximately 35 million points less than the TLS point cloud but covers a larger area.

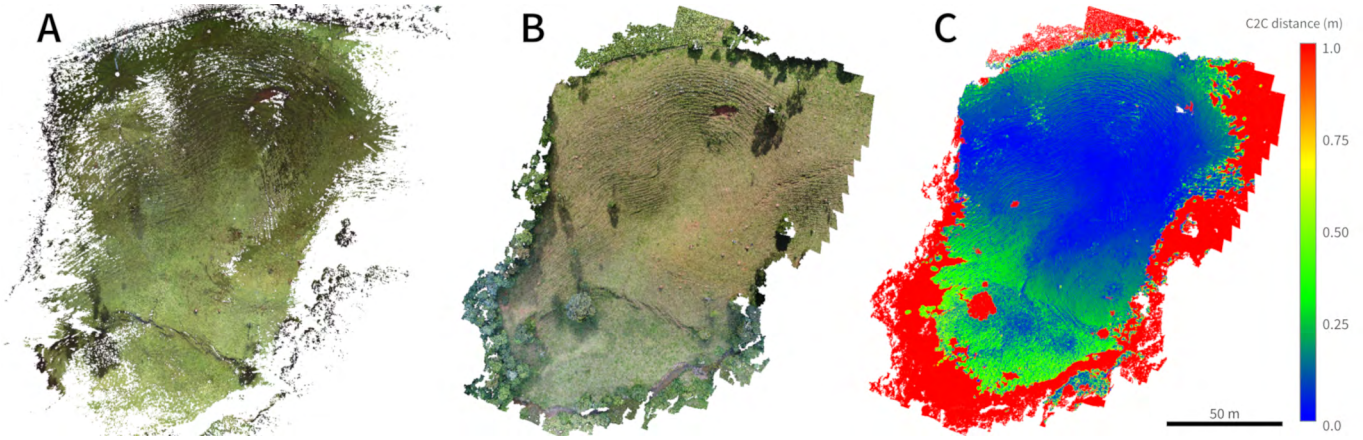

Figure 3: A) TLS point cloud; B) SfM-MVS point cloud; C) Cloud-to-Cloud distance with 1 m threshold using the TLS as the reference cloud.

The difference between the two clouds was computed using the "Cloud-to-Cloud distance" tool in CloudCompare (Fig. 3C). Distances less than 50 cm are predominant in the entire area overlapped by the point clouds with distances less than 15 cm comprising the landslide area. The TLS did not acquired points far from the scan positions, concentrating them within the slope, while the RPA captured a wider area and the SfM-MVS method generated a homogeneous point cloud. Larger distances (>1 m) between the point clouds occur at the borders of the surveyed area, probably beyond TLS scan range or due the presence of ground obstacles blocking the laser beam path. However, points within the slope are very similar even though the TLS point cloud being denser than the SfM-MVS one.

Small differences could be related to georeferencing, since the RPA images do not capture vertical targets precisely, like the TLS does from a ground position. Fig.4 shows an example of how the RPA imaged a vertical marker. This marker was placed over a termite mound and was in a near vertical position, hindering the correct determination of its center Some markers were not visible in the RPA images, affecting the distribution of ground control information and thus affecting georeferencing.

Absence of vegetation also contributes to this smalls differences. RPA images are in visible spectral range (RGB) so it has no penetration through leaves. Densely vegetated areas hide markers in the RPA images, which increases georeferencing errors and point cloud differences.

Both TLS and SfM-MVS point clouds are suitable for 3D surface modelling in this case. Point clouds differences are minimal in the target area, despite the 35 million points variation between them. Larger differences occur only outside the study area and have less influence in the final models. Absence of vegetation allows generation of digital models from both point clouds without significant information loss.

Figure 4: RPA image of a printed target, placed in a near-vertical position over a termite mound.

3.2. Morphological analysis

The landslide was divided in two parts for the volume estimation computation: 1- the upper part (scarp of the landslide) from where the material was removed and has the soil exposed; and, 2- the lower part (body of the landslide) where the material accumulated and its covered by grass and some bushes. The volume was estimated for each part separately and for both TLS and RPA SfM-MVS 10 cm DEMs using the 10 cm TLS DEM with the surface reconstructed as the reference.

Prior the volume calculation it was expected some differences in the results from the upper and lower part of the landslide due to erosion process or the swell factor that happened over the years since the landslide occurrence in 2011 (Dewitte and Demoulin 2005; Pedrazzini et al. 2010; Schulz et al. 2018).

The volume estimation from the TLS DEM with 10 cm resolution showed that 70.05 m^3 of material was displaced from the upper part and 66.85 m^3 of material accumulated in the lower part. For the SfM-MVS DEM with 10 cm spatial resolution the volume estimation was 77.15 m^3 of material displaced from the upper part and 62.68 m^3 of material accumulated in the lower part.

The differences between the TLS and RPA SfM-MVS volumes estimation for the upper (TLS: 70.05 m^3; RPA: 77.15 m^3; Δ = 7.10 m^3) and lower part (TLS: 66.85 m3; RPA: 62.68 m^3; Δ = 4.17 m^3) was probably related to points density, RPA camera position in the image acquisition process and the presence of vegetation.

The main volume differences occur in the upper part (Δ = 7.10 m^3) and must be related to point density or RPA camera position. Point cloud comparison in section 3.1 showed that even though the TLS point cloud has around 35 millions points more than the SfM-MVS point cloud, the TLS point distribution is denser near the scans positions, and it presented occlusions in the landslide area, which may affect the interpolation process and contribute to volume difference in the upper part. However, the nearly vertical position of the landslide scarp makes the RPA image acquisition process difficult with the camera in the nadir position because it does not have a clear view of the whole scarp. The interpolation process for the SfM-MVS point cloud probably smooths the surface in the scarp which creates differences from the TLS DEM. Figure 5 shows three profiles in the upper part of the landslide comparing TLS and SfM-MVS DEMs.

The volume difference in the lower part (Δ = 4.15 m^3) is more feasible and is probably related to the presence of undergrowth or minor errors caused by the georeferencig process discussed in section 3.1. The lower part is covered

with vegetation, mainly tall grass with dozens of centimeters, that prevented the RPA from obtaining bare earth points and was filtered in the TLS point cloud but remain intact in the SfM-MVS data. This grass made it impossible to reconstruct the topography and create a DTM from the RPA SfM-MVS point cloud, a DSM was generated instead which is not accurate as lidar-derived DTM in vegetated areas (Niethammer et al. 2010; Yu et al. 2017).

Although the comparison between the TLS DTM and the SfM-MVS DSM is not ideal, it allows to evaluate major differences between them and whether they have any degree of similarities in morphological analysis.

Also it was possible to estimate the weight of the displaced material. The study area is comprised with red-yellow oxisol which its density vary from 1.0 to 1.4 g/cm³ (Ferreira et al. 2015; Spera et al. 2002; Torres and Saraiva 1999). For the weight calculation an average density of 1.2 g/cm³ was considered. The landslide dimensions were 14.5 m long and 10 m wide with a total area of 145 m². The volume of material displaced from the upper part was estimated in 70.05 m³ from the TLS data and the scarp has 2 m height. The estimation weight of the displaced material was about 84 tons.

The study area has great slope variability with the values at the N and W portions usually higher than 35 degrees and the S and E portions up to 20 - 25 degrees. The landslide occurred in the NE portion of the catchment area which corresponds to the highest slope values, above 45 degrees.

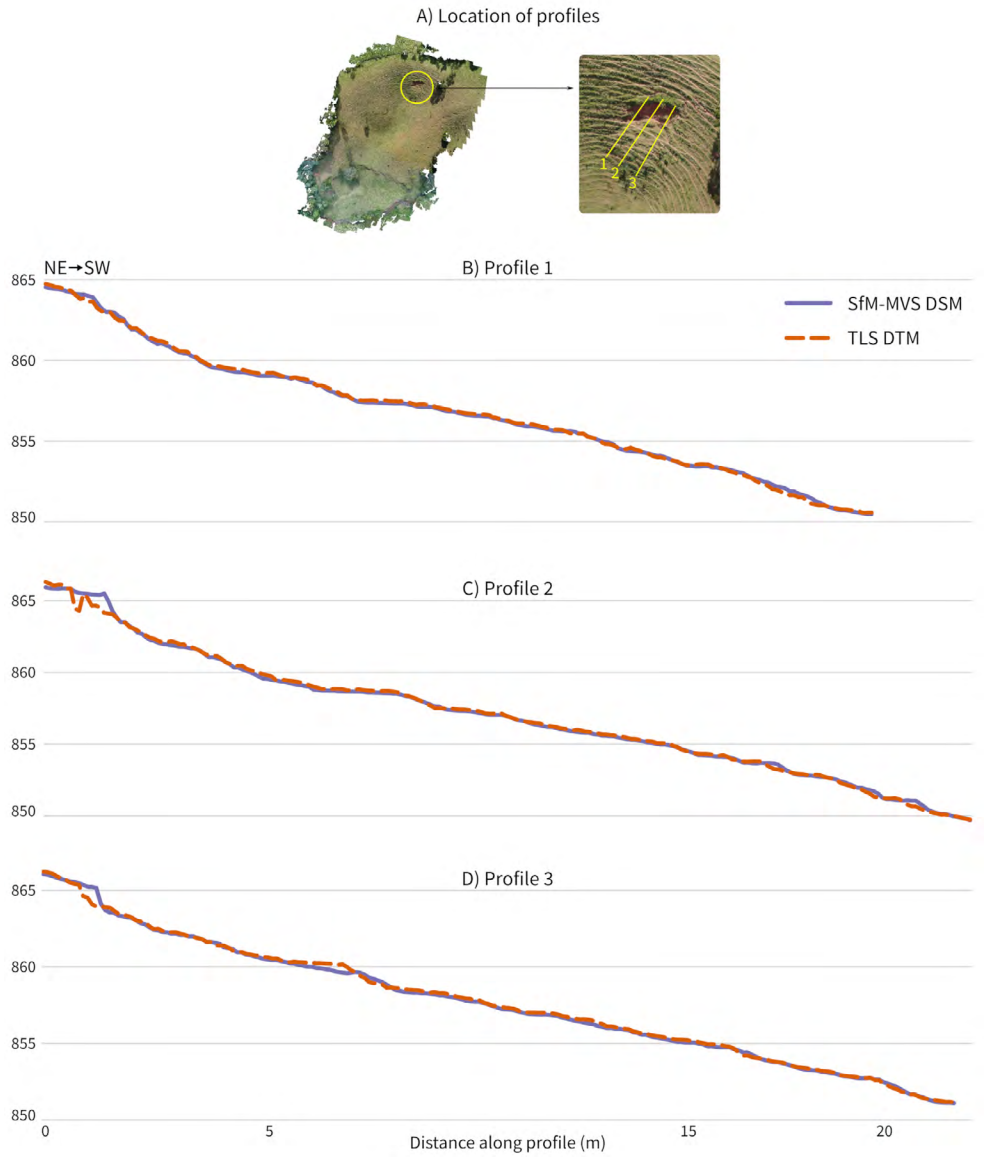

Figure 5: Landslide profiles comparing TLS and SfM-MVS point clouds.

The slope maps with spatial resolutions of 50 cm are the more accurate in delineating the landslide, both scarp and body were detected (Figs. 6B,6F). The 10 cm resolution slope maps enhance non-terrain features such as termite mounds and tree trunks that are common in the study area and the visual interpretation is impaired by the salt-and-pepper effect (Figs. 6A,6E). The maps with 1 m and 2 m spatial resolution (Figs. 6C,D,G,H) are more widespread but are also able to correctly detect the landslide, mainly the scarp that is clearly distinguishable from the surroundings. The non-terrain features are more clearly observed in the SfM-MVS slope maps, probably because the SfM-MVS point cloud could not be filtered before the DEM generation.

Both TLS and SfM-MVS DEMs showed very similar slope results from all the spatial resolutions used. This high similarity was expected once both TLS and SfM-MVS point clouds had minimal differences in the landslide area.

The surface roughness maps (Figs. 6I-P) were classified in five categories: very low (flat terrain), low, medium, high and very high (rugged terrain). The roughness categories were defined from the histogram of each spatial resolution DEM, thus TLS and SfM-MVS DEM with the same spatial resolution had the same classification once the histograms were very similar with near maximum values. The histogram shows how many standard deviations occur at each pixel, the higher the standard deviation the rougher is the terrain. The scarp of the landslide is the most prominent portion detected, the body and toe of the landslide cannot be clearly distinguished due the small size of the landslide but the area beneath the landslide is much smoother than the adjacent areas.

The highest values of surface roughness occur in the landslide scarp and surrounding areas which indicates that these areas were already rougher before the landslide. The predominant rugged parts of the hillslope are probably related to cattle passage, that forms step-like features, which are easily recognized in the fine scale surface roughness maps, mainly in the 10 cm spatial resolution with 3x3 window (Figs. 6I,M). These cattle passage features enhance landslide susceptibility in the hillslope by preventing vegetation growth and exposing the soil, which contributes to erosion process (Fiori and Carmignani 2015).

The surface roughness maps derived from TLS and SfM-MVS DEMs showed some similarities to each other in all combinations of spatial resolution except in the 1 m spatial resolution DEM where there are huge differences between TLS and SfM-MVS maps (Figs. 6K,O). Overall, TLS roughness maps are more accurate in delineating the landslide than SfM-MVS results, with cleaner and more homogeneous images.

For the study area, the fine scale maps (10 cm and 50 cm) are very detailed and comprised features such as termite mounds, which are not part of the terrain and can lead to misinterpretations. The 50 cm spatial resolution roughness maps from both TLS and SfM-MVS (Figs. 6J,N) are the best in detecting the scarp of the landslide with less distortion caused by other terrain features, but did not detected the body of the landslide clearly and the SfM-MVS map had more disturbance from adjacent areas.

Roughness maps with coarser spatial resolutions (1 m and 2 m) are very affected by terrain features other than the landslide parts and had a more erroneous classification. The landslide area can be detected with these maps, mainly in the 1 m TLS map, but it is not possible to determine the boundaries of the landslide parts with certainty which leads to misinterpretation. The 2 m spatial resolution maps presents some pattern of the rougher parts that are clearly connected to the landslide and may indicate preferred paths of the erosion processes. The maps with 1 m spatial resolution are very different while TLS map classification is in accordance with the other maps detecting the rougher parts in a similar way, the SfM-MVS map is highly heterogeneous and chaotic with no patterns and similarities to others roughness map.

4. Conclusions

A hill slope with a minor landslide (14.5 m long and 10 m wide), mainly covered by grass and with partially exposed soil was scanned by a TLS and photographed by an RPA, generating two point clouds. Vegetation absence

is critical for comparing both methods since the RPA images cannot register information below the canopy. The final TLS point cloud contains 128,513,743 points while RPA , generated by SfM-MVS, 93,245,315 points, a difference of about 35 million points. The two point clouds were very similar in the top and center slope areas but presented large differences at the borders of the scene.

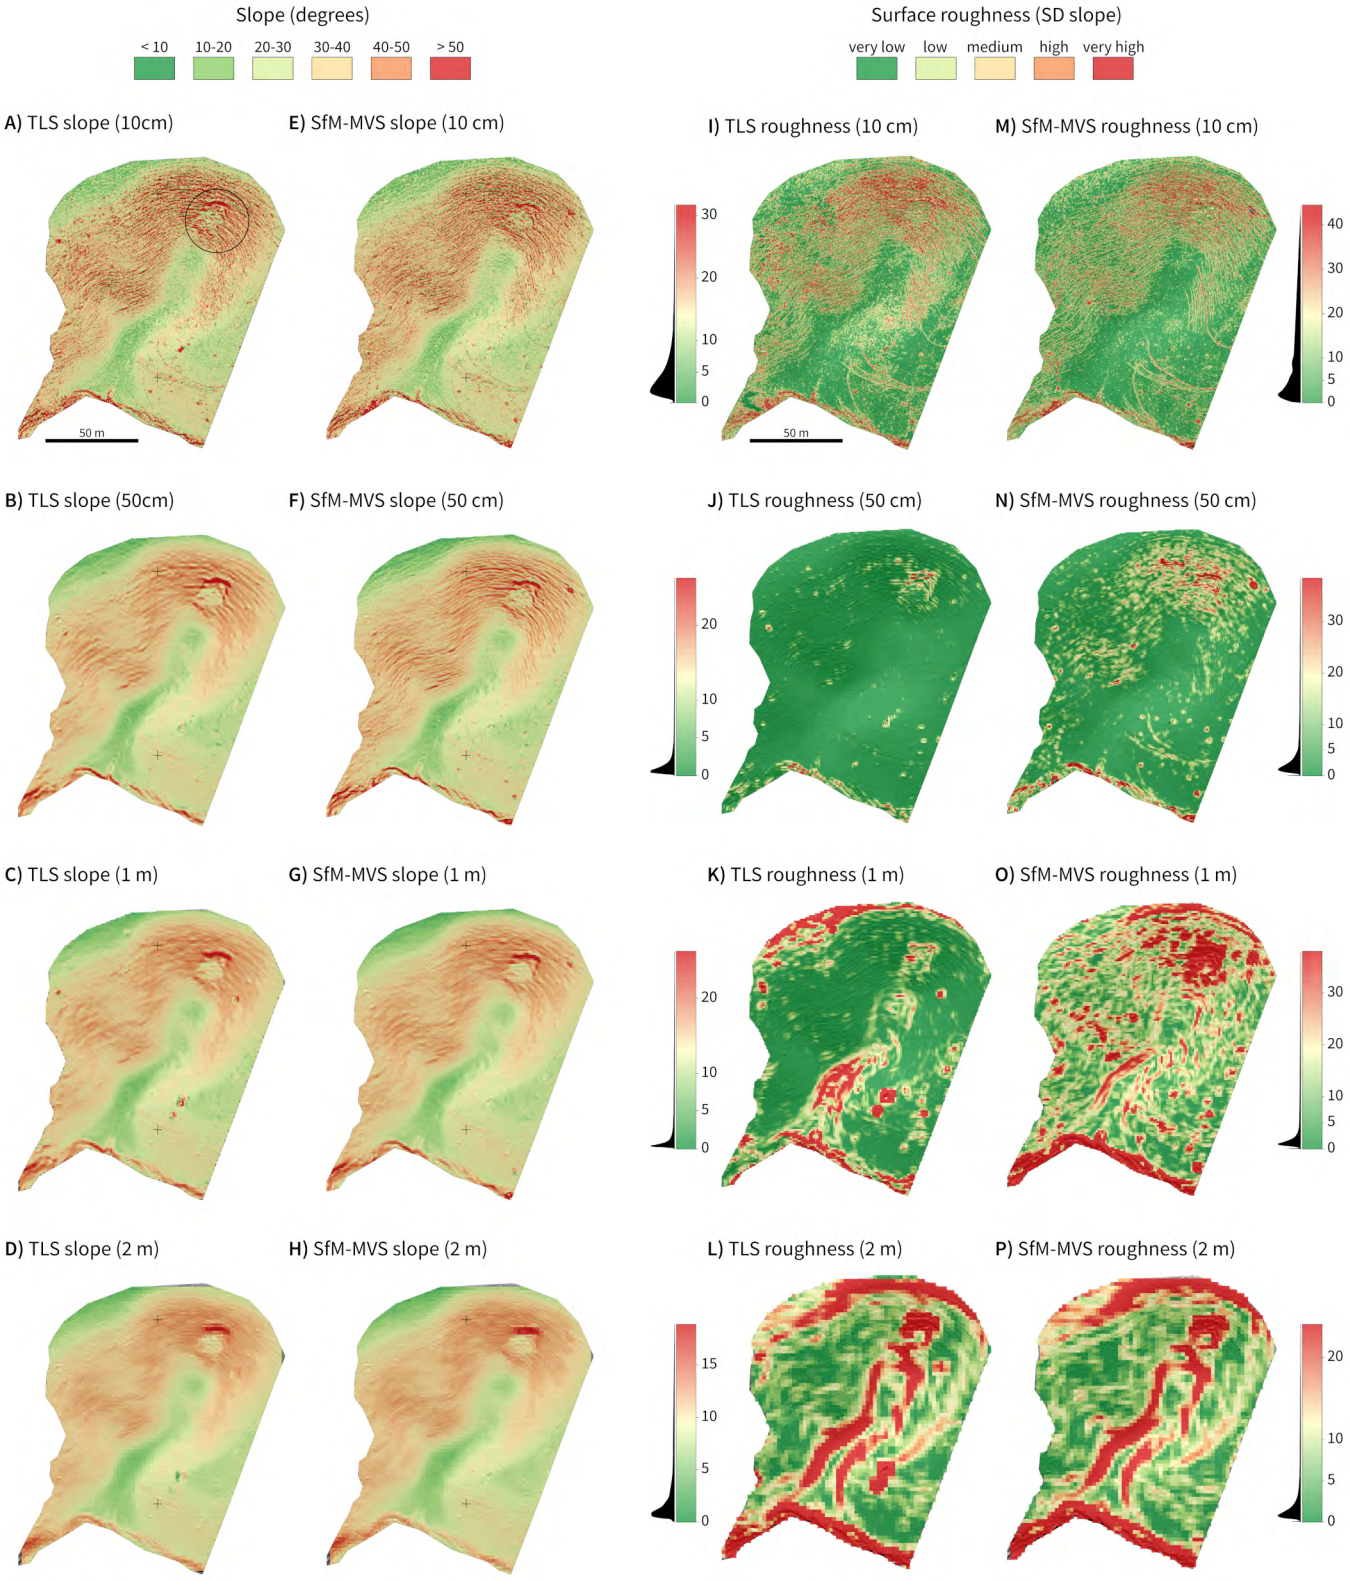

Figure 6: A-D) TLS slope; E-H) SfM-MVS slope; I-L) TLS surface roughness; M-P) SfM-MVS surface roughness.

TLS technical limitations (such as laser beam path obstruction) can explain the major differences in the borders of the scene, while georeferencing problems probably causes small differences within the slope. The RPA images were taken at nadir angle, so ground control points markers in a near-vertical position (such as in tree trunks or termite mounds) are not precisely identified, and this can lead to these minor errors in the point clouds.

The TLS DEM estimation of material displaced from the upper part was of 70.05 m^3 and the estimation of material accumulated in the lower part was 66.85 m^3, while the SfM-MVS DEM estimation for material displacement and accumulation was 77.15 m^3 and 62.68 m^3 respectively. The differences in the volume estimation results between TLS and RPA SfM-MVS DEMs can be addressed to point density, RPA camera position and presence of vegetation, instead of accuracy of the methods.

Both TLS and SfM-MVS slope maps accurately identified the landslide in all the spatial resolutions and classified the whole area in a similar way. Some differences occurred in the min-max slope values but this must be related to georeferencing problems and points acquisition process. The SfM-MVS point cloud was not filtered like the TLS point cloud, so points off the terrain such as tree trunks and termite mounds must be present in the DEM and influenced the slope calculation.

TLS and SfM-MVS roughness maps had similarities but presented important differences. In both cases 50 cm spatial resolution maps were the more accurate correctly delineating the landslide area from surroundings. Fine scale maps (10 cm and 50 cm) enhances features not related to the terrain and enables visualization of cattle passage features that contributes to the increase of surface erosion processes which leads to greater landslide susceptibility.

For this specific terrain conditions, with no vegetation cover and few view obstacles, both point clouds are suitable for DEM generation and other surface modelling to identify landslides. The concentration of TLS points in the landslide area should provide more detailed DEMs than SfM-MVS, but for local and intermediate scales both methods can be applied with minimal information loss.

The choice of which method is a better fit a project will be determined by budget, mapping scale and characteristics of the study area. Other studies comparing TLS, ALS and SfM-MVS in different environments should provide distinct results. Potential advantages of RPA-based SfM-MVS include smaller cost both in terms of equipment and processing time, although its efficacy is limited by the presence of vegetation.

ACKNOWLEDGMENT

This study was supported by the Sao Paulo Research Foundation (FAPESP) grants #2016/06628-0, #2019/26568-0 and by Brazil's National Council of Scientific and Technological Development, CNPq grants #311209/2021-1, #423481/2018-5, #304413/2018-6 to C.H.G. This study was financed in part by CAPES Brasil - Finance Code 001 through a PhD scholarship to G.P.B.G. This work acknowledges the services provided by the OpenTopography Facility with support from the National Science Foundation under NSF Award Numbers 1557484, 1557319, and 1557330. Acknowledgments are extended to the Editor-in-Chief, the Associate Editor, and the anonymous reviewers for their criticism and suggestions, which helped to improve this paper.

AUTHOR´S CONTRIBUTION

Conceptualization, G.P.B.G, C.H.G., C.D.V., E.G.; methodology, C.H.G., G.P.B.G, C.D.V.; formal analysis, G.P.B.G, C.D.V., E.G; writing--original draft preparation, G.P.B.G, C.H.G.; writing--review and editing, G.P.B.G, C.H.G., C.D.V.; visualization, C.H.G., G.P.B.G, E.G.; supervision, C.H.G.; project administration, C.H.G.; funding acquisition, C.H.G.

REFERENCES

Agisoft. (2018). AgiSoft Photoscan Professional Software.

Almeida, F. F. M. (1964). Fundamentos geológicos do relevo paulista. *Boletim do IGG*, *41*, 169–263.

Berti, M., Corsini, A., & Daehne, A. (2013). Comparative analysis of surface roughness algorithms for the identification of active landslides. *Geomorphology*, *182*, 1–18. https://doi.org/10.1016/j.geomorph.2012.10.022

Booth, A. M., Roering, J. J., & Perron, J. T. (2009). Automated landslide mapping using spectral analysis and high-resolution topographic data: Puget Sound lowlands, Washington, and Portland Hills, Oregon. *Geomorphology*, *109*(3–4), 132–147. https://doi.org/10.1016/j.geomorph.2009.02.027

Brovelli, M. A., Cannata, M., & Longoni, U. M. (2004). LIDAR Data Filtering and DTM Interpolation Within GRASS. *Transactions in GIS*, *8*(2), 155–174. https://doi.org/10.1111/j.1467-9671.2004.00173.x

Burns, W. J., Coe, J. A., Kaya, B. S., & Ma, L. (2010). Analysis of elevation changes detected from multi-temporal LiDAR surveys in forested landslide terrain in western Oregon. *Environmental and Engineering Geoscience*, *16*(4), 315–341. https://doi.org/10.2113/gseegeosci.16.4.315

Burns, W. J., & Madin, I. P. (2009). *Protocol for Inventory Mapping of Landslide Deposits from Light Detection and Ranging (lidar) Imagery* (No. 42). Portland, OR.

Carey, J. A., Pinter, N., Pickering, A. J., Prentice, C. S., & Delong, S. B. (2019). Analysis of landslide kinematics using multi-temporal unmanned aerial vehicle imagery, La Honda, California. *Environmental & Engineering Geoscience*, *25*(4), 301–317.

Carrivick, J. L., Smith, M. W., & Quincey, D. J. (2016). *Structure from motion in the geosciences* (1st ed.). Oxford, UK: John Wiley & Sons, Ltd.

Chang, K.-J., Tseng, C.-W., Tseng, C.-M., Liao, T.-C., & Yang, C.-J. (2020). Application of Unmanned Aerial Vehicle (UAV)-Acquired Topography for Quantifying Typhoon-Driven Landslide Volume and Its Potential Topographic Impact on Rivers in Mountainous Catchments. *Applied Sciences*, *10*(17), 1–16. https://doi.org/10.3390/app10176102

Chesley, J. T., Leier, A. L., White, S., & Torres, R. (2017). Using unmanned aerial vehicles and structure-from-motion photogrammetry to characterize sedimentary outcrops: An example from the Morrison Formation, Utah, USA. *Sedimentary Geology*, *354*, 1–8. https://doi.org/10.1016/j.sedgeo.2017.03.013

Dewitte, O., & Demoulin, A. (2005). Morphometry and kinematics of landslides inferred from precise DTMs in West Belgium. *Natural Hazards and Earth System Sciences*, *5*(2), 259–265. https://doi.org/10.5194/nhess-5-259-2005

Drones Made Easy. (2017). MapPilot . San Diego, CA.

Du, J. C., & Teng, H. C. (2007). 3D laser scanning and GPS technology for landslide earthwork volume estimation. *Automation in Construction*, *16*(5), 657–663. https://doi.org/10.1016/j.autcon.2006.11.002

Ferreira, R. M. F., Ferreira, V. M., Filho, J. T., & Ralisch, R. (2015). Qualidade Físico-Hídrica De Cambissolo Sob Pastagem Extensiva. In *XXI Simposio Brasileiro de Recursos Hidricos* (pp. 1–8). Brasilia, DF.

Fiori, A. P., & Carmignani, L. (2015). *Fundamentos de mecânica dos solos e das rochas: aplicações na estabilidade de taludes*. (A. P. Chaves, C. G. Silva, D. C. C. K. Kowaltowski, J. G. Tundisi, L. E. Sánchez, P. Helene, et al., Eds.) (3rd ed.). São Paulo: Oficina dos Textos.

Garcia, G. P. B., Gomes, E. B., Viana, C. D., & Grohmann, C. H. (2019). Comparing Terrestrial Laser Scanner and UAV-based Photogrammetry to Generate a Landslide DEM . In *Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto* (pp. 415–418). Santos: INPE.

Giordan, D., Manconi, A., Tannant, D. D., & Allasia, P. (2015). UAV: low-cost remote sensing for hig-resolution investigation of landslides. In *IEEE International Geoscience and Remote Sensing Symposium* (pp. 5344–5347).

Glenn, N. F., Streutker, D. R., Chadwick, D. J., Thackray, G. D., & Dorsch, S. J. (2006). Analysis of LiDAR-derived topographic information for characterizing and differentiating landslide morphology and activity. *Geomorphology*, *73*(1–2), 131–148. https://doi.org/10.1016/j.geomorph.2005.07.006

Godone, D., Allasia, P., Borrelli, L., & Gulla, G. (2020). UAV and structure from motion approach to monitor the Maierato landslide evolution. *Remote Sensing*, *12*(6), 1039–1057. https://doi.org/https://doi.org/10.3390/rs12061039

GRASS Development Team. (2019). Geographic Resources Analysis Support System (GRASS GIS) Software. Open Source Geospatial Foundation.

Grohmann, C. H., Smith, M. J., & Riccomini, C. (2011). Multiscale Analysis of Topographic Surface Roughness in the Midland Valley, Scotland. *IEEE Transactions on Geoscience and Remote Sensing*, *49*(4), 1200–1213. https://doi.org/10.1109/TGRS.2010.2053546

Guerra, A. J. T., Gonçalves, L. F. H., & Lopes, P. B. M. (2007). Evolução Histórico-Geográfica Da Ocupação Desordenada E Movimentos De Massa No Município De Petrópolis, Nas Últimas Décadas. *Revista Brasileira de Geomorfologia*, *8*(1), 35–43. https://doi.org/10.20502/rbg.v8i1.84

Gupta, S. K., & Shukla, D. P. (2018). Application of drone for landslide mapping, dimension estimation and its 3D reconstruction. *Journal of the Indian Society of Remote Sensing*, *46*(6), 903–914. https://doi.org/https://doi.org/10.1007/s12524-017-0727-1

Heilbron, M., Pedrosa-Soares, A. C., Campos Neto, M. C., Silva, L. C., Trouw, R. A. J., & Janasi, W. A. (2004). Província Mantiqueira. In V. Mantesso-Neto, A. Bartorelli, C. D. R. Carneiro, & B. B. Brito-Neves (Eds.), *Geologia do Continente Sul-Americano: Evolução da obra de Fernando Flávio Marques de Almeida* (1st ed., pp. 203–236). São Paulo, Brasil: Beca.

Hung, C. L. J., Tseng, C. W., Huang, M. J., Tseng, C. M., & Chang, K. J. (2019). Multi-temporal high-resolution landslide monitoring based on UAS photogrammetry and UAS lidar geoinformation. In *Geoinformation for Disaster Management* (pp. 157–160). Prague, Czech Republic. https://doi.org/https://doi.org/10.5194/isprs-archives-XLII-3-W8-157-2019

Jaboyedoff, M., Oppikofer, T., Abellán, A., Derron, M. H., Loye, A., Metzger, R., & Pedrazzini, A. (2012). Use of LIDAR in landslide investigations: A review. *Natural Hazards*, *61*(1), 5–28. https://doi.org/10.1007/s11069-010-9634-2

Karantanellis, E., Marinos, V., & Vassilakis, E. (2019). 3D hazard analysis and object-based characterization of landslide motion mechanism using UAV imagery. In *ISPRS Geospatial Week* (pp. 425–430). Enschede, The Netherlands. https://doi.org/https://doi.org/10.5194/isprs-archives-XLII-2-W13-425-2019

McKean, J., & Roering, J. (2004). Objective landslide detection and surface morphology mapping using high-resolution airborne laser altimetry. *Geomorphology*, *57*(3–4), 331–351. https://doi.org/10.1016/S0169-555X(03)00164-8

Metternicht, G., Hurni, L., & Gogu, R. (2005). Remote sensing of landslides: An analysis of the potential contribution to geo-spatial systems for hazard assessment in mountainous environments. *Remote Sensing of Environment*, *98*(2–3), 284–303. https://doi.org/10.1016/j.rse.2005.08.004

Mokhtar, N. M., Darwin, N., Ariff, M. F. M., Majid, Z., & Idris, K. M. (2019). The capabilities of unmanned aerial vehicle for slope classification. In *6th International Conference on Geomatics and Geospatial Technology* (pp. 451–459). Kuala Lumpur, Malaysia. https://doi.org/https://doi.org/10.5194/isprs-archives-XLII-4-W16-451-2019

Neteler, M., Bowman, M. H., Landa, M., & Metz, M. (2012). GRASS GIS: A multi-purpose open source GIS. *Environmental Modelling & Software*, *31*, 124–130. https://doi.org/10.1016/j.envsoft.2011.11.014

Netto, A. L. C., Sato, A. M., Avelar, A. S., Vianna, L. G. G., Araújo, I. S., Ferreira, D. L. C., et al. (2011). January 2011: the extreme landslide disaster in Brazil. In *Proceedings of the 2nd Worl landslide Forum* (p. 6). https://doi.org/10.1007/978-3-642-31319-6_51

Niethammer, U., Rothmund, S., James, M. R., Travelletti, J., & Joswig, M. (2010). UAV-Based Remote Sensing of Landslides. In *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* (pp. 496–501).

Pedrazzini, A., Abellán, A., Oppikofer, T., Ambrosi, C., Spataro, A., & Jaboyedoff, M. (2010). Retrogressive landslide monitoring by TLS: precursory displacements and final collapse. Case study at Val Canaria (Ticino, Switzerland). *Geophysical Research Abstracts, EGU General Assembly 2010*, *12*. http://meetingorganizer.copernicus.org/EGU2010/EGU2010-12160.pdf

Pellicani, R., Argentiero, I., Manzari, P., Spilotro, G., Mazzo, C., Ermini, R., & Apollonio, C. (2019). UAV and airborne lidar data for interpreting kinematic evolution of landslide movements: the case study of the Montescaglioso landslide (Southern Italy). *Geosciences*, *9*(6), 1–18. https://doi.org/https://doi.org/10.3390/geosciences9060248

Perrota, M. M., Salvador, E. D., Lopes, R. C., D'Agostino, L. Z., Peruffo, N., Gomes, S. D., et al. (2005). *Mapa Geológico do Estado de São Paulo*. São Paulo, Brasil.

Ponçano, V., Carneiro, C., Bistrichi, C., Almeida, F., & Prandini, F. (1981). *Mapa geomorfológico do Estado de São Paulo, escala 1:1.000.000* (1183rd ed., Vol. 2). São Paulo: IPT.

QGIS Development Team. (2019). QGIS Geographic Information System . Open source Geospatial Foundation.

Riley, S. J., DeGloria, S. D., & Elliot, R. (1999). A terrain ruggedness index that quantifies topographic heterogeneity. *Journal of Soil Science* , *5*, 23–27.

Rossi, G., Tanteri, L., Tofani, V., Vannocci, P., Moretti, S., & Casagli, N. (2018). Multitemporal UAV surveys for landslide mapping and characterization. *Landslides*, *15*, 1045–1052. https://doi.org/DOI 10.1007/s10346-018-0978-0

Rowlands, K. A., Jones, L. D., & Whitworth, M. (2003). Landslide laser scanning: a new look at an old problem. *Quarterly Journal of Engineering Geology and Hydrogeology*, *36*(2), 155–157.

Schulz, W. H., Smith, J. B., Wang, G., Jiang, Y., & Roering, J. J. (2018). Clayey Landslide Initiation and Acceleration Strongly Modulated by Soil Swelling. *Geophysical Research Letters*, *45*(4), 1888–1896. https://doi.org/10.1002/2017GL076807

Shan, J., & Toth, C. K. (2009). *Topographic Laser Ranging and Scanning: Principles and Processing*. (J. Shan & C. K. Toth, Eds.) (1st ed.). Boca Raton, FL: Taylor & Francis Group LLC.

Spera, S. T., Reatto, A., Martins, É. de S., Farias, M. F. R., Silva, Â. V., Júnior, O. A. de C., & Guimarães, R. F. (2002). *Solos e Aptidão Agricola das Terras da Área de Proteção Ambiental de cafuringa, Distrito federal*. Planaltina, DF.

Telling, J., Lyda, A., Hartzell, P., & Glennie, C. (2017). Review of Earth science research using terrestrial laser scanning. *Earth-Science Reviews*, *169*, 35–68. https://doi.org/10.1016/j.earscirev.2017.04.007

Torres, E., & Saraiva, O. F. (1999). *Camadas de impedimento mecânico do solo em sistemas agrícolas com a soja*. *Embrapa Soja, Circular Técnica*. Londrina.

Tsunetaka, H., Hotta, N., Hayakawa, Y. S., & Imaizumi, F. (2020). Spatial accuracy assessment of unmanned aerial vehicle-based structures from motion multi-view stereo photogrammetry for geomorphic observations in initiation zones of debris flows, Ohya landslide, Japan. *Progress in Earth and Planetary Science*, *7*(24), 1–14. https://doi.org/10.1186/s40645-020-00336-0

van den Eeckhaut, M., Poesen, J., Gullentops, F., Vandekerckhove, L., & Hervás, J. (2011). Regional mapping and characterisation of old landslides in hilly regions using LiDAR-based imagery in Southern Flanders. *Quaternary Research*, *75*(3), 721–733. https://doi.org/10.1016/j.yqres.2011.02.006

van den Eeckhaut, M., Poesen, J., Verstraeten, G., Vanacker, V., Nyssen, J., Moeyersons, J., et al. (2007). Use of LIDAR-derived images form mapping old landslides under forest. *Earth Surface Processes and Landforms*, *32*, 754–769. https://doi.org/10.1002/esp

Vosselman, G., & Maas, H.-G. (2010). *Airborne and Terrestrial Laser Scanning*. (G. Vosselman & H.-G. Maas, Eds.) *Current* (1st ed.). Dunbeath, Scotland, UK: Whittles Publishing. https://doi.org/10.1080/17538947.2011.553487

Xu, Q., Li, W., Ju, Y., Dong, X., & Peng, D. (2020). Multitemporal UAV-based photogrammetry for landslide detection and monitoring in a large area: a case study in the Heifangtai terrace in the Loess Plateau of China. *Journal of Mountain Science*, *14*, 1826–1839. https://doi.org/https://doi.org/10.1007/s11629-020-6064-9

Yeh, T. W., & Chuang, R. Y. (2020). Morphological analysis of landslides in extreme topography by UAS-SfM: data acquistion, 3D models and chenge detection. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, *XLIII-B5-2020*, 173–178. https://doi.org/10.5194/isprs-archives-XLIII-B5-2020-173-2020

Yu, M., Huang, Y., Zhou, J., & Mao, L. (2017). Modeling of landslide topography based on micro-unmanned aerial vehicle photography and structure-from-motion. *Environmental Earth Sciences*, *76*(520), 1–9. https://doi.org/10.1007/s12665-017-6860-x

Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., & Yan, G. (2016). An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. *Remote Sensing*, *8*(6), 1–22. https://doi.org/https://doi.org/10.3390/rs8060501

ADDITIONAL INFORMATION

Data Availability

The point cloud datasets used in this study are available via the OpenTopography Facility (https://opentopography.org/). The following datasets were used: OpenTopography ID OTDS.082019.32723.1 (SfM-MVS), OTDS.082019.32723.2 (TLS).

Erratum

First page, in the Abstract, where it reads:

(...) New technologies such as laser scanning and remotely piloted aircrafts (RPA) along with photogrammetry technique Structure-from-Motion–Multi-View Stereo (SfM-MVS) photogrammetry technique provides an alternative to conventional mapping methods (…)

Should read:

(...) New technologies such as laser scanning and remotely piloted aircrafts (RPA) along with Structure-from-Motion–Multi-View Stereo (SfM-MVS) photogrammetry technique provides an alternative to conventional mapping methods (…)

First page, in the Abstract where it reads:

(…) DEMs were generated from both point clouds (…)

Should read:

(…) DEMs (Digital Elevation Model) were generated from both point clouds (…)

Page 6, where it reads:

The generation of DEMs, contour maps and terrain derivatives were all performed using the Free and Open Source Software QGIS (QGIS Development Team 2019) grass and

Should read:

The generation of DEMs, contour maps and terrain derivatives were all performed using the Free and Open Source Software QGIS (QGIS Development Team 2019).

Page 8, where it reads:

(…) The interpolation process for the SfM-MVS point cloud probably smooths the surface if the scarp which creates differences from the TLS DEM. Figure 5 shows three profiles in the upper part of the landslide comparing TLS and SfM-MVS DEMs.

Should read:

(…) The interpolation process for the SfM-MVS point cloud probably smooths the surface in the scarp which creates differences from the TLS DEM. Figure 5 shows three profiles in the upper part of the landslide comparing TLS and SfM-MVS point clouds.

Page 12, where it reads:

The choice of which method is a better fit a project will be determined by budget (…)

Should read:

The choice of which method is a better fit to the project will be determined by budget (…)

Bulletin of Geodetic Sciences, 28(4): e2022019, 2022.

Capítulo 5

Artigo 2

G. P. B. Garcia, L. P. Soares, M. Espadoto & C. H. Grohmann (2023) Relict landslide detection using deep-learning architectures for image segmentation in rainforest areas: a new framework, International Journal of Remote Sensing, 44:7, 2168-2195

International Journal of Remote Sensing

ISSN: (Print) (Online) Journal homepage: https://www.tandfonline.com/loi/tres20

Relict landslide detection using deep-learning architectures for image segmentation in rainforest areas: a new framework

G. P. B. Garcia, L. P. Soares, M. Espadoto & C. H. Grohmann

To cite this article: G. P. B. Garcia, L. P. Soares, M. Espadoto & C. H. Grohmann (2023) Relict landslide detection using deep-learning architectures for image segmentation in rainforest areas: a new framework, International Journal of Remote Sensing, 44:7, 2168-2195, DOI: 10.1080/01431161.2023.2197130

To link to this article: https://doi.org/10.1080/01431161.2023.2197130

View supplementary material

Published online: 18 Apr 2023.

Submit your article to this journal

Article views: 113

View related articles

View Crossmark data

Full Terms & Conditions of access and use can be found at
https://www.tandfonline.com/action/journalInformation?journalCode=tres20

INTERNATIONAL JOURNAL OF REMOTE SENSING
2023, VOL. 44, NO. 7, 2168–2195
https://doi.org/10.1080/01431161.2023.2197130

Taylor & Francis
Taylor & Francis Group

Check for updates

Relict landslide detection using deep-learning architectures for image segmentation in rainforest areas: a new framework

G. P. B. Garcia [a], L. P. Soares [a], M. Espadoto [b] and C. H. Grohmann [c]

[a]Instituto de Geociências, Universidade de São Paulo, São Paulo, Brasil; [b]Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, Brasil; [c]Instituto de Energia e Ambiente, Universidade de São Paulo, São Paulo, Brasil

ABSTRACT

Landslides are destructive and recurrent natural disasters on steep slopes and represent a risk to lives and properties. Knowledge of relict landslides' location is vital to understand their mechanisms, update inventory maps and improve risk assessment. However, relict landslide mapping is complex in tropical regions covered with rainforest vegetation. A new CNN framework is proposed for semi-automatic detection of relict landslides, which uses a dataset generated by a k-means clustering algorithm and has a pre-training step. The weights computed in the pre-training are used to fine-tune the CNN training process. A comparison between the proposed and the standard framework is performed using CBERS-04A WPM images. Three CNNs for semantic segmentation are used (Unet, FPN and Linknet) with two augmented datasets. A total of 42 combinations of CNNs are tested. Values of precision and recall were very similar between the combinations tested. Recall was higher than 75% for every combination, but precision values were usually smaller than 20%. False positives (FP) samples were addressed as the cause for these low precision values. Predictions of the proposed framework were more accurate and correctly detected more landslides. This work demonstrates that there are limitations for detecting relict landslides in areas covered with rainforest, mainly related to similarities between the spectral response of pastures and deforested areas with *Gleichenella* sp. ferns, commonly used as an indicator of landslide scars.

- Relict landslide detection has limitations in rainforest environments
- The proposed framework for CNN semantic segmentation proved to be useful for relict landslide detection
- Land cover features spectral characteristics, and input data technical specificities are crucial to the accuracy of CNN models
- No optimal combination of parameters has been identified
- No CNN proved to be superior

ARTICLE HISTORY
Received 5 August 2022
Accepted 24 March 2023

KEYWORDS
landslides; deep learning; CNN; remote sensing; CBERS-04A; k means

CONTACT C. H. Grohmann guano@usp.br Instituto de Energia e Ambiente, Universidade de São Paulo, Av. Prof. Luciano Gualberto, 1289, São Paulo, SP 05508-010, Brasil

Supplemental data for this article can be accessed online at https://doi.org/10.1080/01431161.2023.2197130

© 2023 Informa UK Limited, trading as Taylor & Francis Group

1. Introduction

Landslides are destructive and recurrent natural disasters that represent a risk to lives and properties when near urban areas (Metternicht, Hurni, and Gogu 2005; Kasai et al. 2009; Netto et al. 2011; Jebur, Pradhan, and Tehrany 2014; Nohani et al. 2019). They are responsible for expressive human and economic losses worldwide, costing millions of dollars each year (Tominaga, Santoro, and Do Amaral 2009; Netto et al. 2011). The Sendai framework for disaster risk reduction 2015–2030 UNISDR (2015) stated that natural hazards affected more than 25 million people and caused economic losses up to US$ 1.3 trillion between 2008 and 2012. Landslides occur on steep slopes and are essential agents in landscape evolution by promoting changes through successive events that shape the hillsides (Wolle 1988; Summerfield 1991; Tominaga, Santoro, and Do Amaral 2009; Guzzetti et al. 2012). Deforestation, inadequate urban growth, and climate change are increasing the occurrence of mass movements, mainly water-related landslides, such as earthflows and mudflows (Tominaga, Santoro, and Do Amaral 2009; Gariano and Guzzetti 2016; Nohani et al. 2019).

In recent years, ongoing technological developments have provided new tools for researchers, which are faster, better, and more accurate than conventional ones, making data easier to gather and handle which significantly changed the methods of landslide studies (Mantovani, Soeters, and Westen 1996; Metternicht, Hurni, and Gogu 2005; Scaioni et al. 2014). Conventional methods consist of extensive fieldwork, scanning of topographic maps and visual photo-interpretation of stereo images, which are costly, time-consuming and have limitations that affect the quality of the data (Nilsen and Brabb 1973; Guzzetti et al. 1999; Roering, Kirchner, and Dietrich 2005; Van Den Eeckhaut et al. 2005; Booth, Roering, and Perron 2009; Burns and Madin 2009; Guzzetti et al. 2012; Roering et al. 2013; Scaioni et al. 2014). Use of lidar (Light Detection and Ranging) (McKean and Roering 2004; Glenn et al. 2006; Ardizzone et al. 2007; Van Den Eeckhaut et al. 2007; Baldo et al. 2009; Burns and Madin 2009; Kasai et al. 2009; Ventura et al. 2011; Jaboyedoff et al. 2012; Chen et al. 2013; Wang et al. 2013; Jebur, Pradhan, and Tehrany 2014), RPA (Remotely Piloted Aircraft) SfM-MVS (Structure from Motion Multi-view stereo) (Niethammer et al. 2010; Lucieer, de Jong, and Turner 2014; Turner, Lucieer, and de Jong 2015; Lindner et al. 2016; Yu et al. 2017; Mozas-Calvache, Pérez-Garcia, and Fernandez-Del Castillo 2017; Menegoni, Giordan, and Perotti 2020; Devoto et al. 2020; Samodra et al. 2020; Xu et al. 2020; Godone et al. 2020) and process automation (Van Den Eeckhaut et al. 2007; Guzzetti et al. 2012; Van Den Eeckhaut et al. 2012; Scaioni et al. 2014; Knevels et al. 2019) are the hot spot in landslide studies that are replacing the traditional methods quickly. High resolution (HR) and very high resolution (VHR) data from both remote sensing imagery (satellite, RPA) and topographic data (lidar, SfM-MVS) became mandatory tools in landscape studies (Metternicht, Hurni, and Gogu 2005; Jaboyedoff et al. 2012; Scaioni et al. 2014).

Satellite multi-spectral imagery and airborne photographs are generally collected soon after landslide events, which makes visual identification easier due to the removal of material and vegetation (Guzzetti et al. 1999; Du and Teng 2007; Booth, Roering, and Perron 2009; Liu et al. 2009; Burns et al. 2010; Sameen and Pradhan 2019). Landslide mapping enables the generation and update of inventory maps that are essential input data for risk assessment studies and landslide prediction (Sameen and Pradhan 2019; Yu

et al. 2021; Dias, Hölbling, and Grohmann 2021). The knowledge of the exact landslide location allows specific analysis for emergency response and precautionary actions (Chen et al. 2018), so a continuous monitoring of landslides and update of inventory maps is recommended. Nonetheless, these are not practicable for many government agencies due to lack of resources, personal or technology, where inventory maps do not exist or those that do exist are outdated (Dias, Hölbling, and Grohmann 2021). In this case, inventory maps can be created or updated by identification of relict landslides, but only those which have been preserved in landscape since the day of occurrence.

Identification of relict landslides is important to enhance understanding of landslide causative factors and mechanisms (Sameen and Pradhan 2019; Li et al. 2021), to predict future events, to design preventive frameworks (Schulz 2007) and for quick landslide hazard emergency response (Chen et al. 2018). Also, landslide susceptibility is higher in surrounding areas of relict landslides due to terrain conditions that makes the slope more likely to landslide occurrence (Shahabi and Hashim 2015; Zhong, Hu, and Zhou 2019). Relict landslide detection is most needed where there is a lack of data, no historical records or outdated inventory maps, such as in many states of Brazil (Dias, Hölbling, and Grohmann 2021). However, identification of relict landslides from remote sensing data is not an easy task. In natural steep slopes, vegetation growth covers devastated areas, making landslide identification and monitoring harder over time (Lehmann 2008; Portela 2014; Scaioni et al. 2014). Furthermore, relict landslides may suffer from surface erosion processes, such as runoff (Fiori and Carmignani 2015) or swell factor (Dewitte and Demoulin 2005; Pedrazzini et al. 2010; Schulz et al. 2018), which disturb the terrain and degrade landslide boundaries making them unrecognizable.

The post-event visual identification is commonly performed by experts in GIS (Geographic Information System) software and is an exhaustive, time-consuming task (Van Den Eeckhaut et al. 2007; Burns and Madin 2009; Burns et al. 2010). In the last couple of decades, semi-automatic and automatic detection of landslides started to be exploited from different sources and tools, mainly using very-high-resolution (VHR) topographic data, such as lidar DEMs (Digital Elevation Models), and multispectral imagery (McKean and Roering 2004; Glenn et al. 2006; Ardizzone et al. 2007; Van Den Eeckhaut et al. 2007; Baldo et al. 2009; Burns and Madin 2009; Kasai et al. 2009; Ventura et al. 2011; Jaboyedoff et al. 2012; Chen et al. 2013; Wang et al. 2013; Jebur, Pradhan, and Tehrany 2014). Automatic landslide detection is important because it allows rapid mapping procedures with potential applications for hazard assessments, risk mitigation, and post-event recovery efforts (Guzzetti et al. 2012). Methods such as OBIA (Object-based Identification Analysis) (Petropoulos, Kalaitzidis, and Prasad Vadrevu 2012; Van Den Eeckhaut et al. 2012; Scaioni et al. 2014; Knevels et al. 2019), pixel-based classification (Li et al. 2020; Wang et al. 2020), machine learning algorithms (Pal and Mather 2006; Maxwell, Warner, and Fang 2018; Ghorbanzadeh et al. 2019; Zhong, Hu, and Zhou 2019) and Deep Learning (Luus et al. 2015; Ding et al. 2016; Scott et al. 2017; Kussul et al. 2017; Chen et al. 2018; Ma et al. 2019; Sameen and Pradhan 2019; Ji et al. 2020; Li et al. 2020; Prakash, Manconi, and Loew 2020; Li et al. 2021; Yu et al. 2021; Soares et al. 2022; Xu et al. 2022; Meena et al. 2022) are the most prominent techniques in landslide semi-automatic and automatic detection studies.

Machine learning algorithms and, more recently, deep learning neural networks showed excellent performance in remote sensing analysis, although deep networks

were not designed to process high-resolution images (Audebert, Le Saux, and Lefèvre 2016; Cheng, Han, and Lu 2017). Convolutional Neural Networks (CNN) is probably the most successful network architecture in deep learning and have been widely used to extract spatial features for object detection and image segmentation of high-resolution images (Krizhevsky, Sutskever, and Hinton 2012; Castelluccio et al. 2015; Zhang, Zhang, and Kumar 2016; Kussul et al. 2017; Zhao, Du, and Emery 2017; Cheng et al. 2018; Ma et al. 2019; Zhong, Hu, and Zhou 2019; Hoeser and Kuenzer 2020; Li et al. 2020; Yu et al. 2021; Bai et al. 2022).

Studies for automatic landslide detection using CNN are still incipient, but the results are promising, and the interest of geoscientists in these techniques is increasing significantly (Ji et al. 2020). Although landslide detection studies share the same final goal, the methods and data used are quite different. Studies for comparison, evaluation of existing machine learning methods (Sameen and Pradhan 2019; Ghorbanzadeh et al. 2019; Prakash, Manconi, and Loew 2020; Wang et al. 2020; Li et al. 2021) and proposal of new CNN methods (Ding et al. 2016; Ji et al. 2020; Yu et al. 2021; Soares et al. 2022) are the most outstanding. Usually, new CNN models are proposed to solve specific problems that standard CNN models had difficulties with or achieved inappropriate results. Introduction to new network architecture, modification of CNN framework, pre-processing of input data and image post-processing steps are the most common topics of the CNN models proposal studies.

Input data such as multispectral imagery, topographical data or a combination of both is selected according to data availability and the study area characteristics. Also, the amount of data used for CNN training is essential for obtaining satisfactory results, mainly labelled data (Ronneberger, Fischer, and Brox 2015). Most landslide detection studies focus on identifying recently triggered landslides using mainly multispectral images collected soon after the occurrence when landslides are more clearly visible in the landscape, which facilitates the classification process by the CNN.

On the other hand, identification of relict landslides has difficulties, such as preservation of landslide boundaries and degree of vegetation cover, and is usually performed using as input a DTM (Digital Terrain Model) generated from VHR topographical data that is able to filter out the vegetation cover (Guth et al. 2021; Wang et al. 2020). However, in addition to VHR topographical data not existing or not being available for most countries, results from landslide detection studies that added topographical data as an input band in the CNN's training process did not achieve better results than using only spectral bands (Ghorbanzadeh et al. 2019; Sameen and Pradhan 2019; Ji et al. 2020; Soares et al. 2022).

The main objective of this paper is to perform a semi-automatic detection of relict landslides using CNN for an area in southeastern Brazil that has preserved landslides on its slopes for several decades due to a specific fern species. A new framework for CNN semantic segmentation using transfer learning is proposed as an attempt to overcome difficulties such as lack of labelled landslide data and improve the model's classification ability. A comparison between the proposed and the standard framework will be performed. The focus is on taking advantage of the visual contrast between the ferns and the native vegetation to perform the detection of relict landslides using CBERS-04A WPM multispectral images as input to the CNN training process. Detection of relict landslides will help updating the inventory map of the region that is dated from the 1970s and did not suffer great reviews (Correa et al. 2017; Dias, Hölbling, and Grohmann 2021). This

study is novel in terms of using CBERS4A multispectral images as input for semi-automatic relict landslide detection and for proposing a new framework for CNN semantic segmentation that performs a pre-training step that is later used to fine-tune the neural network, compared to previous studies that attempted to detect landslides in tropical regions.

2. Methods

2.1. Study area

The study area is within the Serra do Mar mountain range, southeastern Brazil (Figure 1). It includes the majority of Caraguatatuba municipality, encompassing coastal and mountainous portions. This region is known for its preserved Atlantic rainforest and has a long

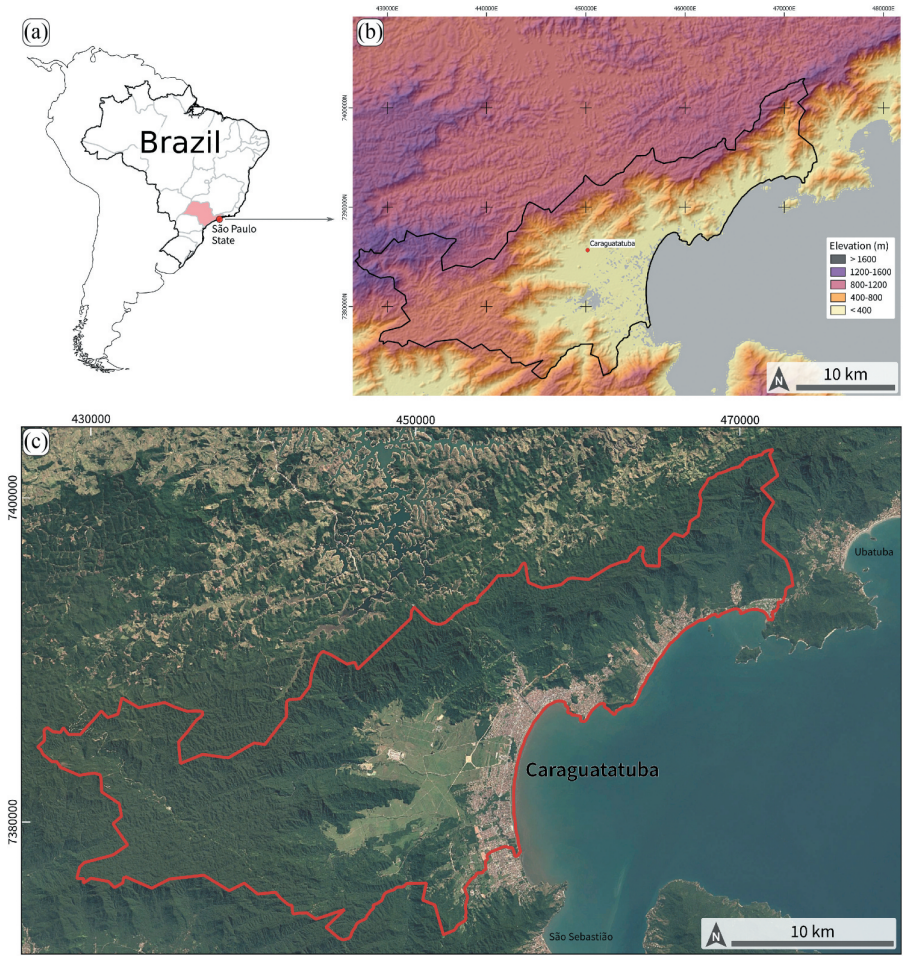

Figure 1. a) Location of São Paulo state in Brazil. b) Elevation map of the study area. c) Image of the study area with Caraguatatuba municipality in red. Satellite image Landsat/Copernicus (2015-12-30), powered by Google. UTM coordinates, zone 23 (South), WGS84.

history of landslide occurrences on hillsides, mainly shallow landslides and flows (Fúlfaro et al. 1976; Guidicini and Nieble 1984; Augusto Filho 1992). An inventory map is available for a major event that occurred in 1967, when almost 600 landslides of various sizes were identified, which caused destruction and human losses (Fúlfaro et al. 1976). Despite the high landslide occurrence rate in the region, there is a lack of landslide documentation, with few studies updating the previous inventory map and monitoring the landslides (Correa et al. 2017; Dias, Hölbling, and Grohmann 2021).

A mountainous landscape marks the study area in the west and the coastal areas with sandy beaches and plains in the east (Ponçano 1981) (Figure 2a). The mountains are characterized as rugged reliefs with high slope gradients and valleys with amplitudes higher than 100 m, defined as Costeira Province (Almeida 1964; Ponçano 1981). Landslides usually occur in this section due to its favourable conditions for mass movements.

The geological setting is within the Mantiqueira Province, specifically in Serra do Mar Domain (Perrota et al. 2005), mainly composed of granites and gneisses from the Costeiro Complex and Pico do Papagaio Complex, which occurs as intercalated lenses controlled by shear zones (Figure 2B). Several faults and shear zones oriented towards SW-NE comprising the structural framework of the study area (Perrota et al. 2005). The principal structure is the shear zone that occurs in the N-NW portion of the study area, namely the Bairro Alto Shear zone; other important structures are the Caraguatatuba fault and the Camburu fault. These structures control lithology. There is also the presence of mafic intrusions related to the Araçuaí - Rio Doce orogen, quaternary deposits occur in river banks and coastal plants.

The local climate also contributes to landslide occurrence with rainy summers that usually trigger landslides and other mass movements (Conti and Furlan 1996). Climate regime in Caraguatatuba is defined as Cwa, or altitude tropical climate Koeppen (1948). The annual average rainfall is up to 1830 mm, with August as the driest month (60 mm) and January as the rainiest (300 mm).

Most of the study area is within the Atlantic rainforest biome, which covers almost all Brazilian coastal regions and presents great biodiversity. The Dense Ombrofile Forest is the predominant vegetation cover, distinguished by high indices of temperature and rainfall during the year (Ellenberg and Dombois 1967; Veloso, Rangel-Filho, and Lima

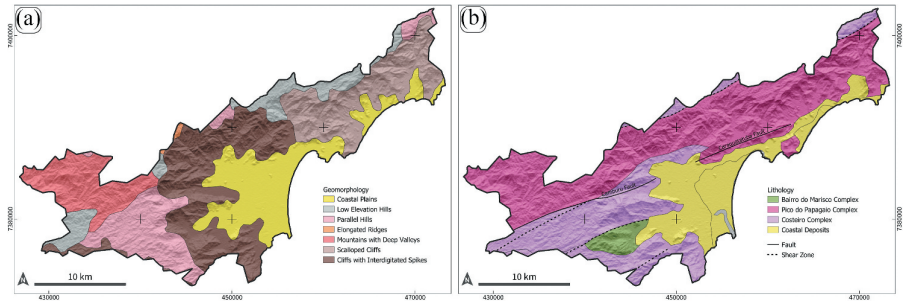

Figure 2. a) Geological and (b) geomorphological map of the study area. UTM coordinates, zone 23 (South), WGS84.

1991), evergreen vegetation cover with several layers, a canopy that can reach up to 50 m in height and dense shrubbery detaching ferns, bromeliads and palm trees (Portela 2014). Forest formation is controlled by elevation due to its mountainous context and can be divided into Dense Ombrofile Forest, Arboreal Forest, and Secondary vegetation (Kronka et al. 2007).

Despite preserved vegetation in most of the studied areas, landslides occur on natural steep slopes but are more common in deforested areas and close to roads and urban areas.

2.1.1. *Gleichenella sp*

Ferns are common plants in the Atlantic rainforest of Serra do Mar being pioneers and efficient in regenerating degraded forests (Lehmann 2008). The hillsides degraded by landslides in the study area are usually covered by a specific fern species named *Gleichenella* sp., while others are almost totally recovered by the forest (Lehmann 2008; Portela 2014) (Figure 3). *Gleichenella sp*. usually prevents complete forest regeneration in the degraded areas, maintaining landslide scars and boundaries distinguishable from adjacent areas.

2.2. Data

2.2.1. CBERS-04A

CBERS-04A is a mid-resolution remote sensing satellite in a sun-synchronous orbit launched in December 2019, with the first images released for download in January 2020. The satellite is operated by the Brazilian National Institute of Spatial Research (INPE), and the images are available for free download on their website (http://www2.dgi.inpe.br/catalogo/explore). It is equipped with three cameras: MUX (Multispectral

Figure 3. Example of *Gleichenella* ferns occurrence in landslide scars in Caraguatatuba municipality. Satellite imagery ©2021 Digital Globe, powered by Google. See location in Figure 1.

Camera), WFI (Wide Field Imager) and WPM (Wide Panchromatic Multispectral). MUX and WFI have four optical bands (R, G, B and NIR) with spatial resolution of 16.5 m and 55.5 m, respectively. The WPM has five bands (R, G, B, NIR and panchromatic) with spatial resolution of 8 m for the optical bands and 2 m for the panchromatic bands. The revisit period is 31 days for the WPM and MUX and 5 days for the WFI. The swath width for each camera is 92 km (WPM), 95 km (MUX) and 684 km (WFI).

In this project five CBERS4A images were used with the four optical bands of the WPM camera, namely blue (0,45–0,52 μm), green (0,52–0,59 μm), red (0,63–0,69 μm) and near-infrared (0,77–0,89 μm). All the images were used without radiometric or atmospheric corrections and with no cloud cover.

2.3. Convolutional neural networks

CNN has shown impressive performance in many applications, including remote sensing analysis, with fast growth in the use of this network in the last few years (Krizhevsky, Sutskever, and Hinton 2012; Castelluccio et al. 2015; Cheng et al. 2018; Bai et al. 2022). The typical architecture of a CNN is composed of multiple feature-extraction stages where each stage consists of a series of layers, including convolutional layers, pooling layers and fully connected layers (Castelluccio et al. 2015; Cheng et al. 2018). CNN is designed to take advantage of the two-dimensional structure of the input image and focus on bridging the low-level features to high-level semantics of the image scene, automatically extracting intrinsic features from remote sensing imagery (Zhang, Zhang, and Kumar 2016; Zhong et al. 2017). For Zhao et al. (2015) a limitation for using CNN in remote sensing image classification is that it requires many labelled training samples, which is not always available.

In this study, the focus was not to propose a new CNN architecture but to explore the capabilities of the existing CNN models in the Segmentation Models python library (Yakubovskiy 2019). The CNNs in these libraries are built explicitly for semantic segmentation tasks rather than classification, which means that the classification task aims to assign one label to each pixel in the images (Bai et al. 2022). U-Net (Ronneberger, Fischer, and Brox 2015), FPN (Lin et al. 2017) and Linknet (Chaurasia and Culurciello 2017) were the CNN models chosen for landslide detection in this project (Figure 4).

2.3.1. Deep learning architectures for image segmentation

Image segmentation models are considered to be a multi-scale context problem, i.e. to predict the class of a single pixel they use contextual information, so the areas around the pixel of interest help in its identification, based on some factors like the size and continuity of the element, and the amount of neighbouring segments of other classes (Hoeser and Kuenzer 2020). Landslide detection studies benefit from contextual information since landslides, particurlaly shallow landslides, have a distinctive colour and long, narrow shapes that distinguishes them from their surroundings, both in natural slopes and urban areas, which facilitates the identification through image segmentation (Ghorbanzadeh et al. 2019; Sameen and Pradhan 2019; Prakash, Manconi, and Loew 2020; Soares et al. 2022).

The Unet architecture was introduced by Ronneberger, Fischer, and Brox (2015), modifying and extending FCN (Fully Convolutional Network) by working with very few

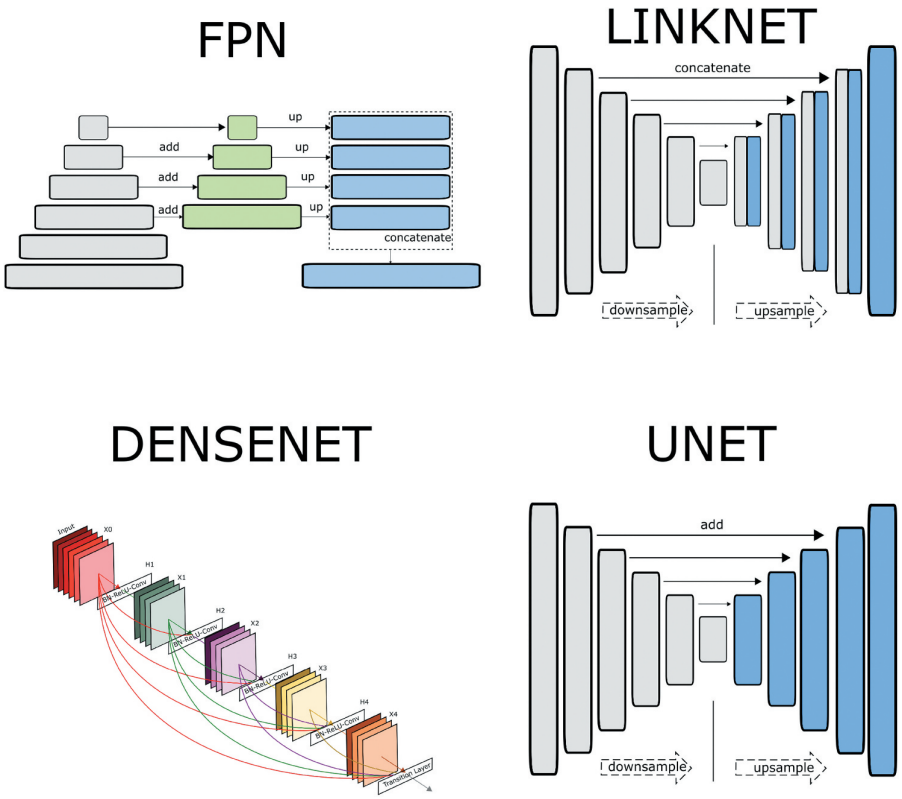

Figure 4. Structure of FPN, LinkNet, DenseNet and Unet. Modified from Yakubovskiy (2019).

training images, with more accurate segmentation and preserving image localization. The main difference from traditional CNN lies in its architecture of the expanding path. Unet consists of two paths: a constructive path and an expansive path (Figure 4). The constructive path follows a typical CNN architecture with convolution and pooling layers for downsampling. The expansive path consists of upsampling the feature map and replacing the fully connected layers.

Feature pyramids are a primary component in recognition systems for detecting objects at different scales. The Feature Pyramid Network (FPN) was introduced by Lin et al. (2017) as a feature pyramid with rich semantics at all levels is built quickly from a single input image scale and is a generic solution built inside a deep CNN. Its architecture combines low-resolution, semantically strong features, with high-resolution, semantically weak features, with a top-down pathway and lateral connections (Figure 4). The pyramid's construction involves two parts: a bottom-up pathway and a top-down pathway and the lateral connections between them.

LinkNet is a neural network architecture proposed by Chaurasia and Culurciello (2017) and designed specifically for semantic segmentation (Figure 4). It comprises an encoder-decoder pair containing residual blocks and linking each encoder with a decoder to avoid losing spatial information. The input of each encoder layer is bypassed by the output of its

corresponding decoder so that the decoder and the upsampling operations can use the spatial information. LinkNet results are more efficient compared to existing state-of-the-art segmentation networks that have an order of magnitude larger computational and memory requirements.

DenseNet (Huang et al. 2017) was used as a backbone for the pre-training step and it is available as a standard backbone in the segmentation models python library (Yakubovskiy 2019). It was proposed as a network with a different connectivity pattern that connects each layer to every other layer in a feed-forward fashion, namely Dense Convolutional Network (DenseNet) (Figure 4). A remarkable difference between DenseNet and other networks, such as ResNet (He et al. 2016), is that it yields condensed models with feature reuse that are easy to train and more efficient. It also concatenates feature maps learned by different layers, which increases variation and efficiency. The DenseNet architecture comprises dense blocks and transition layers, with a convolution at the beginning and a softmax classifier at the end.

2.3.2. Proposed deep learning framework

This study proposes a new deep learning framework for semi-automatic relict landslide detection that uses transfer learning for accuracy improvement, and the results are compared to a standard CNN framework. The standard framework is usually performed in three steps: data processing, training and validation, while the proposed framework has one more step, pre-training (Figure 5).

- Data Processing

Two datasets were created in the data processing step, the labelled dataset and the Cluster Dataset. The labelled dataset comprises images labelled in two classes, with or without landslide scars. It uses the CBERS4A 201/143 (path/row) image from August of 2020 as input with a dimension of 14,210 × 14,592 pixels, which was clipped in tiles of 32 × 32 pixels. A zero-padding process was used to enable the creation of the tiles. Each tile received a label due to the existence of landslides (label = 1) or not (label = 0) according to a landslide mask. The landslide mask was created by rasterizing a landslide vector composed of 384 landslides that were identified from Fúlfaro et al. (1976) inventory map and visual interpretation of current images. If a tile has at least 1 pixel in intersection with the landslide mask, it is labelled as a landslide. The CBERS4A 201/143 image that encompasses the study area was split into train and test areas so that the landslide mask was split into a nearly 70:30 ratio, where 276 (~70%) landslides belong to the train area and were used to create the labelled dataset (LD) and 108 (~30%) belong to the test area and were used for the evaluation of model's accuracy (Figure 6). The Labelled Dataset has a total of 202,464 tiles of which only 422 tiles were labelled as landslides (Table 1).

The Cluster dataset (CD) used the k-means algorithm to cluster data by trying to automatically separate samples into *k* groups based on pixel colour similarity, which is expected to be able to segregate major land cover areas (Pedregosa et al. 2011). Images covering the full extension of the Serra do Mar mountain range were used in this step, almost encompassing the whole coast of São Paulo state. Five CBERS4A images were used as input (path/row): 200/142, 200/143, 201/142, 201/143 and 202/143. The images were

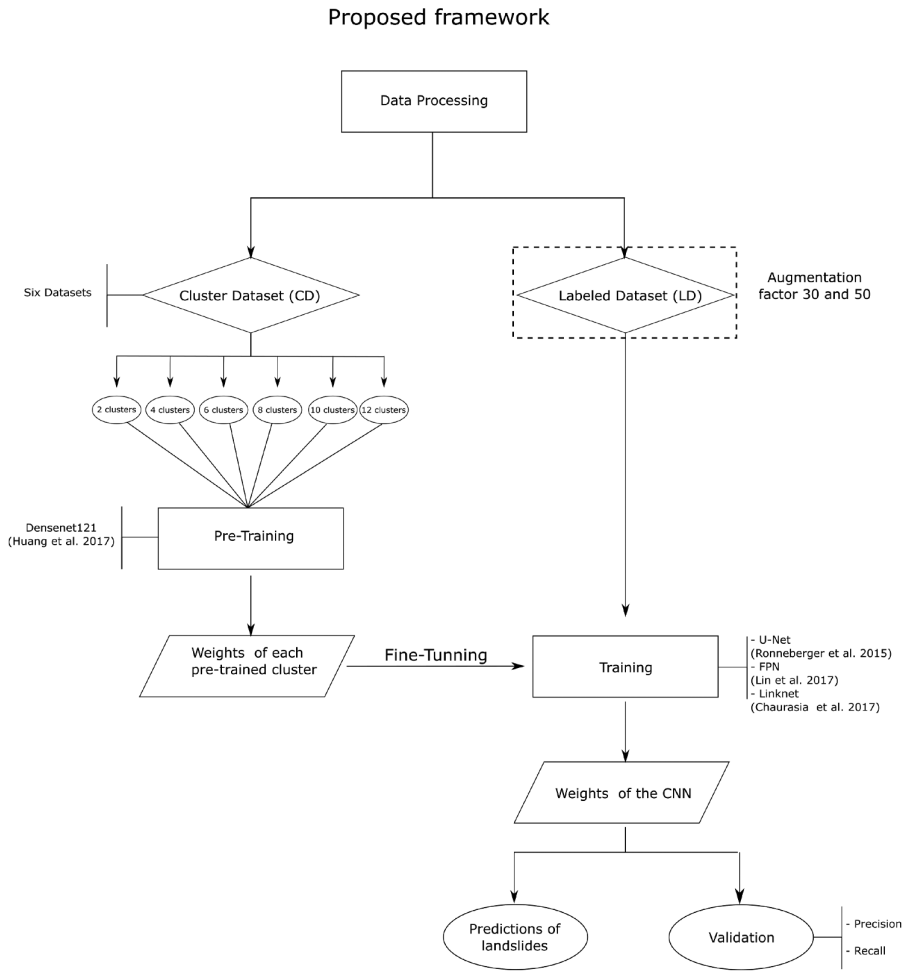

Figure 5. Proposed framework of CNN relict landslide detection.

clipped in tiles with 32×32 pixels, also using the zero-padding process for the borders of the images. Each tile receives a label with the predominant class according to the k-means clustering results. Since the number of clusters has to be specified for the k-means algorithm, the clustering was performed with values 2, 4, 6, 8, 10 and 12. To enhance the clustering process, pixels representing ocean and urban coastal areas were removed from input images, so the k-means algorithm used only highland and mountain features. Finally, a class balancing process was performed with the tiles assigned to each cluster (Table 2).

- Augmentation

Usually, a massive amount of data is necessary for training a neural network such as CNN, which is not always available (Zhao et al. 2015). To overcome this lack of training samples, researchers can use data augmentation techniques to increase these numbers

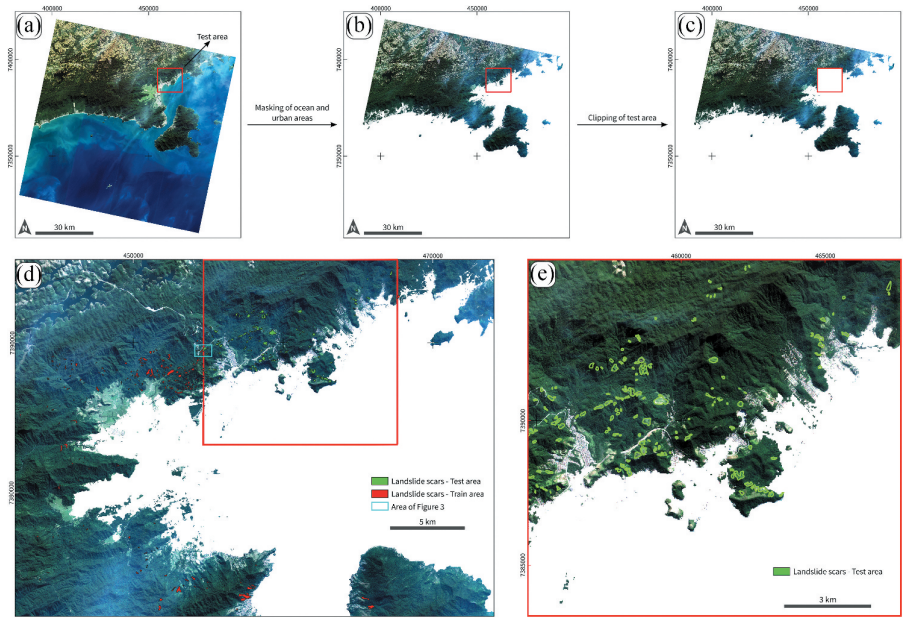

Figure 6. a) CBERS-04A image 201/143 with the location of the test area. b) Image with ocean and urban areas clipped. c) Image with the test area clipped, used for the training process. d) Landslide scars in the train area and test area. E) Test area with landslide scars.

(Ronneberger, Fischer, and Brox 2015). This study performed three types of data augmentation techniques: horizontal flip, vertical flip, and a combination of both (horizontal-vertical flip). To avoid unbalancing data, the augmentation was performed only for the positive class of the labelled dataset, i.e. tiles labelled as landslides. In total, 390 tiles were labelled as landslides and were split into train and test sets with a ratio of 60:40, 241 labelled landslides in the train area and 149 labelled landslides in the test area (Table 1). The 241 labelled landslides in the train area were augmented by a factor of 30 (7230 tiles) and 50 (12050 tiles); these augmented datasets are referred to as LD30 and LD50, respectively, and were used in the training process for both the standard and the proposed CNN framework.

- Pre Training

Densenet121 was chosen for this pre-training step, and the input was the Cluster dataset, which was explicitly created to pre-train the backbone network. The pre-training step intends to initialize the CNN, i.e. enable the CNN to learn how to segregate objects through the image bands automatically. As spectral features of landslides are usually different from adjacent areas, the pre-training step may help to identify these areas. The weights computed in this process will be used for transfer learning, i.e. fine-tuning the training process of the CNNs. Transfer learning is usually used when there is a lack of training dataset, which is the case with labelled landslide data for the study area (Liu et al. 2018).

Table 1. Details of Labelled Dataset.

Labelled Dataset		
Augmentation	Negative Class	Positive class
	202,042 tiles	422 tiles
LD30	-	12,660 tiles
LD50	-	21,100 tiles

Table 2. Details of the cluster dataset with the number of tiles for each class created.

Cluster Dataset						
Classes ↓ /Clusters →	2	4	6	8	10	12
0	497474 tiles	165743	99447	71004	55195	45147
1	497474	18084	5360	3713	3540	3064
2	-	206833	20703	20277	19473	17781
3	-	272312	259210	253449	251040	13156
4	-	-	85145	35873	22875	255105
5	-	-	126818	93978	39922	28676
6	-	-	-	29688	25174	49795
7	-	-	-	60050	58609	26133
8	-	-	-	-	29999	42012
9	-	-	-	-	46127	9913
10	-	-	-	-	-	19052
11	-	-	-	-	-	31932

- Training

Three CNNs were used for landslide detection: FPN, Linknet, and Unet. These CNNs are available in the Segmentation Models python library based on Keras (Tensorflow) (Yakubovskiy 2019) and are specific for semantic segmentation tasks. All three CNN models have a downsample and an upsample path and use the Densenet121 as a backbone. The weights of these CNNs are evaluated in the test area using validation indices and prediction of landslides. The standard framework used both LD30 and LD50 as input to train each CNN and compute the weights for later validation. A total of 6 combinations were made, and the results were used to predict landslides. In the proposed framework, the weights learned in the pre-training step were used to fine-tune the training process. The CNNs were trained for each cluster with LD30 and LD50 as input, resulting in 12 combinations for each CNN (FPN, Linknet and Unet), 36 in total, used for model evaluation. The entire CNN training process was done with a learning rate of 0.00001 and for 300 epochs.

- Validation/Accuracy Assessment

Precision and Recall were used to validate the models. These statistical methods are based on three kinds of classified pixels: True Positives (TP), False Positives (FP) and False Negatives (FN) (Ghorbanzadeh et al. 2019). Precision (Eq. 1) is used to quantify the rate of positive samples (TP) among predicted positive samples (TP + FP). The higher the precision of the model, the better the probability of correctly classifying positive samples. In other words, precision determines how many of the classified areas are really landslides. Recall (Eq. 2) represents the ratio of correctly predicted landslides to the ground truth (Ji et al. 2020). This means that recall can determine

Table 3. Precision and Recall results of FPN, Unet and Linknet models tested for the proposed framework. In bold, the highest value of each model.

		Precision			Recall		
Dataset	Clusters	FPN	Unet	Linknet	FPN	Unet	Linknet
LD30	2	0.1144	0.1270	0.1367	0.7618	0.7824	0.7749
	4	0.1755	0.0537	**0.1902**	0.7669	0.7965	0.7828
	6	0.1425	**0.1875**	0.1779	0.7820	0.7914	0.7866
	8	**0.2047**	0.1644	0.0555	0.7710	0.7944	0.7795
	10	0.0687	0.1655	0.1732	0.7602	0.7956	0.8056
	12	0.1328	0.1676	0.1674	0.7696	0.7775	0.7815
LD50	2	0.0473	0.1431	0.1366	0.7581	0.7782	0.7828
	4	0.0876	0.0621	0.1752	0.7788	0.7886	**0.8109**
	6	0.1542	0.1585	0.1546	0.7765	0.7798	0.7832
	8	0.1836	0.1428	0.0612	0.7750	0.7800	0.7996
	10	0.1786	0.0627	0.0471	**0.7853**	**0.8095**	0.7906
	12	0.1323	0.1723	0.1613	0.7692	0.7877	0.7970

Table 4. Precision and recall results of FPN, Unet and Linknet models tested for the standard framework. In bold, the highest value of each model.

	Precision			Recall		
Dataset	FPN	Unet	Linknet	FPN	Unet	Linknet
LD30	**0.1337**	0.1405	0.1212	**0.7845**	**0.7952**	0.7774
LD50	0.1264	**0.1583**	**0.1240**	0.7750	0.7925	**0.7892**

how much of the landslide areas defined by visual interpretation were classified in the images (Ghorbanzadeh et al. 2019).

$$Precision = \frac{TP}{TP + FP} \tag{1}$$

$$Recall = \frac{TP}{TP + FN} \tag{2}$$

3. Results and discussion

The results were evaluated by Precision and Recall validation indices and by landslide predictions that enable visual interpretation. All the combinations of CNNs and parameters were trained and validated in the train area, while the results were obtained from the test area. Table 3 shows the values of precision and recall for each combination tested in the proposed framework. Table 4 shows the values of precision and recall for the standard CNN framework.

3.1. Validation indices

The results between the standard and the proposed CNN frameworks are similar, with a difference between the validation results generally around 5%. The combinations of parameters and clusters also had similar results. Recall achieved relevant outcomes, with values higher than 75% for every combination tested. U-Net neural network is

commonly used for semantic segmentation of landslides in other studies with relevant outcomes (Prakash, Manconi, and Loew 2020; Li et al. 2021; Soares et al. 2022); therefore, it was expected that U-Net combinations would produce the best results in this project, which did not necessarily happen. Although U-Net achieved the best recall and precision results for the standard framework, it was surpassed by FPN and Linknet in the proposed framework.

The best recall result for the standard framework was 79.52% (Unet with LD30), while for the proposed framework the best recall result was 81.09% (Linknet with 4 clusters and LD50). In contrast with recall results, precision values were unexpectedly low for all combinations usually between 10% and 20%. The higher values of precision were 15.83% for Unet with LD50 in the standard framework and 20.47% of FPN with 8 clusters and LD30 for the proposed framework. These low precision values may indicate that the models have a high false-positive rate, i.e. non-landslide pixels classified as landslides (Equation (1)).

In the studies of semi-automatic landslide detection using CNN, the values of recall and precision are both commonly above 70% (Chen et al. 2018; Ding et al. 2016; Ghorbanzadeh et al. 2019; Ji et al. 2020; Li et al. 2021; Yu et al. 2021; Zhong, Hu, and Zhou 2019). These high rates of recall and precision are probably related to the ease of identifying recently occurred landslides through images collected right after the event when vegetation cover is removed and the soil is exposed. Nonetheless, maximizing both evaluation indices may be challenging as they are inversely correlated, i.e. increases in recall often come at the expense of decreases in precision.

These results (high recall/low precision) mean that the CNNs tested in this study identifieid, or predicted, more relict landslides than exist in the ground truth, which generated many false-positive samples, thus decreasing precision. High recall/low precision models are considered less conservative, which means that for landslide detection, the model will try to identify as many landslides as possible at the expense of generating many false-positive samples.

Although these results may seem flawed (inappropriate or unsatisfactory) at first, they are consistent with the primary objective of detecting relict landslides. Landslide detection studies are valuable in creating and updating inventory maps with the inclusion of new landslides after they occur. Thus, in areas with few landslide historical data or outdated inventory maps, it is a good sign that landslide detection methods are able to predict more landslides than they exist on ground truth. In other words, false-positive samples may indicate new relict landslides identified in the study area that were previously undetected.

3.2. Predictions

Landslide prediction maps enable visually evaluating CNNs' ability to detect landslides. All the predictions were performed with a threshold of 0.5, i.e. cell values above 0.5 are classified as landslides. Predictions were very heterogeneous across all tested combinations, with some models correctly detecting relict landslides, while predictions from other models were very noisy, with many errors and unable to detect any relict landslides. Predictions that correctly detected most relict landslides did so with errors and misclassifications, mostly false-positive samples.

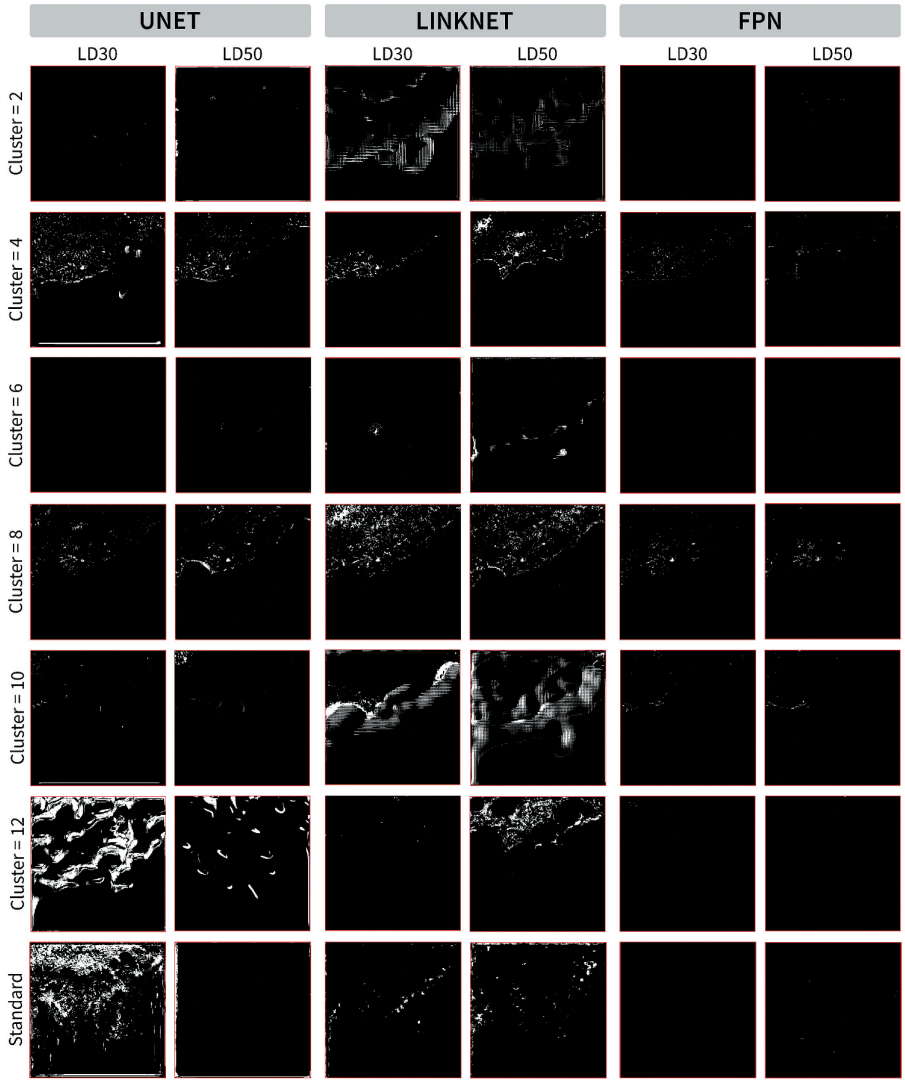

Figure 7. Predictions of landslides from the proposed and standard frameworks.

Although recall assessment showed high results for all the combinations from both frameworks, mainly above 75%, predictions showed that only 18 of 42 (36 + 6) combinations were able to detect relict landslides more or less accurately (Figure 7). Most of the predictions did not detected any relict landslides or had a coarse aspect with many false-positive samples.

Predictions of the proposed framework were more acurrate than those of the standard framework. Fifteen of the 36 (41.7%) predictions of the proposed framework detected relict landslides in the test area, but always with the presence of false-positive samples. Figure 8 shows predictions of the CNNs with eight clusters and LD50, as well as the TP, FP

and FN results. The supplementary material presents all 15 predictions that correctly detected landslides with TP, FP and FN results.

In general, these predictions managed to delineate the relict landslides mainly located in the centre-north portion of the test area. Predictions of Unet (six clusters and LD50) and Linknet (six clusters with LD30 and LD50) identified only the relict landslides in the centre-south portion (Figure 7).

It is not clear why this difference in classification per region occurs. The southern portion of the study area represents mainly urban and ocean areas that were removed from the original image in the data processing step, and the voids were labelled as 'no data'. The image tiles used as input for the CNN were generated from this clipped image. The tile size (32×32 pixels) and the tile cutting pattern may have affected the accuracy for relict landslide detection of the CNN. That may help explain why the landslides in the southern portion were more complex to detect than those from the centre-north portion of the study area.

In the standard framework, three of six (50%) predictions (Linknet with LD30/LD50 and Unet with LD30) correctly detected relict landslides, but the latter also showed a high number of false positives and had a noisy representation similar to the salt-and-pepper effect. However, despite being less accurate than the proposed framework predictions, these predictions were able to detect relict landslides in the whole study area.

Notably, there is a clear difference in the number of false-positive samples in the landslide predictions of each method. FPN predictions are those with fewer false-positive samples, which means that FPN is the most conservative method, but also with fewer true positive samples. The best FPN predictions are those with eight clusters and both LD30 and LD50 that can detect almost all the major relict landslides in the area with very few errors.

U-Net and Linknet predictions are less conservative models, i.e. predicted many false-positive samples, in an attempt to detect more relict landslides than they exist in the ground truth. The problem with the less conservative models is that they are subject to many errors, some of them very rude. There are some false-positive samples in standardized, rectilinear or symmetrical positions, which are very strange and unnatural positions. The combinations of (CNN/Cluster/LD) Linknet/4/LD50, Linknet/8/LD50, Linknet/Standard/LD30, Linknet/Standard/LD50, U-Net/4/LD30, U-Net/4/LD50 and U-Net/8/LD50 depict these kinds of errors. However, the most outstanding errors occur with the U-Net/Standard/LD30 predictions, which are smeared with false-positive samples across the entire test area.

3.3. Correlation

Although 42 combinations of parameters were performed, it was not possible to determine an optimal combination for relict landslide detection. The types of CNNs (U-Net, FPN and Linknet), augmented dataset (LD30 or LD50) and number of clusters (2, 4, 6, 8, 10, 12) did not show a consistent and significant correlation with the results. Recall and precision results were very similar for all 42 combinations, whereas the predictions were very divergent. The combinations that detected relict landslides in the predictions were not necessarily the same combinations that achieved the best results in recall and precision (Table 5).

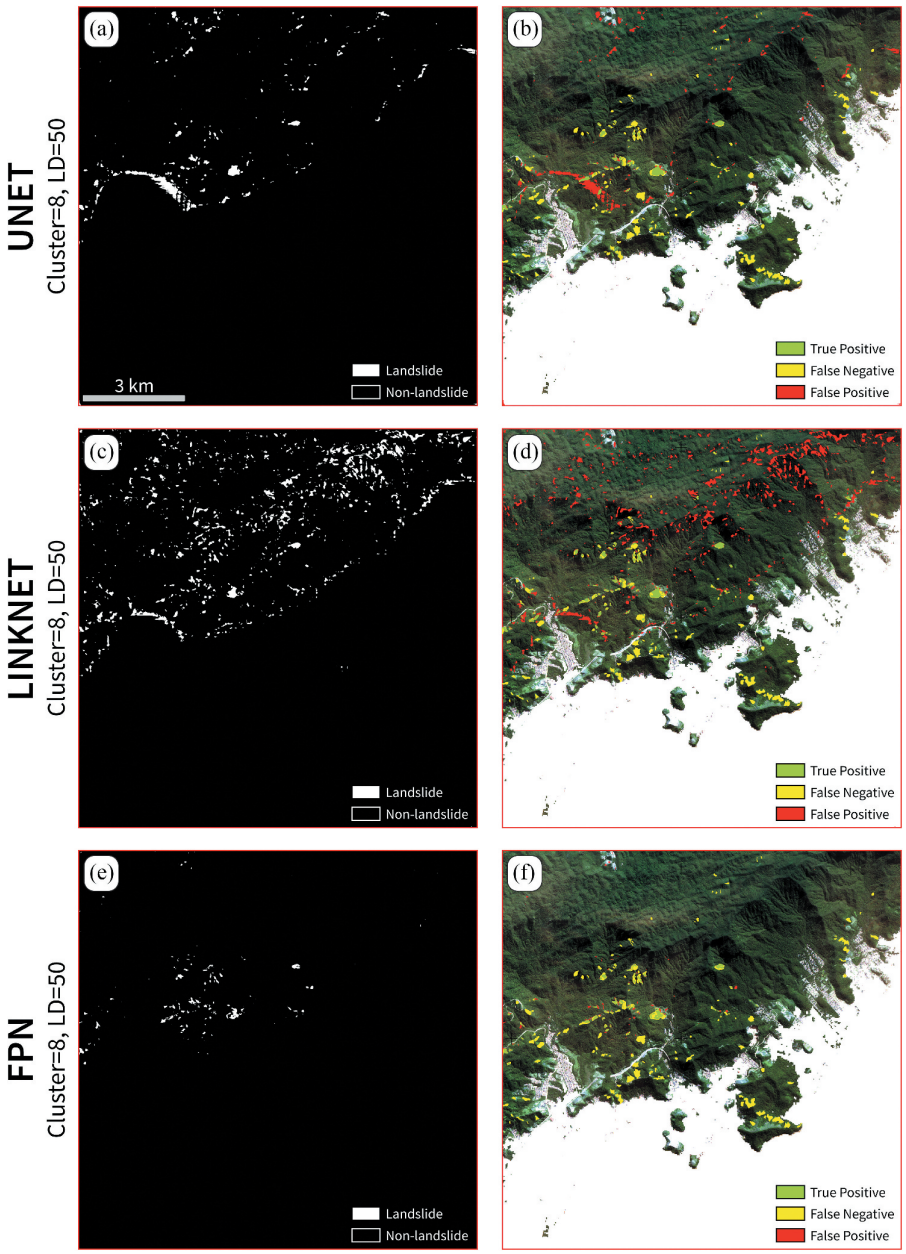

Figure 8. Image of True Positive, False Positive and False Negative samples from the predicitons of (a) Unet, (b) Linknet and (c) FPN. All predictions are from the combination of eight clusters and LD50.

The combinations of FPN and Linknet parameters that achieved better recall and precision results were able to detect relict landslides in the predicitons, unlike what happens with the combinations of U-Net parameters where the predictions that detected relict landslide are not the same as those with better recall and precision results. Thus, it

Table 5. Recall and precision values of the predictions that detected relict landslides. Numbers in bold represent the highest results for the CNN framework type.

Type of CNN	Clusters	Dataset	Recall	Precision
FPN	4	LD30	0.7669	0.1755
		LD50	0.7788	0.0876
	8	LD30	0.7710	**0.2047**
		LD50	0.7750	0.1836
	10	LD30	0.7602	0.0687
		LD50	**0.7853**	0.1786
Linknet	4	LD30	0.7828	**0.1902**
		LD50	**0.8109**	0.1752
	6	LD30	0.7866	0.1779
	8	LD30	0.7795	0.0555
		LD50	0.7996	0.0612
	Standard	LD30	0.7774	0.1212
		LD50	**0.7892**	**0.1240**
U-Net	4	LD30	0.7965	0.0537
		LD50	0.7886	0.0621
	8	LD30	0.7944	0.1644
		LD50	0.7800	0.1428
	Standard	LD30	**0.7952**	0.1405

demonstrates that one cannot rely only on validation results to evaluate CNNs, but that visual inspection of landslide predictions is also of paramount importance.

3.4. Discussion

This study found significant limitations in the semi-automatic detection of relict landslides in vegetation-covered areas using multispectral images as input to the CNN semantic segmentation process. The lack of labelled data for training the CNNs and the spectral similarities of the land cover units are probably the main reasons that prevented the CNNs to achieve more accurate results.

The efficiency of CNN classification ability relies mainly on the amount of labelled data used as input in the training process (Ronneberger, Fischer, and Brox 2015). Usually, labelled landslide data is directly obtained from inventory maps that show all landslides that have occurred over a period of time, however the inventory map of the study area is outdated and incomplete. It was first created in the late 1970s to map a major landslide event that occurred in 1967 (Fúlfaro et al. 1976), and there have been no relevant updates since (Correa et al. 2017). Thus, labelled landslide data are sparse for the study area, which made it necessary to perform data augmentation to enable CNN training even if augmentation may skew the data and decrease CNN's accuracy.

The semi-automatic detection of relict landslides was only possible in this project due to the presence of *Gleichenella sp*. ferns that cover degraded areas, prevent forest restoration and preserve the boundaries of landslides (Section 2.1.1). As shown in Figure 3, the relict landslides can be distinguished from their surroundings by the light green colour of *Gleichenella* sp., while native vegetation has a dark green colour in general. However, there are spectral similarities between *Gleichenella* sp. ferns and other land cover features such as pasture, agricultural fields or deforested areas. Thus, the spectral characteristics are not sufficient to enable accurate detection of relict landslides and the occurrence of misclassification is somewhat expected. In areas covered by dense vegetations, such as

the Atlantic rainforest, landslide detection is usually performed using multispectral images acquired soon after the event. In these images, landslides are easily recognizable due to the removal of material and soil exposure (Guzzetti et al. 1999; Du and Teng 2007; Booth, Roering, and Perron 2009; Burns et al. 2010; Sameen and Pradhan 2019). In multispectral images, the soil has a brown-orange colour that contrasts with the surroundings' green colour of vegetation cover, making identification easier for the CNNs, but even in these cases errors and misclassifications are common (Soares et al. 2022).

These findings are essential to demonstrate that the accuracy of CNNs for landslide detection is closely related to the technical specificities of the input data, availability of labelled landslide data and the study area characteristics, instead of the CNN's semantic segmentation process itself. To the best of the authors' knowledge, this is the first project that uses CBERS4A images for landslide detection. The mid- to high-spatial resolution (8 m) and four spectral bands (R, G, B and NIR) were insufficient to accurately differentiate relict landslides from their surroundings. Despite adequate results of recall for all combinations ($\geq$ 75%) and that 18 of 42 predictions correctly identified relict landslides, the majority of the results were inaccurate.

In addition, a new CNN framework was proposed in an attempt to enhance landslide detection accuracy. The results demonstrate that the predictions of the proposed framework are better than those of the standard framework, although the values of precision and recall were quite similar. The k-means clustering process used to create the cluster dataset for the pre-training step computed weights to fine-tune the CNN training process, enhancing its prediction ability. Another finding is that it was not possible to address an optimal correlation of parameters that maximizes the accuracy of landslide detection (Section 3).

Most landslide detection studies are in areas partially covered with vegetation and focus on detecting recent landslides using post-event multispectral images when the landslides are clearly visible in the landscape (Chen et al. 2018; Ghorbanzadeh et al. 2019; Ji et al. 2020; Li et al. 2021). Few studies occur in areas covered with rainforest vegetation (Sameen and Pradhan 2019; Soares et al. 2022) or for detecting relict landslides (Wang et al. 2020). Also, many studies use a combination of topographic and spectral information as input for the CNNs, which achieved worse results than using only spectral bands as input (Ghorbanzadeh et al. 2019; Ji et al. 2020; Sameen and Pradhan 2019; Wang et al. 2020; Soares et al. 2022).

Thus, there is a lack of investigation in areas of tropical environments where landslides are common, and the monitoring is impaired by vegetation growth. The present study findings demonstrated the complexity of performing semi-automatic detection of relict landslides in rainforest areas using only multispectral imagery and highlighted the importance of the input data specifications for the CNN models. It also showed the relevance of a continuous update of inventory maps that increases labelled landslide data, which may improve CNN landslide detection accuracy.

This study has several specificities that prevent directly comparing the results with other works. However, many studies of landslide detection using CNNs also showed that both the input data and the study area are directly related to model accuracy (Chen et al. 2018; Ghorbanzadeh et al. 2019; Wang et al. 2020; Yu et al. 2021; Soares et al. 2022). The CBERS4A multispectral images are the newer and best free data available for the mapping and monitoring of the Brazilian territory. Despite the great advances promoted in the area

of remote sensing for Brazil, the CBERS4A images were inappropriate for the detection of relict landslides in the specific conditions of this project. Nonetheless, they may be very useful and yield better results if used for recent landslide detection with images taken soon after the event.

Although the results were generally inaccurate and the limitations of using multispectral images for relict landslide detection were exposed, the proposed framework had interesting results mainly from landslide predictions that outperformed the standard framework results. Even with all the limitations addressed previously, the CNN proposed framework could correctly predict relict landslides more or less accurately in almost half of the combinations (41.7%) and achieved recall values higher than 75% for every combination. The low precision values ($\leq$ 20%) are related to the high rate of false-positive samples predicted by the CNNs, but this is not necessarily inappropriate since it is suitable for relict landslide detection studies to predict more landslides than occur in the ground truth (Section 3).

4. Conclusion

This work proposed a new CNN framework for semi-automatic relict landslide detection using CBERS4A multispectral imagery, and the results were compared with a standard CNN framework. The proposed framework is an attempt to improve CNN image segmentation ability and consequently its accuracy by using transfer learning. It is composed of a pre-training step that uses a dataset generated by a k-means algorithm clustering process as input. The weights computed in the pre-training step are later used to fine-tune the CNN training process. Two augmentation factors of 30 and 50 were used to increase the dataset since labelled landslide data are sparse for the study area, and three CNNs (U-Net, Linknet and FPN) were used for image segmentation. Six combinations of CNN and parameters were generated for the standard framework and 36 combinations for the proposed framework.

The validation indices showed that the results of recall were $\geq$ 75% for every combination and the precision results were generally between 10% and 20%. For the standard framework, the higher recall value was 79.53% (Unet/LD30) and the higher precision was 15.83% (Unet/LD50) while for the proposed framework the higher values were 81.09% (Linknet/4/LD50) for recall and 20.47% (FPN/8/LD30) for precision.

Predictions of the landslides for each combination tested were performed in a test area to enhance the evaluation process by visual interpretation of the relict landslides. Eighteen of 42 total combinations were able to correctly identify relict landslides more or less accurately. Predictions from the proposed framework were more accurate, but they still showed many misclassifications, mainly because of the number of false-positive samples. FPN was the more conservative model with less FP samples while U-Net and Linknet were less conservative and predicted more FP samples. In landslide detection studies, less conservative prediction models are adequate, since it is expected to detect more landslides than occur in ground truth and, thus, allow the detection of new landslides.

Therefore, despite the recall and precision results were very similar for both frameworks, the predictions of the proposed framework were more accurate for the detection of relict landslides in the study area. The results of validation indices and landslide predictions also demonstrate that there is not an optimal correlation of parameters (type of CNN, number of clusters, augmentation factor), which increases the difficulties

for the detection of relict landslides since the higher recall/precision values are not necessarily the most accurate in predicting relict landslides.

Further investigation is needed to improve the proposed framework's accuracy, and the authors expect better results in areas with more visible landslides or using this framework for the detection of recent landslides. To improve the detection of relict landslides, it is expected that using high to very high spatial resolution multispectral images, or even hyperspectral images, may overcome the limitations found in this study. It is also worth testing if using DTMs from VHR topographic data as a single band, or as an additional band to RGB input data, in the CNN training process could enhance the accuracy of the models for relict landslide detection since DTMs do not contain the vegetation cover.

Acknowledgements

The authors acknowledge the support provided by the Institute of Energy and Environment, the Institute of Geosciences and the Graduate Programme in Mineral Resources and Hydrogeology (PPG-RMH). Acknowledgements are extended to the Guest Editors, the Editor-in-Chief and the anonymous reviewers for their criticism and suggestions, which have helped to improve this paper.

Data availability statement

The code used in this research is available at the following link: https://github.com/SPAMLab/data_sharing/tree/main/Relict_landslides_CNN_kmeans (accessed on 15 December 2022).

Disclosure statement

No potential conflict of interest was reported by the authors.

Funding

This study was supported by the Sao Paulo Research Foundation (FAPESP) under grants #2016/06628-0, #2019/26568-0 and by Brazil's National Council of Scientific and Technological Development, CNPq grant #311209/2021-1 to C.H.G. This study was financed in part by CAPES Brasil - Finance Code 001.

ORCID

G. P. B. Garcia http://orcid.org/0000-0003-1209-7842
L. P. Soares http://orcid.org/0000-0002-6980-597X
M. Espadoto http://orcid.org/0000-0002-1922-4309
C. H. Grohmann http://orcid.org/0000-0001-5073-5572

References

Almeida, F. F. M. 1964. "Fundamentos geológicos do relevo paulista." *Boletim do IGG* 41: 169–263.
Ardizzone, F., M. Cardinali, M. Galli, F. Guzzetti, and P. Reichenbach. 2007. "Identification and Mapping of Recent Rainfall-Induced Landslides Using Elevation Data Collected by Airborne Lidar." *Natural Hazards and Earth System Science* 7 (6): 637–650. doi:10.5194/nhess-7-637-2007.

Audebert, N., B. Le Saux, and S. Lefèvre. 2016. "How Useful is Region-Based Classification of Remote Sensing Images in a Deep Learning Framework?" *International Geoscience and Remote Sensing Symposium (IGARSS)* 2016-November, Beijing, 5091–5094.

Augusto Filho, O. 1992. "Caracterização geológico-geotécnica voltada à estabilização de encostas: uma proposta metodológica." In *conferência brasileira sobre estabilidade de encostas*, Rio de Janeiro, Vol. 1, 721–733.

Bai, Y., X. Sun, Y. Ji, J. Huang, W. Fu, and H. Shi. 2022. "Bibliometric and Visualized Analysis of Deep Learning in Remote Sensing." *International Journal of Remote Sensing* 43: 5534–5571. doi:10.1080/01431161.2021.1949069.

Baldo, M., C. Bicocchi, U. Chiocchini, D. Giordan, and G. Lollino. 2009. "LIDAR Monitoring of Mass Wasting Processes: The Radicofani Landslide, Province of Siena, Central Italy." *Geomorphology* 105 (3–4): 193–201. doi:10.1016/j.geomorph.2008.09.015.

Booth, A. M., J. J. Roering, and J. T. Perron. 2009. "Automated Landslide Mapping Using Spectral Analysis and High-Resolution Topographic Data: Puget Sound Lowlands, Washington, and Portland Hills, Oregon." *Geomorphology* 109 (3–4): 132–147. doi:10.1016/j.geomorph.2009.02.027.

Burns, W. J., J. A. Coe, B. Sener Kaya, and L. Ma. 2010. "Analysis of Elevation Changes Detected from Multi-Temporal LiDar Surveys in Forested Landslide Terrain in Western Oregon." *Environmental & Engineering Geoscience* 16 (4): 315–341. doi:10.2113/gseegeosci.16.4.315.

Burns, W. J., and I. P. Madin. 2009. "Protocol for Inventory Mapping of Landslide Deposits from Light Detection and Ranging (Lidar) Imagery." 1–36.

Castelluccio, M., G. Poggi, C. Sansone, and L. Verdoliva. 2015. *Land Use Classification in Remote Sensing Images by Convolutional Neural Networks*, 1–11. http://arxiv.org/abs/1508.00092.

Chaurasia, A., and E. Culurciello. 2017. "LinkNet: Exploiting Encoder Representations for Efficient Semantic Segmentation." In *IEEE Visual Communications and Image Processing (VCIP)*, St. Petersburg, FL, USA, 4.

Cheng, G., J. Han, and X. Lu. 2017. "Remote Sensing Image Scene Classification: Benchmark and State of the Art." *Proceedings of the IEEE* 105 (10): 1865–1883. doi:10.1109/JPROC.2017.2675998.

Cheng, G., C. Yang, X. Yao, L. Guo, and J. Han. 2018. "When Deep Learning Meets Metric Learning: Remote Sensing Image Scene Classification via Learning Discriminative CNNs." *IEEE Transactions on Geoscience and Remote Sensing* 56 (5): 2811–2821. doi:10.1109/TGRS.2017.2783902.

Chen, W., X. Li, Y. Wang, and S. Liu. 2013. "Landslide Susceptibility Mapping Using LiDar and DMC Data: A Case Study in the Three Gorges Area, China." *Environmental Earth Sciences* 70 (2): 673–685. doi:10.1007/s12665-012-2151-8.

Chen, Z., Y. Zhang, C. Ouyang, F. Zhang, and J. Ma. 2018. "Automated Landslides Detection for Mountain Cities Using Multi-Temporal Remote Sensing Imagery." *Sensors* 18 (821): 18. doi:10.3390/s18030821.

Conti, J. B., and S. A. Furlan. 1996. *Geoecologia: o clima, os solos e a biota*. São Paulo: EDUSP.

Correa, C. V. D. S., F. Augusto Gomes Vieira Reis, L. Carmo Giordano, C. Jardinetti Chaves, B. Marquez Gabelini, and R. Irineu Cerri. 2017. "Movimentos de massa na região de Caraguatatuba e São Sebastião (SP) entre 1967 e 2011: utilização de cicatrizes de escorregamento como subsídio a estudos de retro-análise." In *XVII Simpósio Brasileiro de Geografia Física Aplicada/I Congresso Nacional de Geografia Física*, Campinas, 4162–4173.

Devoto, S., V. Macovaz, M. Mantovani, M. Soldati, and S. Furlani. 2020. "Advantages of Using UAV Digital Photogrammetry in the Study of Slow-Moving Coastal Landslides." *Remote Sensing* 12 (21): 3566–3594. doi:10.3390/rs12213566.

Dewitte, O., and A. Demoulin. 2005. "Morphometry and Kinematics of Landslides Inferred from Precise DTMs in West Belgium." *Natural Hazards and Earth System Sciences* 5: 259–265. doi:10.5194/nhess-5-259-2005.

Dias, H. C., D. Hölbling, and C. H. Grohmann. 2021. "Landslide Susceptibility Mapping in Brazil: A Review." *Geosciences* 11: 425. doi:10.3390/geosciences11100425.

Ding, A., Q. Zhang, X. Zhou, and B. Dai. 2016. "Automatic Recognition of Landslide Based on CNN and Texture Change Detection." In *31st Youth Academic Annual Conference of Chinese Association of Automation*, Wuhan, China, 444–448.

Du, J. C., and H. C. Teng. 2007. "3D Laser Scanning and GPS Technology for Landslide Earthwork Volume Estimation." *Automation in Construction* 16 (5): 657–663. doi:10.1016/j.autcon.2006.11.002.

Ellenberg, H., and D. M. Dombois. 1967. "A Key to Raunkiaer Plant Life Forms with Revised Subdivisions." *Berlin Geobotanical Institute ETH, Stiftung* 37: 56–73.

Fiori, A. P., and L. Carmignani. 2015. *Fundamentos de mecânica dos solos e das rochas: aplicações na estabilidade de taludes*. 3rd ed. São Paulo: Oficina dos Textos.

Fúlfaro, V. J., W. L. Ponçano, C. A. Bistrichi, and D. P. Stein. 1976. "Escorregamentos de Caraguatatuba: expressão atual, e registro na coluna sedimentar da plancie costeira adjacente." In *Congresso brasileiro de geologia de engenharia*, Rio de Janeiro, Vol. 2, 341–350.

Gariano, S. L., and F. Guzzetti. 2016. "Landslides in a Changing Climate." *Earth-Science Reviews* 162: 227–252. doi:10.1016/j.earscirev.2016.08.011.

Ghorbanzadeh, O., T. Blaschke, K. Gholamnia, S. R. Meena, D. Tiede, and J. Aryal. 2019. "Evaluation of Different Machine Learning Methods and Deep-Learning Convolutional Neural Networks for Landslide Detection." *Remote Sensing* 11 (196): 21. doi:10.3390/rs11020196.

Glenn, N. F., D. R. Streutker, D. J. Chadwick, G. D. Thackray, and S. J. Dorsch. 2006. "Analysis of LiDar-Derived Topographic Information for Characterizing and Differentiating Landslide Morphology and Activity." *Geomorphology* 73 (1–2): 131–148. doi:10.1016/j.geomorph.2005.07.006.

Godone, D., P. Allasia, L. Borrelli, and G. Gulla. 2020. "UAV and Structure from Motion Approach to Monitor the Maierato Landslide Evolution." *Remote Sensing* 12 (6): 1039–1057. doi:10.3390/rs12061039.

Guidicini, G., and C. M. Nieble. 1984. *Estabilidade de Taludes Naturais e de Escavação*, edited by Edgard Blücher,*2nd* ed. São Paulo.

Guth, P. L., A. Van Niekerk, C. H. Grohmann, J. -P. Muller, L. Hawker, I. V. Florinsky, D. Gesch, et al. 2021. "Digital Elevation Models: Terminology and Definitions." *Remote Sensing* 13 (18): 3581. doi:10.3390/rs13183581.

Guzzetti, F., A. Carrara, M. Cardinali, and P. Reichenbach. 1999. "Landslide Hazard Evaluation: A Review of Current Techniques and Their Application in a Multi-Scale Study, Central Italy." *Geomorphology* 31 (1–4): 181–216. doi:10.1016/S0169-555X(99)00078-1.

Guzzetti, F., A. Cesare Mondini, M. Cardinali, F. Fiorucci, M. Santangelo, and K. Tsung Chang. 2012. "Landslide Inventory Maps: New Tools for an Old Problem." *Earth-Science Reviews* 112 (1–2): 42–66. doi:10.1016/j.earscirev.2012.02.001.

He, K., X. Zhang, S. Ren, and J. Sun. 2016. "Deep Residual Learning for Image Recognition." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, 2016. 770–778.

Hoeser, T., and C. Kuenzer. 2020. "Object Detection and Image Segmentation with Deep Learning on Earth Observation Data: A Review-Part I: Evolution and Recent Trends." *Remote Sensing* 12: 1667. doi:10.3390/rs12101667.

Huang, G., Z. Liu, L. Van Der Maaten, and K. Q. Weinberger. 2017. "Densely Connected Convolutional Networks." In *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Los Alamitos, CA, USA, jul, 2261–2269. IEEE Computer Society. doi:10.1109/CVPR.2017.243.

Jaboyedoff, M., T. Oppikofer, A. Abellán, M. Henri Derron, A. Loye, R. Metzger, and A. Pedrazzini. 2012. "Use of LIDAR in Landslide Investigations: A Review." *Natural Hazards* 61 (1): 5–28. doi:10.1007/s11069-010-9634-2.

Jebur, M. N., B. Pradhan, and M. S. Tehrany. 2014. "Optimization of Landslide Conditioning Factors Using Very High-Resolution Airborne Laser Scanning (LiDar) Data at Catchment Scale." *Remote Sensing of Environment* 152: 150–165. doi:10.1016/j.rse.2014.05.013.

Ji, S., D. Yu, C. Shen, and Q. Xu. 2020. "Landslide Detection from an Open Satellite Imagery and Digital Elevation Model Dataset Using Attention Boosted Convolutional Neural Networks." *Landslides* 17: 1337–1352. doi:10.1007/s10346-020-01353-2.

Kasai, M., M. Ikeda, T. Asahina, and K. Fujisawa. 2009. "LiDar-Derived DEM Evaluation of Deep-Seated Landslides in a Steep and Rocky Region of Japan." *Geomorphology* 113 (1–2): 57–69. doi:10.1016/j.geomorph.2009.06.004.

Knevels, R., H. Petschko, P. Leopold, and A. Brenning. 2019. "Geographic Object-Based Image Analysis for Automated Landslide Detection Using Open Source GIS Software." *International Journal of Geo-Information* 8 (551): 21. doi:10.3390/ijgi8120551.

Koeppen, W. 1948. "Climatologia: con un estudio de los climas de la tierra." 478 p.

Krizhevsky, A., I. Sutskever, and G. E. Hinton. 2012. "ImageNet Classification with Deep Convolutional Neural Networks." *Advances in Neural Information Processing Systems 25 (NIPS 2012)*, Lake Tahoe, 1097–1105.

Kronka, F., Nalon, M. A., Matskuma, C. K., Ywane, M. S. S.-I., Kanashiro, M. M., Lima, L. M. P. R., Durigan, G., Guillaumon, J. R., Baitello, J. B., Monteiro, C. H. B., Pontinhas, A. A. S., Borgo, S. C. 2007. *Inventario florestal da vegetacao natural do Estado de Sao Paulo. Regioes administrativas de Sao Jose dos Campos (Litoral, Baixada Santista e Registro)*, 140. São Paulo: Instituto Florestal.

Kussul, N., M. Lavreniuk, S. Skakun, and A. Shelestov. 2017. "Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data." *IEEE Geoscience and Remote Sensing Letters* 14 (5): 778–782. doi:10.1109/LGRS.2017.2681128.

Lehmann, D. R. M. 2008. "Estudos Sobre a Propagação De Gleichenella Pectinata (Willd.) Ching (Pteridófita - Gleicheniaceae)." Dissertação de Mestrado.

Lindner, G., K. Schraml, R. Mansberger, and J. Hubl. 2016. "UAV Monitoring and Documentation of a Large Landslide." *Applied Geomatics* 8: 1–11. doi:10.1007/s12518-015-0165-0.

Lin, T.Y., P. Dollar, R. Girshick, K. He, B. Harihraran, and S. Belongie. 2017. "Feature Pyramid Networks for Object Detection." In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, 2117–2125.

Liu, J.K., K.T. Chang, J.Y. Rau, W.C. Hsu, Z.Y. Liao, C.C. Lau, and T.Y. Shih. 2009. "The Geomorphometry of Rainfall-Induced Landslides in Taiwan Obtained by Airborne Lidar and Digital Photography." In *Geoscience and Remote Sensing*, edited by Ho, P.-G, Garching Bei München: InTech. doi:10.5772/8305.

Liu, B., X. Yu, A. Yu, and G. Wan. 2018. "Deep Convolutional Recurrent Neural Network with Transfer Learning for Hyperspectral Image Classification." *Journal of Applied Remote Sensing* 12: 1. doi:10.1117/1.JRS.12.026028.

Li, S., L. Xiong, G. Tang, and J. Strobl. 2020. "Deep Learning-Based Approach for Landform Classification from Integrated Data Sources of Digital Elevation Model and Imagery." *Geomorphology* 354: 1–14. doi:10.1016/j.geomorph.2020.107045.

Li, C., B. Yi, P. Gao, H. Li, J. Sun, X. Chen, and C. Zhong. 2021. "Valuable Clues for DCNN-Based Landslide Detection from a Comparative Assessment in the Wenchuan Earthquake Area." *Sensors* 21 (15): 14. doi:10.3390/s21155191.

Lucieer, A., S. M. de Jong, and D. Turner. 2014. "Mapping Landslide Displacements Using Structure from Motion (SfM) and Image Correlation of Multi-Temporal UAV Photography." *Progress in Physical Geography* 38 (1): 97–116. doi:10.1177/0309133313515293.

Luus, F. P. S., B. P. Salmon, F. van den Bergh, and B. T. J. Maharaj. 2015. "Multiview Deep Learning for Land-Use Classification." *IEEE Geoscience and Remote Sensing Letters* 12 (12): 2448–2452. doi:10.1109/LGRS.2015.2483680.

Ma, L., Y. Liu, X. Zhang, Y. Yuanxin, G. Yin, and B. Alan Johnson. 2019. "Deep Learning in Remote Sensing Applications: A Meta-Analysis and Review." *ISPRS Journal of Photogrammetry and Remote Sensing* 152 (November 2018): 166–177. doi:10.1016/j.isprsjprs.2019.04.015.

Mantovani, F., R. Soeters, and C. J. V. Westen. 1996. "Remote Sensing Techniques for Landslide Studies and Hazard Zonation in Europe." *Geomorphology* 15: 213–225. doi:10.1016/0169-555X(95)00071-C.

Maxwell, A. E., T. A. Warner, and F. Fang. 2018. "Implementation of Machine-Learning Classification in Remote Sensing: An Applied Review." *International Journal of Remote Sensing* 39 (9): 2784–2817. doi:10.1080/01431161.2018.1433343.

McKean, J., and J. Roering. 2004. "Objective Landslide Detection and Surface Morphology Mapping Using High-Resolution Airborne Laser Altimetry." *Geomorphology* 57 (3–4): 331–351. doi:10.1016/S0169-555X(03)00164-8.

Meena, S. R., L. Pedrosa Soares, C. H. Grohmann, C. van Westen, K. Bhuyan, R. P. Singh, M. Floris, and F. Catani. 2022. "Landslide Detection in the Himalayas Using Machine Learning Algorithms and U-Net." *Landslides* 19: 19. doi:10.1007/s10346-022-01861-3.

Menegoni, N., D. Giordan, and C. Perotti. 2020. "Reliability and Uncertainties of the Analysis of an Unstable Rock Slope Performed on RPAS Digital Outcrop Models: The Case of the Gallivaggio Landslide (Western Alps, Italy)." *Remote Sensing* 12 (10): 1635–1660. doi:10.3390/rs12101635.

Metternicht, G., L. Hurni, and R. Gogu. 2005. "Remote Sensing of Landslides: An Analysis of the Potential Contribution to Geo-Spatial Systems for Hazard Assessment in Mountainous Environments." *Remote Sensing of Environment* 98 (2–3): 284–303. doi:10.1016/j.rse.2005.08.004.

Mozas-Calvache, A. T., J. L. Pérez-Garcia, and T. Fernandez-Del Castillo. 2017. "Monitoring of Landslides Displacements Using UAS and Control Methods Based on Lines." *Landslides* 14: 2115–2128. doi:10.1007/s10346-017-0842-7.

Netto, A. L. C., A. M. Sato, A. S. Avelar, L. G. G. Vianna, I. S. Araújo, D. L. C. Ferreira, P. H. Lima, A. P. A. Silva, and R. P. Silva. 2011. "January 2011: The Extreme Landslide Disaster in Brazil." In *Proceedings of the 2nd Worl landslide Forum*, Rome, 6.

Niethammer, U., M. R. J. Sabrina Rothmund, J. Travelletti, and M. Joswig. 2010. "UAV-Based Remote Sensing of Landslides." *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* XXXVIII: 496–501.

Nilsen, T. H., and E. E. Brabb. 1973. "Current Slope Stability Studies in the San Francisco Bay Region." *Journal Research US Geological Survey* 1 (4): 431–437.

Nohani, E., M. Moharrami, S. Sharafi, K. Khosravi, B. Pradhan, B. Thai Pham, S. Lee, and A. M. Melesse. 2019. "Landslide Susceptibility Mapping Using Different GIS-Based Bivariate Models." *Water* 11 (1402): 1–22. doi:10.3390/w11071402.

Pal, M., and M. Mather. 2006. "Support Vector Machines for Classification in Remote Sensing." *International Journal of Remote Sensing* 26 (5): 1007–1011. doi:10.1080/01431160512331314083.

Pedrazzini, A., A. Abellán, T. Oppikofer, C. Ambrosi, A. Spataro, and M. Jaboyedoff. 2010. "Retrogressive Landslide Monitoring by TLS: Precursory Displacements and Final Collapse. Case Study at Val Canaria (Ticino, Switzerland)." *Geophysical Research Abstracts, EGU General Assembly 2010* 12. http://meetingorganizer.copernicus.org/EGU2010/EGU2010-12160.pdf.

Pedregosa, F., G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, et al. 2011. "Scikit-Learn: Machine Learning in Python." *Journal of Machine Learning Research* 12: 2825–2830.

Perrota, M. M., E. D. Salvador, R. C. Lopes, L. Z. D'agostino, N. Peruffo, S. D. Gomes, L. L. B. Sachs, V. T. Meira, M. G. M. Garcia, and J. V. Lacerda Filho. 2005. *Mapa Geológico do Estado de São Paulo*. Technical Report. São Paulo, Brasil: CPRM.

Petropoulos, G. P., C. Kalaitzidis, and K. Prasad Vadrevu. 2012. "Support Vector Machines and Object-Based Classification for Obtaining Land-Use/cover Cartography from Hyperion Hyperspectral Imagery." *Computers & Geosciences* 41: 99–107. doi:10.1016/j.cageo.2011.08.019.

Ponçano, W. L. 1981. *Mapa geomorfológico do estado de São Paulo*. Vol. 1. Divisão de Minas: Instituto de Pesquisas Tecnológicas do Estado de São Paulo.

Portela, V. D. A. 2014. "Avaliação da vegetação como indicadora de areas suscetiveis a escorregamentos na Serra do Mar em Caraguatatuba (SP). áreas suscetíveis a escorregamentos na Serra do Mar em Caraguatatuba (SP) Viviane Dias Alves Portela Avaliação da vegetação como indicad." Dissertação de mestrado.

Prakash, N., A. Manconi, and S. Loew. 2020. "Mapping Landslides on EO Data: Performance of Deep Learning Vs. Traditional Machine Learning Models." *Remote Sensing* 12 (346): 24. doi:10.3390/rs12030346.

Roering, J. J., J. W. Kirchner, and W. E. Dietrich. 2005. "Characterizing Structural and Lithologic Controls on Deep-Seated Landsliding: Implications for Topographic Relief and Landscape Evolution in the Oregon Coast Range, USA." *Geological Society of America Bulletin* 117: 654–668. doi:10.1130/B25567.1.

Roering, J. J., B. H. Mackey, J. A. Marshall, K. E. Sweeney, N. I. Deligne, A. M. Booth, A. L. Handwerger, and C. Cerovski-Darriau. 2013. ""You are HERE': Connecting the Dots with Airborne Lidar for Geomorphic Fieldwork." *Geomorphology* 200: 172–183. doi:10.1016/j.geomorph.2013.04.009.

Ronneberger, O., P. Fischer, and T. Brox. 2015. "U-Net: Convolutional Networks for Biomedical Image Segmentation." Navab, N., Hornegger, J., Wells, W. M., Frangi, A. F.(eds.), Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015: 18th International Conference, Munich, III, 234–241.

Sameen, M. I., and B. Pradhan. 2019. "Landslide Detection Using Residual Networks and the Fusion of Spectral and Topographic Information." *IEEE Access* 7: 114363–114373. doi:10.1109/ACCESS.2019.2935761.

Samodra, G., M. Fauzan Ramadhan, J. Sartohadi, M. Anggri Setiawan, N. Christanto, and A. Sukmawijaya. 2020. "Characterization of Displacement and Internal Structure of Landslides from Multitemporal UAV and ERT Imaging." *Landslides* 17: 2455–2468. doi:10.1007/s10346-020-01428-0.

Scaioni, M., L. Longoni, V. Melillo, and M. Papini. 2014. "Remote Sensing for Landslide Investigations: An Overview of Recent Achievements and Perspectives." *Remote Sensing* 6: 53. doi:10.3390/rs6109600.

Schulz, W. H. 2007. "Landslide Susceptibility Revealed by LIDAR Imagery and Historical Records, Seattle, Washington." *Engineering Geology* 89 (1–2): 67–87. doi:10.1016/j.enggeo.2006.09.019.

Schulz, W. H., J. B. Smith, G. Wang, Y. Jiang, and J. J. Roering. 2018. "Clayey Landslide Initiation and Acceleration Strongly Modulated by Soil Swelling." *Geophysical Research Letters* 45: 1888–1896. doi:10.1002/2017GL076807.

Scott, G. J., M. R. England, W. A. Starms, R. A. Marcum, and C. H. Davis. 2017. "Training Deep Convolutional Neural Networks for Land-Cover Classification of High-Resolution Imagery." *IEEE Geoscience and Remote Sensing Letters* 14 (4): 549–553. doi:10.1109/LGRS.2017.2657778.

Shahabi, H., and M. Hashim. 2015. "Landslide Susceptibility Mapping Using GIS-Based Statistical Models and Remote Sensing Data in Tropical Environment." *Scientific Reports* 5 (9899): 15. doi:10.1038/srep09899.

Soares, L. P., H. Cristina Dias, G. Pereira Bento Garcia, and C. Henrique Grohmann. 2022. "Landslide Segmentation with Deep Learning: Evaluating Model Generalization in Rainfall-Induced Landslides in Brazil." *Remote Sensing* 14: 2237. doi:10.3390/rs14092237.

Summerfield, M. A. 1991. *Global Geomorphology*. 1st ed. Edinburgh: Pearson Education Limited.

Tominaga, L. K., J. Santoro, and R. Do Amaral. 2009. *Desastres naturais: conhecer para prevenir*. São Paulo: Instituto geológico.

Turner, D., A. Lucieer, and S. M. de Jong. 2015. "Time Series Analysis of Landslide Dynamics Using an Unmanned Aerial Vehicle (UAV)." *Remote Sensing* 7: 1736–1757. doi:10.3390/rs70201736.

UNISDR. 2015. *Sendai Framework for Disaster Risk Reduction 2015-2030*. Technical Report. Geneva, Switzerland: The United Nations Office for Disaster Risk Reduction.

Van Den Eeckhaut, M., N. Kerle, J. Poesen, and J. Herv?s. 2012. "Object-Oriented Identification of Forested Landslides with Derivatives of Single Pulse LiDar Data." *Geomorphology* 173-174: 30–42. doi:10.1016/j.geomorph.2012.05.024.

Van Den Eeckhaut, M., J. Poesen, G. Verstraeten, V. Vanacker, J. Moeyersons, J. Nyssen, and L. P. H. van Beek. 2005. "The Effectiveness of Hillshade Maps and Expert Knowledge in Mapping Old Deep-Seated Landslides." *Geomorphology* 67 (3–4): 351–363. doi:10.1016/j.geomorph.2004.11.001.

Van Den Eeckhaut, M., J. Poesen, G. Verstraeten, V. Vanacker, J. Nyssen, J. Moeyersons, L. P. H. van Beek, and L. Vandekerckhove. 2007. "Use of LIDAR-Derived Images Form Mapping Old Landslides Under Forest." *Earth Surface Processes and Landforms* 32 (5): 754–769. doi:10.1002/esp.1730.

Veloso, H. P., A. L. R. Rangel-Filho, and J. C. A. Lima. 1991. *Classificação da vegetação brasileira, adaptada a um sistema universal*. Rio de Janeiro: IBGE.

Ventura, G., G. Vilardo, C. Terranova, and E. Bellucci Sessa. 2011. "Tracking and Evolution of Complex Active Landslides by Multi-Temporal Airborne LiDar Data: The Montaguto Landslide (Southern Italy)." *Remote Sensing of Environment* 115 (12): 3237–3248. doi:10.1016/j.rse.2011.07.007.

Wang, G., J. Joyce, D. Phillips, R. Shrestha, and W. Carter. 2013. "Delineating and Defining the Boundaries of an Active Landslide in the Rainforest of Puerto Rico Using a Combination of Airborne and Terrestrial LIDAR Data." *Landslides* 10 (4): 503–513. doi:10.1007/s10346-013-0400-x.

Wang, H., L. Zhang, K. Yin, H. Luo, and J. Li. 2020. "Landslide Identification Using Machine Learning." *Geoscience Frontiers* 12: 1–14. doi:10.1016/j.gsf.2020.02.012.

Wolle, C. M. 1988. "Análise de escorregamentos translacionais numa região da Serra do Mar no contexto de uma classificação de mecanismos de instabilização de encostas." Universidade de São Paulo.

Xu, Q., W.L. Li, Y.Z. Ju, X.J. Dong, and D.L. Peng. 2020. "Multitemporal UAV-Based Photogrammetry for Landslide Detection and Monitoring in a Large Area: A Case Study in the Heifangtai Terrace in the Loess Plateau of China." *Journal of Mountain Science* 17: 1826–1839. doi:10.1007/s11629-020-6064-9.

Xu, G., Y. Wang, L. Wang, L. Pedrosa Soares, and C. Henrique Grohmann. 2022. "Feature-Based Constraint Deep CNN Method for Mapping Rainfall-Induced Landslides in Remote Regions with Mountainous Terrain: An Application to Brazil." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 15: 2644–2659. doi:10.1109/JSTARS.2022.3161383.

Yakubovskiy, P. 2019. "Segmentation Models." https://github.com/qubvel/segmentation_models.

Yu, B., F. Chen, C. Xu, L. Wang, and N. Wang. 2021. "Matrix SegNet: A Practical Deep Learning Framework for Landslide Mapping from Images of Different Areas with Different Spatial Resolutions." *Remote Sensing* 13 (3158): 16. doi:10.3390/rs13163158.

Yu, M., Y. Huang, J. Zhou, and L. Mao. 2017. "Modeling of Landslide Topography Based on Micro-Unmanned Aerial Vehicle Photography and Structure-From-Motion." *Environmental Earth Sciences* 76 (520): 9. doi:10.1007/s12665-017-6860-x.

Zhang, L., L. Zhang, and V. Kumar. 2016. "Deep Learning for Remote Sensing Data." *IEEE Geoscience and Remote Sensing Magazine* 4 (2): 22–40. doi:10.1109/MGRS.2016.2540798.

Zhao, W., S. Du, and W. J. Emery. 2017. "Object-Based Convolutional Neural Network for High-Resolution Imagery Classification." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10 (7): 3386–3396. doi:10.1109/JSTARS.2017.2680324.

Zhao, W., Z. Guo, J. Yue, X. Zhang, and L. Luo. 2015. "On Combining Multiscale Deep Learning Features for the Classification of Hyperspectral Remote Sensing Imagery." *International Journal of Remote Sensing* 36 (13): 3368–3379. doi:10.1080/2150704X.2015.1062157.

Zhong, Y., F. Fei, Y. Liu, B. Zhao, H. Jiao, and L. Zhang. 2017. "SatCnn: Satellite Image Dataset Classification Using Agile Convolutional Neural Networks." *Remote Sensing Letters* 8 (2): 136–145. doi:10.1080/2150704X.2016.1235299.

Zhong, L., L. Hu, and H. Zhou. 2019. "Deep Learning Based Multi-Temporal Crop Classification." *Remote Sensing of Environment* 221 (November 2018): 430–443. doi:10.1016/j.rse.2018.11.032.

Supplemental Material - predictions which detected landslides

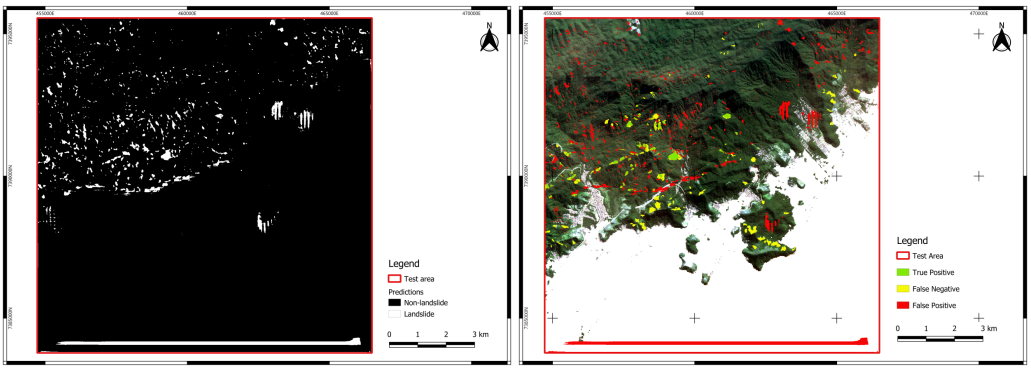

Figure 1. Image of True Positive, False Positive and False Negative samples from the predicitons of Unet with 4 clusters and LD30.

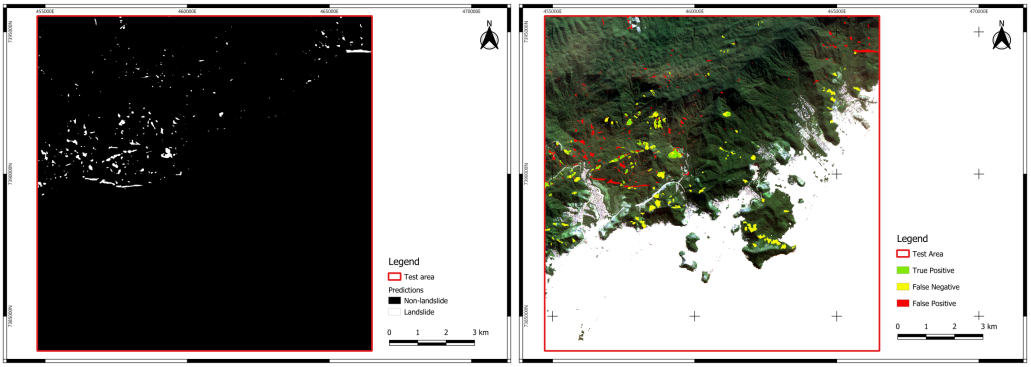

Figure 2. Image of True Positive, False Positive and False Negative samples from the predicitons of Unet with 4 clusters and LD50.

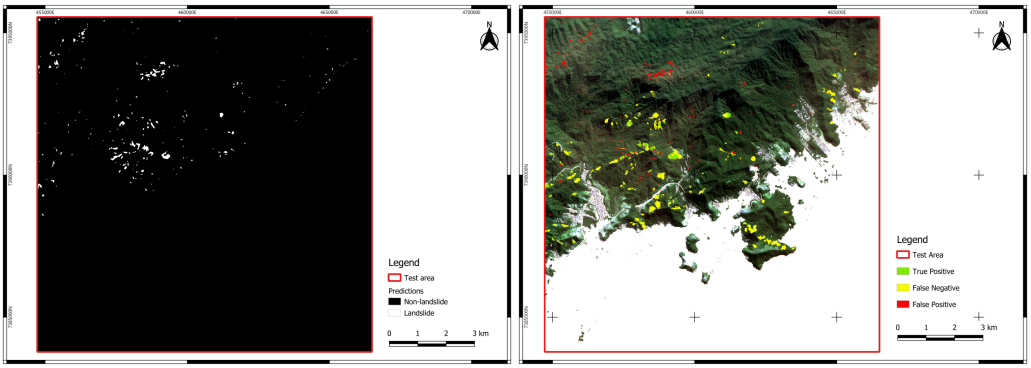

Figure 3. Image of True Positive, False Positive and False Negative samples from the predicitons of Unet with 8 clusters and LD30.

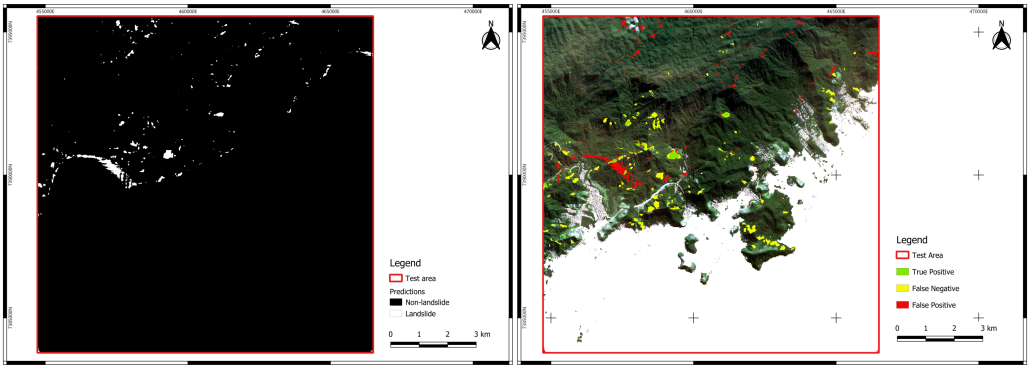

Figure 4. Image of True Positive, False Positive and False Negative samples from the predicitons of Unet with 8 clusters and LD50.

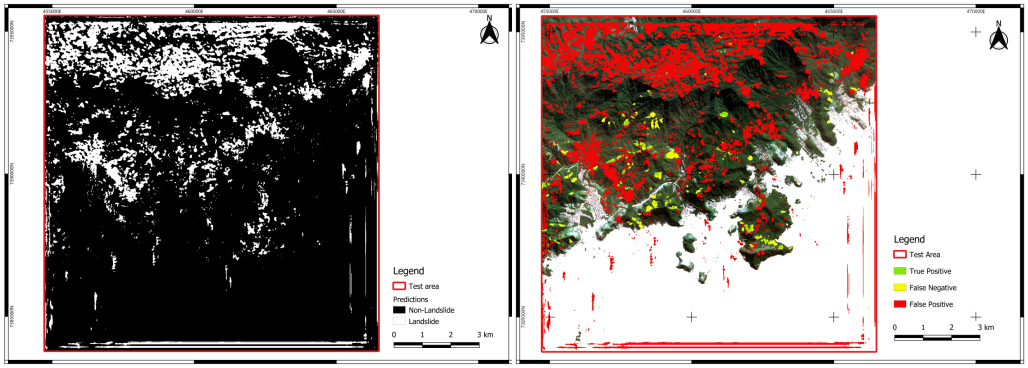

Figure 5. Image of True Positive, False Positive and False Negative samples from the predicitons of standard Unet with LD30.

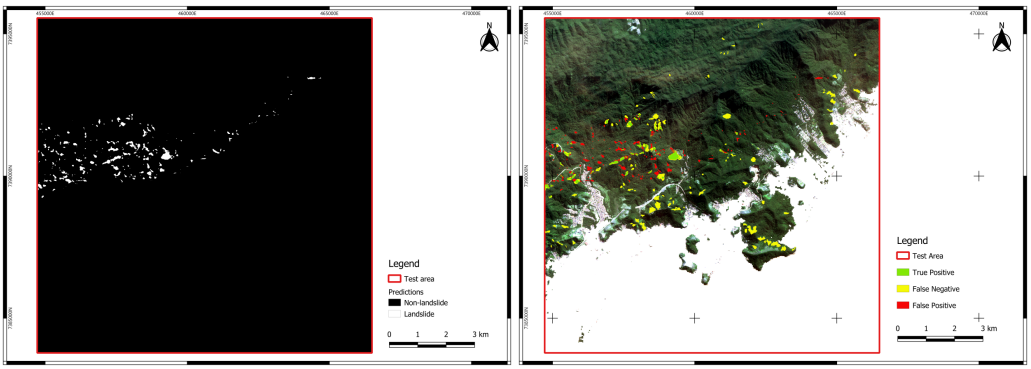

Figure 6. Image of True Positive, False Positive and False Negative samples from the predicitons of Linknet with 4 clusters and LD30.

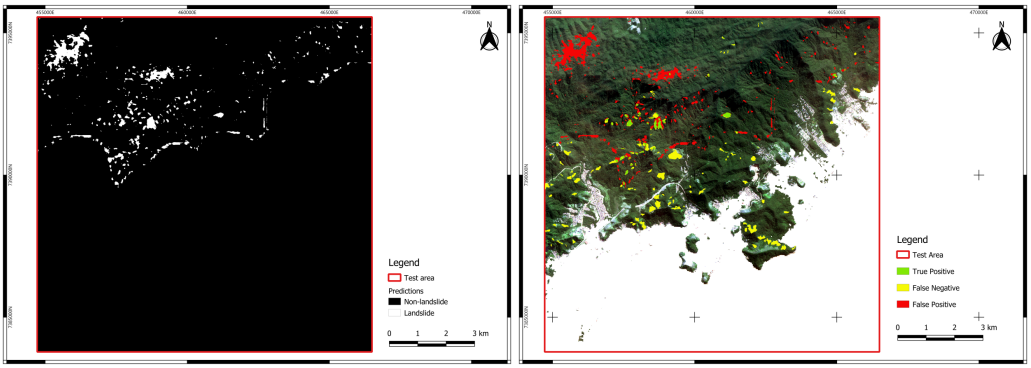

Figure 7. Image of True Positive, False Positive and False Negative samples from the predicitons of Linknet with 4 clusters and LD50.

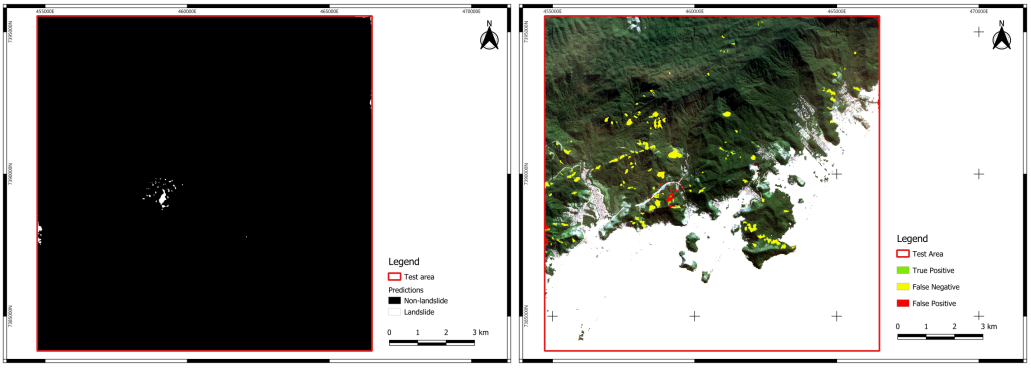

Figure 8. Image of True Positive, False Positive and False Negative samples from the predicitons of Linknet with 6 clusters and LD30.

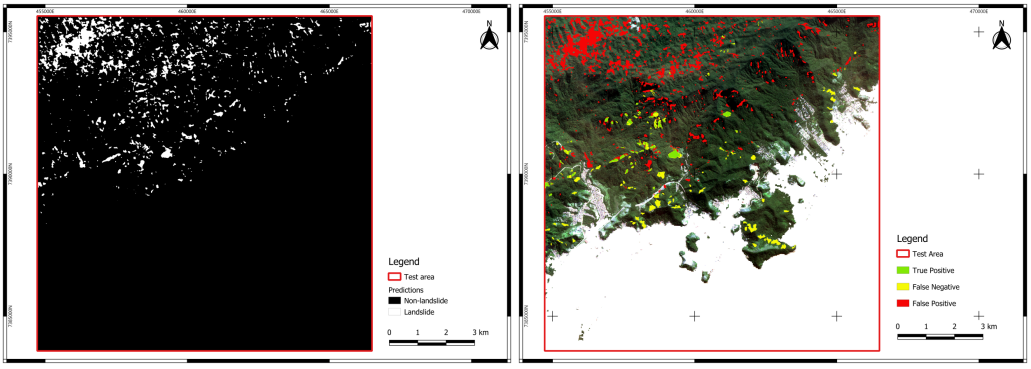

Figure 9. Image of True Positive, False Positive and False Negative samples from the predicitons of Linknet with 8 clusters and LD30.

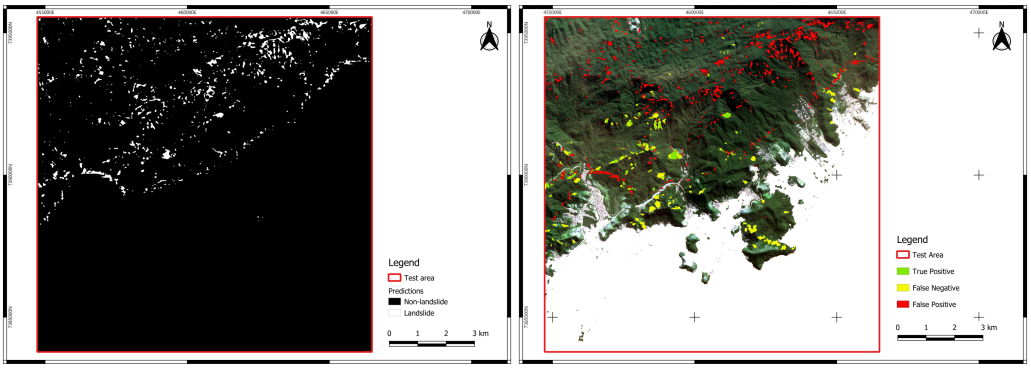

Figure 10. Image of True Positive, False Positive and False Negative samples from the predicitons of Linknet with 8 clusters and LD50.

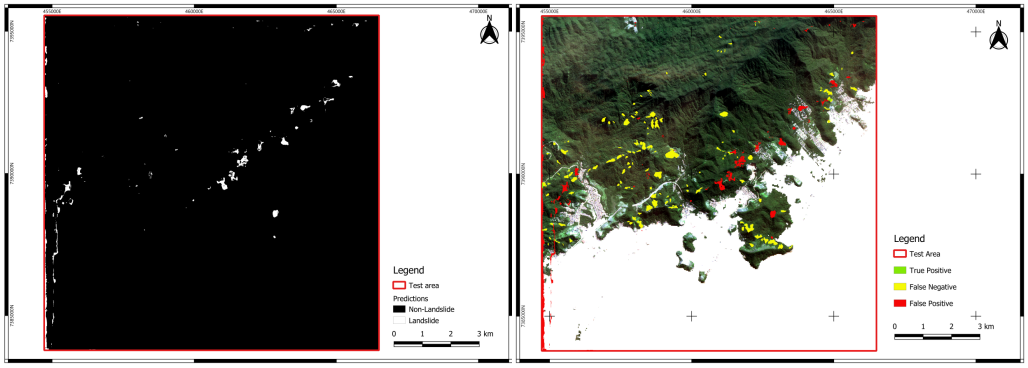

Figure 11. Image of True Positive, False Positive and False Negative samples from the predicitons of standard Linknet with LD30.

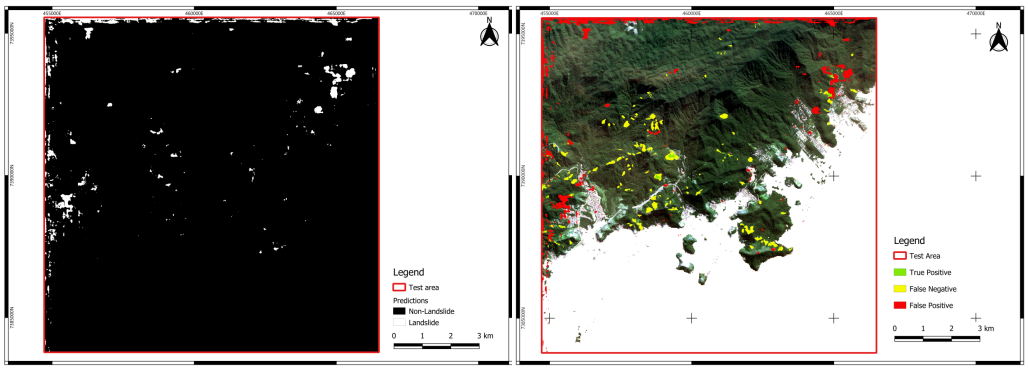

Figure 12. Image of True Positive, False Positive and False Negative samples from the predicitons of standard Linknet with LD50.

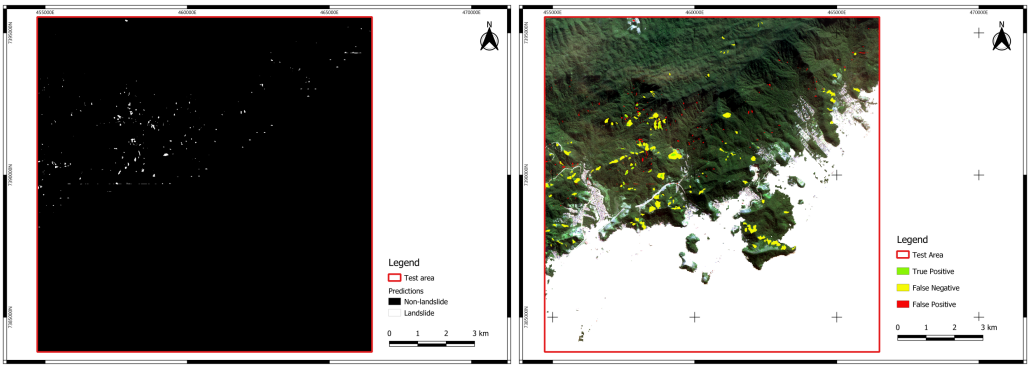

Figure 13. Image of True Positive, False Positive and False Negative samples from the predicitons of FPN with 4 clusters and LD30.

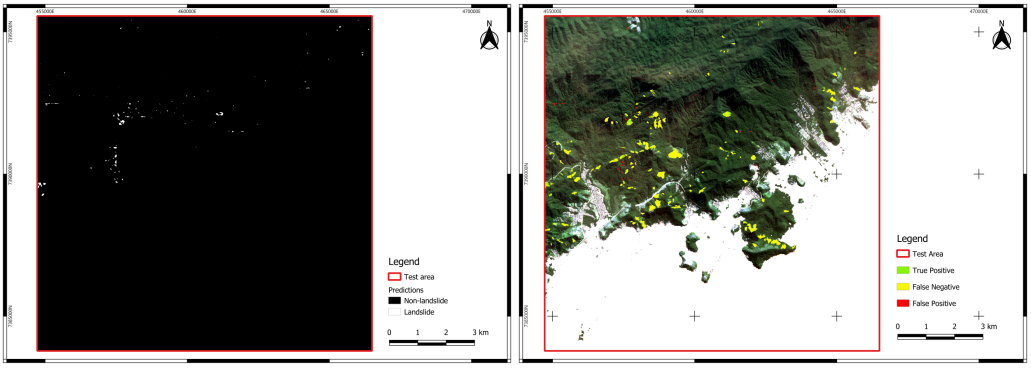

Figure 14. Image of True Positive, False Positive and False Negative samples from the predicitons of FPN with 4 clusters and LD50.

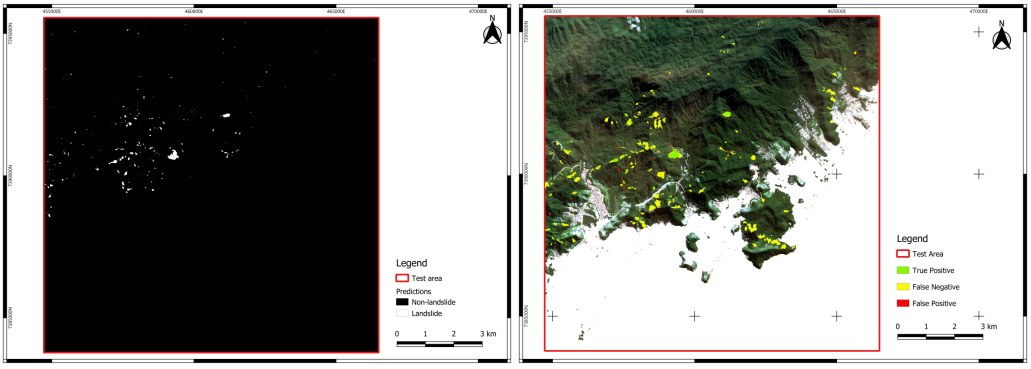

Figure 15. Image of True Positive, False Positive and False Negative samples from the predicitons of FPN with 8 clusters and LD30.

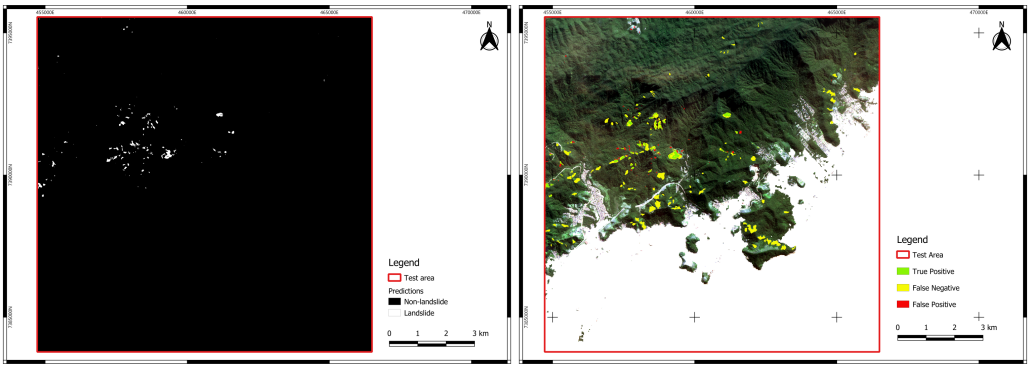

Figure 16. Image of True Positive, False Positive and False Negative samples from the predicitons of FPN with 8 clusters and LD50.

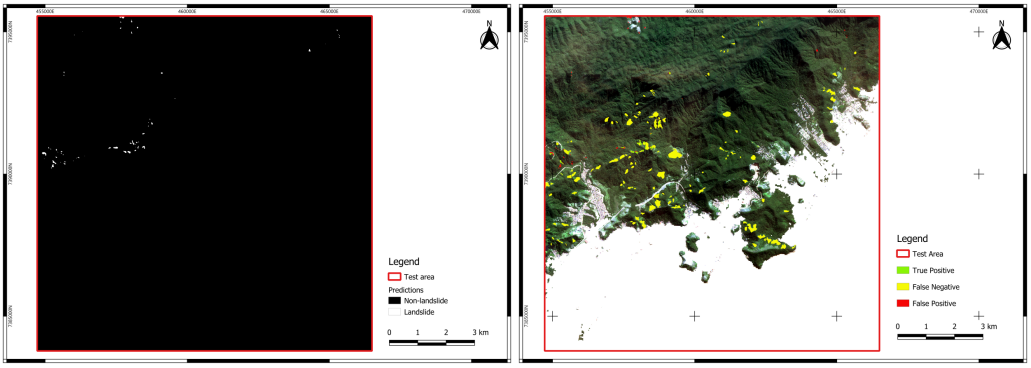

Figure 17. Image of True Positive, False Positive and False Negative samples from the predicitons of FPN with 10 clusters and LD30.

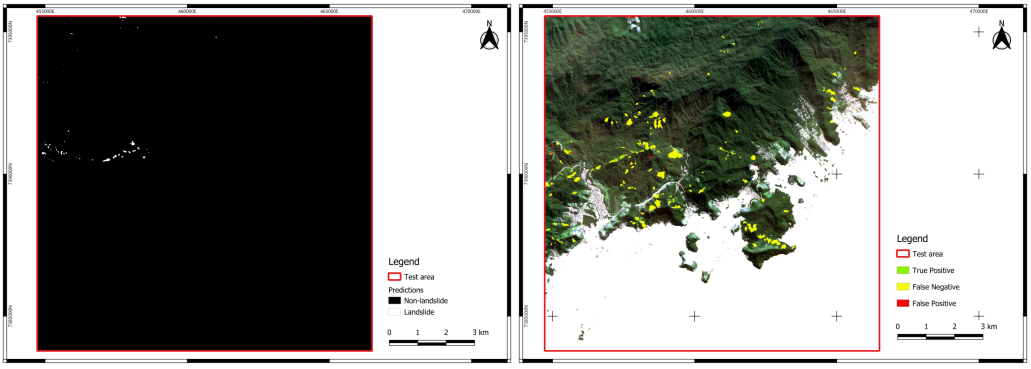

Figure 18. Image of True Positive, False Positive and False Negative samples from the predicitons of FPN with 10 clusters and LD50.

Capítulo 6

Conclusão

O principal objetivo deste projeto foi utilizar as principais tecnologias, ferramentas e técnicas existentes para o estudo de escorregamentos e avaliar seus resultados em relação a eficácia, precisão, custo benefício e reprodutibilidade.

Foram realizados dois estudos com a aplicação de diferentes tecnologias. O primeiro estudo teve por objetivo a utilização de dados topográficos para a realização de uma análise morfométrica de um escorregamento, enquanto que o objetivo do segundo estudo foi utilizar dados espectrais para a classificação semi-automática de escorregamentos em regiões montanhosas cobertas por vegetação.

O artigo 1 ("*Using Terrestrial Laser Scanner and RPA-based Photogrammetry for Surface Analysis of Landslide: A comparison*") teve como principal objetivo avaliar a precisão e eficiência dos sensores de *lidar* e RPA a partir da análise morfométrica de um escorregamento em uma encosta no município de Cunha (SP) seguida por uma comparação entre os dados obtidos por escaneamento a laser terrestre (TLS) com os dados obtidos por RPA. Os dados topográficos oriundos do *lidar* representam o padrão ouro em estudos morfométricos devido à alta resolução espacial e à capacidade de filtrar objetos que não representam o terreno. Por sua vez, os dados de RPA representam uma opção mais acessível, de fácil manuseio e com maior agilidade na obtenção de dados. Dessa forma, o objetivo desse estudo foi avaliar se os dados obtidos por RPA poderiam substituir os dados de *lidar* para análises de escorregamentos em encostas com características físicas específicas (desmatadas ou com pouca vegetação arbórea).

Esse estudo demonstrou que os resultados da análise morfométrica foram semelhantes entre os dados de *lidar* e de RPA, sendo as principais diferenças relacionadas à distribuição dos pontos coletados, ao volume calculado de material deslocado pelo escorregamento e à rugosidade, principalmente nos modelos com resoluções espaciais de 1 m e 2 m. No entanto, apesar das diferenças encontradas, os resultados foram, em geral, similares e comparáveis, o que permite considerar que a utilização de dados de RPA em detrimento aos dados *lidar* para análises morfométricas de escorregamentos não apresenta prejuízos relevantes na área de estudo analisada. Vale ressaltar que esses resultados podem variar de acordo com as características da área de estudo. A similari-

dade observada nesse estudo ocorreu em uma área com características físicas específicas em que a encosta é composta por pasto e ausência de vegetação arbórea, paisagem típica dos locais de ocorrência de escorregamentos nas regiões da Serra do Mar e Serra da Mantiqueira no Sudeste brasileiro. Contudo é esperado que a análise morfométrica com dados RPA tenha desempenho inferior em relação ao *lidar* em áreas cobertas por vegetação que impedem uma observação clara do terreno.

O artigo 2 ("*Relict landslide detection using Deep-Learning architectures for image segmentation in rainforest areas: A new framework*") tem como principal objetivo realizar uma classificação semi-automática de escorregamentos reliquiares utilizando modelos de *Deep Learning*. É proposta uma nova abordagem para o processamento de dados e treinamento de redes neurais convolucionais (CNN) de segmentação semântica (UNet, FPN e Linknet). A área de estudo escolhida foi o munícipio de Caraguatatuba (SP) devido ao histórico de escorregamentos em suas encostas, a boa preservação de cicatrizes de escorregamentos e por possuir um mapa de inventário de um grande evento ocorrido em 1967 (Fúlfaro et al., 1976). Imagens do satélite CBERS4A do INPE (Instituto Nacional de Pesquisas Espaciais) foram utilizadas como dados de entrada das redes neurais. Os resultados demonstraram que a abordagem proposta foi mais precisa que a abordagem padrão normalmente utilizada, apresentando os maiores valores de precisão e *recall*, respectivamente, 20.47% e 81.09% . As predições de escorregamentos da abordagem proposta, que permitem uma interpretação visual do resultado das redes neurais testadas, também foram melhores que a abordagem tradicional. Ao todo foram testadas 42 combinações de parâmetros sendo que algumas combinações foram capazes de identificar quase que a totalidade das cicatrizes de escorregamentos presentes na área de estudo, apesar da grande quantidade de falsos positivos (FP) gerados.

Os resultados obtidos foram inferiores aos de outros estudos de classificação de escorregamentos utilizando CNNs (Ghorbanzadeh et al., 2019; Sameen e Pradhan, 2019; Yu et al., 2021; Soares et al., 2022). No entanto, é importante ressaltar que as especificidades do projeto, como o foco na detecção de escorregamentos reliquiares, a utilização de imagens do satélite CBERS4A e área de estudo com ampla cobertura vegetal impedem uma comparação direta com os resultados de outros estudos. Importante destacar que esse projeto foi pioneiro na utilização das imagens multiespectrais do satélite CBERS4A para a detecção dos escorregamentos. A grande quantidade de falsos positivos (FP) se deve, principalmente, à similaridade espectral das cicatrizes de escorregamento com a vegetação rasteira/arbustiva das encostas normalmente em áreas devastadas ou em pastos. A resolução espectral das imagens CBERS4A não foi suficiente para permitir a segregação dos pixels das cicatrizes de escorregamento de forma eficaz.

A classificação supervisionada de escorregamentos reliquiares é uma ferramenta essencial para o mapeamento de escorregamentos e, principalmente, para a atualização dos mapas de inventário de forma rápida e eficaz (Dias et al., 2021). Apesar das dificuldades encontradas e dos resultados heterogêneos e, em sua maioria, inapropriados, o estudo demonstrou a grande capacidade das

CNNs de segmentação semântica para a detecção de escorregamentos, algo que já vem sendo bastante explorado em outros trabalhos (Chen et al., 2018; Ghorbanzadeh et al., 2019; Sameen e Pradhan, 2019; Zhong et al., 2020; Ji et al., 2020; Li et al., 2021; Yu et al., 2021; Soares et al., 2022). A abordagem proposta apresentou resultados melhores que a abordagem padrão tanto de validação como das predições mesmo com as limitações impostas pelas características da área de estudo. Espera-se que a replicação da abordagem proposta nesse estudo obtenha melhores resultados em outras áreas de estudo com os escorregamentos mais destacados da paisagem, provavelmente utilizando imagens logo após os eventos ou com a utilização de imagens com maior resolução espectral como as imagens hiperespectrais.

Os dois projetos permitiram manusear tanto dados topográficos como dados espectrais para o estudo de escorregamentos, assim como destacar a importância, as especificidades e a aplicabilidade de cada tipo de dado. Cada artigo possui um objetivo próprio que está diretamente relacionado com o tipo de dado utilizado. Nesse projeto foi demonstrado que as diferentes ferramentas utilizadas foram eficazes apesar de limitações inerentes às características físicas do terreno e/ou às especificações técnicas dos dados de entrada.

Considerando os relevantes resultados obtidos nos artigos 1 e 2, é possível concluir que a utilização conjunta de dados topográficos e espectrais nos estudos de escorregamentos pode ser capaz de aprimorar os resultados. Diversos trabalhos exploram essa integração de dados topográficos e espectrais, principalmente de detecção de escorregamento por técnicas de *Machine Learning* e *Deep Learning* em que modelos de elevação, e suas derivadas físicas, são adicionados como bandas da imagem de entrada no processo de treinamento dos algoritmos (Chen et al., 2018; Ghorbanzadeh et al., 2019; Sameen e Pradhan, 2019; Ji et al., 2020; Wang et al., 2020; Soares et al., 2022). No entanto, na maioria desses estudos, a adição dos dados topográficos não melhorou significativamente a eficácia dos modelos testados, em alguns casos o resultado foi, inclusive, pior do que utilizando apenas dados espectrais. A resolução espacial dos dados, a utilização de MDE ao invés de MDT e a maior dificuldade das redes neurais em treinar imagens com muitas bandas podem explicar o desempenho insatisfatório da utilização conjunta dos dados topográficos e espectrais (Ghorbanzadeh et al., 2019; Sameen e Pradhan, 2019; Soares et al., 2022).

Infelizmente, devido a diversas dificuldades ocorridas no cronograma do projeto como a aquisição e procesamento de dados; o período que o laboratório esteve fechado devido a pandemia de COVID-19 e algumas mudanças no tema principal do projeto, não houve tempo hábil para a realização de um novo estudo integrando os dados e ferramentas utilizados nos artigos 1 e 2.

Os dois projetos realizados demonstraram as potencialidades dessas ferramentas e técnicas, e a importante contribuição dessas novas tecnologias no aprimoramento dos métodos tradicionais de estudo de escorregamentos. Os maiores obstáculos para a utilização dessas novas tecnologias são a acessibilidade restrita a essa ferramentas, uma vez que muitas delas possuem um alto

custo para aplicação e/ou aquisição, e o conhecimento do funcionamento das mesmas. Porém, o aumento do interesse dos pesquisadores nessas ferramentas irá promover um aumento no número de publicações sobre esses temas, disseminando ainda mais o conhecimento e provavelmente melhorando a acessibilidade aos dados e às ferramentas.

Referências Bibliográficas

Aggarwal, C.C., 2018, Neural networks and deep learning: Springer International Publishing, doi: 10.1007/978-3-319-94463-0.

Ahmadabadian, A.H., Robson, S., Boehm, J., Shortis, M., Wenzel, K., e Fritsch, D., 2013, A comparison of dense matching algorithms for scaled surface reconstruction using stereo camera rigs: ISPRS Journal of Photogrammetry and Remote Sensing, v. 78, p. 157–167, doi: 10.1016/j.isprsjprs.2013.01.015.

Althuwaynee, O.F., Pradhan, B., e Lee, S., 2012, Application of an evidential belief function model in landslide susceptibility mapping: Computers & Geosciences, v. 44, p. 120–135, doi: 10.1016/j.cageo.2012.03.003.

Ardizzone, F., Cardinali, M., Galli, M., Guzzetti, F., Reichenbach, P., Ardizzone, F., Cardinali, M., Galli, M., Guzzetti, F., e Identification, P.R., 2007, Identification and mapping of recent rainfall-induced landslides using elevation data collected by airborne lidar: Natural Hazards and Earth System Science, v. 7, p. 637–650.

Assali, P., Grussenmeyer, P., Villemin, T., Pollet, N., e Viguier, F., 2014, Surveying and modeling of rock discontinuities by terrestrial laser scanning and photogrammetry: Semi-automatic approaches for linear outcrop inspection: Journal of Structural Geology, v. 66, p. 102–114, doi: 10.1016/j.jsg.2014.05.014.

Augusto Filho, O., 1992, Caracterização geológico-geotécnica voltada à estabilização de encostas: uma proposta metodológica, *in* conferência brasileira sobre estabilidade de encostas, v. 1: p. 721–733.

Ayalew, L., Yamagishi, H., e Ugawa, N., 2004, Landslide susceptibility mapping using gis-based weighted linear combination, the case in tsugawa area of agano river, niigata prefecture, japan: Landslides, v. 1, p. 73–81, doi: 10.1007/s10346-003-0006-9.

Ba, Q., Chen, Y., Deng, S., Wu, Q., Yang, J., e Zhang, J., 2017, An improved information value model based on gray clustering for landslide susceptibility mapping: International Journal of Geo-Information2, v. 6, p. 20, doi: 10.3390/ijgi6010018.

Baldo, M., Bicocchi, C., Chiocchini, U., Giordan, D., e Lollino, G., 2009, Lidar monitoring of mass wasting processes: The radicofani landslide, province of siena, central italy: Geomorphology, v. 105, p. 193–201, doi: 10.1016/j.geomorph.2008.09.015, URL http://dx.doi.org/10.1016/j.geomorph.2008.09.015.

Baltsavias, E.P., 1999, A comparison between photogrammetry and laser scanning: ISPRS Journal of Photogrammetry & Remote Sensing, v. 54, p. 83–94, URL https://pdfs.semanticscholar.org/5aab/42d1552075c79e9b55d80386161f02e18377.pdf.

Booth, A.M., Roering, J.J., e Perron, J.T., 2009, Automated landslide mapping using spectral analysis and high-resolution topographic data: Puget sound lowlands, washington, and portland hills, oregon: Geomorphology, v. 109, p. 132–147, doi: 10.1016/j.geomorph.2009.02.027, URL http://dx.doi.org/10.1016/j.geomorph.2009.02.027.

Brideau, M.A., Sturzenegger, M., Stead, D., Jaboyedoff, M., Lawrence, M., Roberts, N., Ward, B., Millard, T., e Clague, J., 2012, Stability analysis of the 2007 chehalis lake landslide based on long-range terrestrial photogrammetry and airborne lidar data: Landslides, v. 9, p. 75–91, doi: 10.1007/s10346-011-0286-4.

Brock, J., Schartz, P., Petschko, H., Muenchow, J., Micu, M., e Brenning, A., 2020, The performance of landslide susceptibility models critically depends on the quality of digital elevation models: Geomatics, Natural Hazards and Risk, v. 11, p. 1075–1092, doi: https://doi.org/10.1080/19475705.2020.1776403.

Brown, D.C., 1958, A solution to the general problem of multiple station analytical stereotriangulation: .

Buckley, S.J., Howell, J., Enge, H., e Kurz, T., 2008, Terrestrial laser scanning in geology: data acquisition, processing and accuracy considerations: Journal of the Geological Society, v. 165, p. 625–638, doi: 10.1144/0016-76492007-100, URL http://jgs.lyellcollection.org/cgi/doi/10.1144/0016-76492007-100.

Burns, W.J., Coe, J.A., Kaya, B.S., e Ma, L., 2010, Analysis of elevation changes detected from multi-temporal lidar surveys in forested landslide terrain in western oregon: Environmental and Engineering Geoscience, v. 16, p. 315–341, doi: 10.2113/gseegeosci.16.4.315.

Burns, W.J., e Madin, I.P., 2009, Protocol for inventory mapping of landslide deposits from light detection and ranging (lidar) imagery: .

Busarello, M.d.S.T., 2017, Análise estrutural de diques clásticos da Formação Corumbataí a partir de Structure-from-Motion, Monografia de trabalho de formatura: Instituto de Geociências, Universidade de São Paulo, 46 p.

Carey, J.A., Pinter, N., Pickering, A.J., Prentice, C.S., e Delong, S.B., 2019, Analysis of landslide kinematics using multi-temporal unmanned aerial vehicle imagery, la honda, california: Environmental & Engineering Geoscience, v. 25, p. 301–317.

Carrivick, J.L., Smith, M.W., e Quincey, D.J., 2016, Structure from motion in the geosciences: 1st edn., John Wiley & Sons, Ltd, 194 p.

Casagli, N., Cigna, F., Bianchini, S., Hölbling, D., Füreder, P., Righini, G., Conte, S.D., Friedl, B., Schneiderbauer, S., Iasio, C., Vlcko, J., Greif, V., Proske, H., Granica, K., Falco, S., Lozzi, S., Mora, O., Arnaud, A., Novali, F., e Bianchi, M., 2016, Landslide mapping and monitoring by using radar and optical remote sensing: Examples from the ec-fp7 project safer: Remote Sensing Applications: Society and Environment, v. 4, p. 92–108, doi: 10.1016/j.rsase.2016.07.001, URL http://dx.doi.org/10.1016/j.rsase.2016.07.001.

Casagli, N., Frodella, W., Morelli, S., Tofani, V., Ciampalini, A., Intrieri, E., Raspini, F., Rossi, G., Tanteri, L., e Lu, P., 2017, Spaceborne, uav and ground-based remote sensing techniques for landslide mapping, monitoring and early warning: Geoenvironmental Disasters, v. 4, p. 23, doi: 10.1186/s40677-017-0073-1.

Catani, F., Lagomarsino, D., Segoni, S., e Tofani, V., 2013, Landslide susceptibility estimation by random forests technique: sensitivity and scaling issues: Natural Hazards and Earth System Sciences, v. 13, p. 2815–2831, doi: 10.5194/nhess-13-2815-2013.

CEMADEN, 2022, Chamada 12 pci-db: URL https://www.gov.br/cemaden/pt-br/acesso-a-informacao/licitacoes-e-contratos-1/editais-de-bolsas/bolsas/pci/chamadas-11-12-13-14-15-16-17-18-19-20-21-22-23-24-25-26-e-27-2022-programa-de-capacitacao-institucional-pci/chamada_12_pci-db.pdf/view.

Chandler, J., 1999, Effective application of automated digital photogrammetry for geomorphological research: Earth Surface Processes and Landforms, v. 24, p. 51–63, doi: 10.1002/(SICI)1096-9837(199901)24:1⟨51::AID-ESP948⟩3.0.CO;2-H.

Chang, K.J., Tseng, C.W., Tseng, C.M., Liao, T.C., e Yang, C.J., 2020, Application of unmanned aerial vehicle (uav)-acquired topography for quantifying typhoon-driven landslide volume and its potential topographic impact on rivers in mountainous catchments: Applied Sciences, v. 10, p. 1–16, doi: 10.3390/app10176102.

Chen, R.F., Chang, K.J., Angelier, J., Chan, Y.C., Deffontaines, B., Lee, C.T., e Lin, M.L., 2006, Topographical changes revealed by high-resolution airborne lidar data: The 1999 tsaoling landslide induced by the chi-chi earthquake: Engineering Geology, v. 88, p. 160–172, doi: 10.1016/j.enggeo.2006.09.008.

Chen, W., Li, X., Wang, Y., Chen, G., e Liu, S., 2014, Forested landslide detection using lidar data and the random forest algorithm: A case study of the three gorges, china: Remote Sensing of Environment, v. 152, p. 291–301, doi: 10.1016/j.rse.2014.07.004, URL http://dx.doi.org/10.1016/j.rse.2014.07.004.

Chen, W., Li, X., Wang, Y., e Liu, S., 2013, Landslide susceptibility mapping using lidar and dmc data: A case study in the three gorges area, china: Environmental Earth Sciences, v. 70, p. 673–685, doi: 10.1007/s12665-012-2151-8.

Chen, Y., Zhao, X., e Jia, X., 2015, Spectral–spatial classification of hyperspectral data based on deep belief network: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, v. 8, p. 2381–2392, doi: 10.1109/JSTARS.2015.2388577.

Chen, Z., Zhang, Y., Ouyang, C., Zhang, F., e Ma, J., 2018, Automated landslides detection for mountain cities using multi-temporal remote sensing imagery: Sensors, v. 18, no. 821, p. 18, doi: doi:10.3390/s18030821.

Cheng, G., Han, J., e Lu, X., 2017, Remote sensing image scene classification: benchmark and state of the art: Proceedings of the IEEE, v. 105, p. 1865–1883, doi: 10.1109/JPROC.2017.2675998.

Cheng, G., Zhou, P., e Han, J., 2016, Learning rotation-invariant convolutional neural networks for object detection in vhr optical remote sensing images: IEEE Transactions on Geoscience and Remote Sensing, v. 54, p. 7405–7415, doi: 10.1109/TGRS.2016.2601622.

Choi, S., Kim, T., e Yu, W., 2009, Performance evaluation of ransac family, : British Machine Vision Association, p. 81.1–81.12, doi: 10.5244/C.23.81.

CloudCompare, 2018, CloudCompare (versão 2.10) [GPL software]: URL http://www.cloudcompare.org/.

Corsini, A., Cervi, F., Daehne, A., e Ronchetti, 2009, Coupling geomorphic field observation and lidar derivatives to map complex landslides: Landslides processes—from geomorphologic mapping to dynamic modeling, proceedings of the landslide processes conference, p. 6–7.

Costa, J.E., e Baker, V.R., 1981, Surficial geology: building with the earth: John Wiley & Sons.

Costa, J.E., e Fleisher, P.J., 1984, Developments and Applications of Geomorphology: 1st edn., Berlin, Springer-Verlag, 386p p., URL https://link.springer.com/content/pdf/10.1007{%}2F978-3-642-69759-3.pdf.

da Silva, F.A., 2012, Georreferenciamento automático de placas de sinalização com imagens obtidas com um sistema móvel de mapeamento, Tese de doutorado: Universidade de São Paulo, 231 p.

Deems, J.S., Painter, T.H., e Finnegan, D.C., 2013, Lidar measurement of snow depth: a review: Journal of Glaciology, v. 59, p. 467–479, doi: 10.3189/2013JoG12J154, URL https://www.cambridge.org/core/product/identifier/S0022143000204462/type/journal_article.

Densmore, A.L., e Hovius, N., 2000, Topographic fingerprints of bedrock landslides: Geology, p. 371, URL https://pubs.geoscienceworld.org/gsa/geology/article-pdf/28/4/371/3520420/i0091-7613-28-4-371.pdf.

Derron, M.H., e Jaboyedoff, M., 2010, Lidar and dem techniques for landslides monitoring and characterization: Natural Hazards and Earth System Science, v. 10, p. 1877–1879, doi: 10.5194/nhess-10-1877-2010.

Dewitte, O., Jasselette, J.C., Cornet, Y., Eeckhaut, M.V.D., Collignon, A., Poesen, J., e Demoulin, A., 2008, Tracking landslide displacements by multi-temporal dtms: A combined aerial stereophotogrammetric and lidar approach in western belgium: Engineering Geology, v. 99, p. 11–22, doi: 10.1016/j.enggeo.2008.02.006.

Diakogiannis, F.I., Waldner, F., Caccetta, P., e Wu, C., 2020, Resunet-a: A deep learning framework for semantic segmentation of remotely sensed data: ISPRS Journal of Photogrammetry and Remote Sensing, v. 162, p. 94–114.

Dias, H.C., Hölbling, D., e Grohmann, C.H., 2021, Landslide susceptibility mapping in brazil: A review: Geosciences, v. 11, p. 425, doi: 10.3390/geosciences11100425.

Ding, A., Zhang, Q., Zhou, X., e Dai, B., 2016, Automatic recognition of landslide based on cnn and texture change detection, : p. 444 – 448.

dos Santos Correa, C.V., Reis, F.A.G.V., Giordano, L.C., Chaves, C.J., Gabelini, B.M., e Cerri, R.I., 2017, Movimentos de massa na região de caraguatatuba e são sebastião (sp) entre 1967 e 2011: utilização de cicatrizes de escorregamento como subsídio a estudos de retro-análise, : p. 4162–4173, doi: 10.20396/sbgfa.v1i2017.2599.

Du, J.C., e Teng, H.C., 2007, 3d laser scanning and gps technology for landslide earthwork volume estimation: Automation in Construction, v. 16, p. 657–663, doi: 10.1016/j.autcon.2006.11.002.

Eeckhaut, M.V.D., Moeyersons, J., Nyssen, J., Abraha, A., Poesen, J., Haile, M., e Deckers, J., 2009, Spatial patterns of old, deep-seated landslides: A case-study in the northern ethiopian highlands: Geomorphology, v. 105, p. 239–252, doi: 10.1016/j.geomorph.2008.09.027, URL http://dx.doi.org/10.1016/j.geomorph.2008.09.027.

Eeckhaut, M.V.D., Poesen, J., Verstraeten, G., Vanacker, V., Nyssen, J., Moeyersons, J., van Beek, L.P.H., e Vandekerckhove, L., 2007, Use of lidar-derived images form mapping old landslides under forest: Earth Surface Processes and Landforms, v. 32, p. 754–769, doi: 10.1002/esp, URL http://doi.wiley.com/10.1002/esp.1730.

Eeckhaut, M.V.D., Poesen, J., Gullentops, F., Vandekerckhove, L., e Hervás, J., 2011, Regional mapping and characterisation of old landslides in hilly regions using lidar-based imagery in southern flanders: Quaternary Research, v. 75, p. 721–733, doi: 10.1016/j.yqres.2011.02.006, URL http://dx.doi.org/10.1016/j.yqres.2011.02.006.

Eeckhaut, M.V.D., Kerle, N., Poesen, J., e Herv??s, J., 2012, Object-oriented identification of forested landslides with derivatives of single pulse lidar data: Geomorphology, v. 173-174, p. 30–42, doi: 10.1016/j.geomorph.2012.05.024, URL http://dx.doi.org/10.1016/j.geomorph.2012.05.024.

Eeckhaut, M.V.D., Poesen, J., Verstraeten, G., Vanacker, V., Moeyersons, J., Nyssen, J., e van Beek, L.P.H., 2005, The effectiveness of hillshade maps and expert knowledge in mapping old deep-seated landslides: Geomorphology, v. 67, p. 351–363, doi: 10.1016/j.geomorph.2004.11.001.

Eker, R., Aydın, A., e Hübl, J., 2018, Unmanned aerial vehicle (uav)-based monitoring of a landslide: Gallenzerkogel landslide (ybbs-lower austria) case study: Environmental Monitoring and Assessment, v. 190, p. 28, doi: 10.1007/s10661-017-6402-8.

Ermini, L., Catani, F., e Casagli, N., 2005, Artificial neural networks applied to landslide susceptibility assessment: Geomorphology, v. 66, p. 327–343, doi: 10.1016/j.geomorph.2004.09.025.

Farr, T., Rosen, P., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D., e Alsdorf, D., 2007, The shuttle radar topography mission: Reviews of Geophysics, v. 45, p. 1–33, doi: 10.1029/2005RG000183.1.INTRODUCTION.

Fernandes, N.F., e Amaral, C.d., 1996, Movimentos de massa: uma abordagem geológico-geomorfológica: Geomorfologia e Meio Ambiente. Bertrand, Rio de Janeiro, p. 123–194.

Fischler, M.A., e Bolles, R.C., 1981, Random sample consensus: Communications of the ACM, v. 24, p. 381–395, doi: 10.1145/358669.358692.

Florenzano, T.G., 2008, Geomorfologia: conceitos e tecnologias atuais: Oficina de Textos.

Florinsky, I.V., 1998, Combined analysis of digital terrain models and remotely sensed data in landscape investigations: Progress in Physical Geography, v. 22, p. 33–60, doi: 10.

1177/030913339802200102, URL http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.113.9399&rep=rep1&type=pdf.

Forstner, W., 1986, A feature bassed correspondence algorithm for image matching: International Archives of Photogrammetry, v. 26, p. 150–166.

Franklin, S., 1987, Geomorphometric processing of digital elevation models: Computers & Geosciences, v. 13, p. 603–609, URL http://www.sciencedirect.com/science/article/pii/0098300487900306.

Fukushima, K., 1980, Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position: Biological Cybernetics, v. 36, p. 193–202, doi: 10.1007/BF00344251.

Fúlfaro, V., Ponçano, W., Bistrichi, C., e Stein, D., 1976, Escorregamentos de caraguatatuba: expressão atual, e registro na coluna sedimentar da planície costeira adjacente, *in* Congresso brasileiro de geologia de engenharia, v. 2: p. 341–350.

Furukawa, Y., Curless, B., Seitz, S.M., e Szeliski, R., 2010, Towards internet-scale multi-view stereo, : IEEE, p. 1434–1441, doi: 10.1109/CVPR.2010.5539802.

Furukawa, Y., e Hernández, C., 2015, Multi-view stereo: A tutorial: Foundations and Trends® in Computer Graphics and Vision, v. 9, p. 1–148, doi: 10.1561/0600000052.

Furukawa, Y., e Ponce, J., 2010, Accurate, dense, and robust multiview stereopsis: IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 32, p. 1362–1376, doi: 10.1109/TPAMI.2009.161.

Garcia, G.P.B., 2020, Os desafios dos escritórios de contabilidade para garantir a conformidade com a lei geral de proteção de dados pessoais (lgpd): .

Gariano, S.L., e Guzzetti, F., 2016, Landslides in a changing climate: Earth-Science Reviews, v. 162, p. 227–252, doi: 10.1016/j.earscirev.2016.08.011.

Ghorbanzadeh, O., Blaschke, T., Gholamnia, K., Meena, S.R., Tiede, D., e Aryal, J., 2019, Evaluation of different machine learning methods and deep-learning convolutional neural networks for landslide detection: Remote Sensing, v. 11, no. 196, p. 21, doi: doi:10.3390/rs11020196.

Ghuffar, S., Székely, B., Roncat, A., e Pfeifer, N., 2013, Landslide displacement monitoring using 3d range flow on airborne and terrestrial lidar data: Remote Sensing, v. 5, p. 2720–2745, doi: 10.3390/rs5062720.

Glenn, N.F., Streutker, D.R., Chadwick, D.J., Thackray, G.D., e Dorsch, S.J., 2006, Analysis of lidar-derived topographic information for characterizing and differentiating landslide morphology and activity: Geomorphology, v. 73, p. 131–148, doi: 10.1016/j.geomorph.2005.07.006.

Gokceoglu, M.E.C., 2002, Assessment of landslide susceptibility for a landslide-prone area (north of yenice, nw turkey) by fuzzy approach: Environmental Geology, v. 41, p. 720–730, doi: 10.1007/s00254-001-0454-2.

Goldblatt, R., Stuhlmacher, M.F., Tellman, B., Clinton, N., Hanson, G., Georgescu, M., Wang, C., Serrano-Candela, F., Khandelwal, A.K., Cheng, W.H., e Balling, R.C., 2018, Using landsat and nighttime lights for supervised pixel-based image classification of urban land cover: Remote Sensing of Environment, v. 205, p. 253–275, doi: 10.1016/j.rse.2017.11.026.

Gomes, E.B., 2018, Aplicação de análise de suscetibilidade a movimentos de massa em encostas naturais a partir de modelo digital de terreno de alta resolução: .

Gramani, M.F., 2001, Caracterização geológica-geotécnica das corridas de detritos ("Debris Flows") no Brasil e comparação com alguns casos internacionais., Mestrado: Universidade de São Paulo, 372 p p.

Grohmann, C.H., Garcia, G.P., Affonso, A.A., e Albuquerque, R.W., 2020, Dune migration and volume change from airborne lidar, terrestrial lidar and structure from motion-multi view stereo: Computers & Geosciences, v. 143, p. 104,569, doi: 10.1016/j.cageo.2020.104569.

Grohmann, C.H., Viana, C.D., Garcia, G.P., e Albuquerque, R.W., 2023a, Remotely piloted aircraft-based automated vertical surface survey: MethodsX, v. 10, p. 101,982, doi: 10.1016/j.mex.2022.101982.

Grohmann, C.H., Garcia, G.P.B., Viana, C.D., Dias, H.C., Gramani, M.F., dos Santos, L.F., Sousa, A.M., Soares, L.P., e Coelho, R.D., 2023b, Landslide 3d reconstruction and monitoring using drone aerial imagery: 1-8 p.

Grohmann, C.H., Zacharias, G., Garcia, G.P.B., Barale, F., Almeida, F.V., e Arnone, I.S., 2019a, Mapeamento e modelagem 3d do setor turístico da caverna do diabo (sp) com laser scanner: resultados preliminares., : p. 201–206.

Grohmann, C., Viana, C., Garcia, G., Albuquerque, R., Barale, F., e Ferretti, F., 2019b, Semi-automatic uav-based sfm survey of vertical surfaces, : .

Gualtieri, J.A., e Robert, C., 1999, Support vector machine for hyperspectral remote sensing classification, : p. 221–232.

Guidicini, G., e Nieble, C.M., 1984, Estabilidade de taludes naturais e de escavação: .

Guzzetti, F., Carrara, A., Cardinali, M., e Reichenbach, P., 1999, Landslide hazard evaluation: a review of current techniques and their application in a multi-scale study, central italy: Geomorphology, v. 31, p. 181–216, doi: 10.1016/S0169-555X(99)00078-1, URL https://www.sciencedirect.com/science/article/pii/S0169555X99000781?via%3Dihub.

Guzzetti, F., Mondini, A.C., Cardinali, M., Fiorucci, F., Santangelo, M., e Chang, K.T., 2012, Landslide inventory maps: New tools for an old problem: Earth-Science Reviews, v. 112, p. 42–66, doi: 10.1016/j.earscirev.2012.02.001, URL http://dx.doi.org/10.1016/j.earscirev.2012.02.001.

Guzzetti, F., Reichenbach, P., Cardinali, M., Galli, M., e Ardizzone, F., 2005, Probabilistic landslide hazard assessment at the basin scale: Geomorphology, p. 272–299, doi: 10.1016/j.geomorph.2005.06.002, URL www.elsevier.com/locate/geomorph.

Haneberg, W.C., Cole, W.F., e Kasali, G., 2009, High-resolution lidar-based landslide hazard mapping and modeling, UCSF Parnassus Campus, San Francisco, USA: Bulletin of Engineering Geology and the Environment, v. 68, no. 2, p. 263–276, doi: 10.1007/s10064-009-0204-3.

Harris, C., e Stephens, M., 1988, A combined corner and edge detector, : p. 147–152.

Heleno, S., Matias, M., Pina, P., e Sousa, A.J., 2016, Semiautomated object-based classification of rain-induced landslides with vhr multispectral images on madeira island: Natural Hazards and Earth System Sciences, v. 16, p. 1035–1048, doi: 10.5194/nhess-16-1035-2016, URL https://www.nat-hazards-earth-syst-sci.net/16/1035/2016/.

Hetherington, D., 2010, Topographic Laser Ranging and Scanning: Principles and Processing, v. 31: 654 p p., doi: 10.1080/01431160903112612, URL http://www.tandfonline.com/doi/abs/10.1080/01431160903112612.

Highland, L., 2004, Landslide types and processses, , US Geological Fact Sheet 3072 - USGS.

Hsiao, K., Liu, J., Yu, M., e Tseng, Y., 2004, Change detection of landslide terrains using ground-based lidar data: XXth ISPRS Congress, Istanbul, Turkey, Comission VII, v. VII, p. 1–5.

Hubel, D.H., e Wiesel, T.N., 1959, Receptive fields of single neurones in the cat's striate cortex: The Journal of Physiology, v. 148, p. 574–591, doi: 10.1113/jphysiol.1959.sp006308.

Hung, C.L.J., Tseng, C.W., Huang, M.J., Tseng, C.M., e Chang, K.J., 2019, Multi-temporal high-resolution landslide monitoring based on uas photogrammetry and uas lidar geoinformation, : p. 157–160, doi: https://doi.org/10.5194/isprs-archives-XLII-3-W8-157-2019.

Hungr, O., Leroueil, S., e Picarelli, L., 2014, The Varnes classification of landslide types, an update: Landslides, v. 11, no. 2, p. 167–194, doi: 10.1007/s10346-013-0436-y.

Hutchinson, J., 1968, Field meeting on the coastal landslides of Kent: 1–3 July 1966, *in* Proceedings of the geologists' association: p. 227–237, doi: doi:10.1016/S0016-7878(68)80039-2, URL https://ac.els-cdn.com/S0016787868800392/1-s2.0-S0016787868800392-main.pdf?{_}tid=e3646fce-5f70-45ee-a64e-73efbd4902ce{&}acdnat=1547561409{_}d558ce49fbc8ddea4aeaefd869ed4982.

Ienco, D., Gaetano, R., Dupaquier, C., e Maurel, P., 2017, Land cover classification via multitemporal spatial data by recurrent neural networks: IEEE Geoscience and Remote Sensing Letters, v. 14, p. 1685–1689, doi: 10.1109/LGRS.2017.2728698.

Infanti Jr, N., e Fornasari Filho, N., 1998, Processos de dinâmica superficial: Geologia de engenharia.

Interdonato, R., Ienco, D., Gaetano, R., e Ose, K., 2019, Duplo: A dual view point deep learning architecture for time series classification: ISPRS Journal of Photogrammetry and Remote Sensing, v. 149, p. 91–104, doi: https://doi.org/10.1016/j.isprsjprs.2019.01.011.

Iwahashi, J., Kamiya, I., e Yamagishi, H., 2012, High-resolution dems in the study of rainfall- and earthquake-induced landslides: Use of a variable window size method in digital terrain analysis: Geomorphology, v. 153-154, p. 29–38, doi: 10.1016/j.geomorph.2012.02.002, URL http://dx.doi.org/10.1016/j.geomorph.2012.02.002.

Jaboyedoff, M., Oppikofer, T., Abellán, A., Derron, M.H., Loye, A., Metzger, R., e Pedrazzini, A., 2012, Use of lidar in landslide investigations: A review: Natural Hazards, v. 61, p. 5–28, doi: 10.1007/s11069-010-9634-2.

Jebur, M.N., Pradhan, B., e Tehrany, M.S., 2014, Optimization of landslide conditioning factors using very high-resolution airborne laser scanning (lidar) data at catchment scale: Remote Sensing of Environment, v. 152, p. 150–165, doi: 10.1016/j.rse.2014.05.013, URL http://dx.doi.org/10.1016/j.rse.2014.05.013.

Ji, S., Yu, D., Shen, C., e Xu, Q., 2020, Landslide detection from an open satellite imagery and digital elevation model dataset using attention boosted convolutional neural networks: Landslides, v. 17, p. 1337 – 1352, doi: DOI10.1007/s10346-020-01353-2.

Jutzi, B., 2007, Analyse der zeitlichen signalform von rückgestreuten laserpulsen, Dissertation: München, Technische Universität München.

Kasai, M., Ikeda, M., Asahina, T., e Fujisawa, K., 2009, Lidar-derived dem evaluation of deep-seated landslides in a steep and rocky region of japan: Geomorphology, v. 113, p. 57–69, doi: 10.1016/j.geomorph.2009.06.004, URL http://dx.doi.org/10.1016/j.geomorph.2009.06.004.

Kawabata, D., e Bandibas, J., 2009, Landslide susceptibility mapping using geological data, a dem from aster images and an artificial neural network (ann): Geomorphology, v. 113, p. 97–109, doi: 10.1016/j.geomorph.2009.06.006, URL http://dx.doi.org/10.1016/j.geomorph.2009.06.006.

Kayastha, P., Dhital, M., e Smedt, F.D., 2013, Application of the analytical hierarchy process (ahp) for landslide susceptibility mapping: A case study from the tinau watershed, west nepal: Computers & Geosciences, v. 52, p. 398–408, doi: 10.1016/j.cageo.2012.11.003.

Kazhdan, M., e Hoppe, H., 2013, Screened poisson surface reconstruction: ACM Transactions on Graphics, v. 32, p. 1–13, doi: 10.1145/2487228.2487237.

Knevels, R., Petschko, H., Leopold, P., e Brenning, A., 2019, Geographic object-based image analysis for automated landslide detection using open source gis software: International Journal of Geo-Information, v. 8, p. 21.

Komac, M., 2006, A landslide susceptibility model using the analytical hierarchy process method and multivariate statistics in perialpine slovenia: Geomorphology, v. 74, p. 17–28, doi: 10.1016/j.geomorph.2005.07.005.

Krizhevsky, A., Sutskever, I., e Hinton, G.E., 2012, Imagenet classification with deep convolutional neural networks, *in* Pereira, F., Burges, C.J.C., Bottou, L., e Weinberger, K.Q., eds., Advances in neural information processing systems, v. 25: Curran Associates, Inc., URL https://proceedings.neurips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf.

Kurtz, C., Stumpf, A., Malet, J.P., Gançarski, P., Puissant, A., e Passat, N., 2014, Hierarchical extraction of landslides from multiresolution remotely sensed optical images: ISPRS Journal of Photogrammetry and Remote Sensing, v. 87, p. 122–136, doi: 10.1016/j.isprsjprs.2013.11.003, URL https://linkinghub.elsevier.com/retrieve/pii/S0924271613002621.

Kussul, N., Lavreniuk, M., Skakun, S., e Shelestov, A., 2017, Deep learning classification of land cover and crop types using remote sensing data: IEEE Geoscience and remote sensing letters, v. 14, p. 778–782.

Lecun, Y., Bottou, L., Bengio, Y., e Haffner, P., 1998, Gradient-based learning applied to document recognition: Proceedings of the IEEE, v. 86, p. 2278–2324, doi: 10.1109/5.726791.

LeCun, Y., e Bengio, Y., 1995, Convolutional networks for images, speech, and time series., *in* The handbook of brain theory and neural networks, v. 3361: 10th edn.

Lee, S., 2005, Application of logistic regression model and its validation for landslide susceptibility mapping using gis and remote sensing data: International Journal of Remote Sensing, v. 26, p. 1477–1491, doi: 10.1080/01431160412331331012.

Lee, S., 2007, Application and verification of fuzzy algebraic operators to landslide susceptibility mapping: Environmental Geology, v. 52, p. 615–623, doi: 10.1007/s00254-006-0491-y.

Lee, S., e Pradhan, B., 2006, Probabilistic landslide hazards and risk mapping on penang island, malaysia: J. Earth Syst. Sci., v. 115, p. 661–672, URL https://link.springer.com/content/pdf/10.1007%2Fs12040-006-0004-0.pdf.

Lehmann, D., 2008, Estudos sobre a propagação de gleichenella pectinata (willd.) ching (pteridófita - gleicheniaceae).: , p. 54.

Lhuillier, M., e Quan, L., 2005, A quasi-dense approach to surface reconstruction from uncalibrated images: IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 27, p. 418–433, doi: 10.1109/TPAMI.2005.44.

Li, C., Yi, B., Gao, P., Li, H., Sun, J., Chen, X., e Zhong, C., 2021, Valuable clues for dcnn-based landslide detection from a comparative assessment in the wenchuan earthquake area: Sensors, v. 21, p. 14, doi: https://doi.org/10.3390/s21155191.

Li, X., Cheng, X., Chen, W., Chen, G., e Liu, S., 2015, Identification of forested landslides using lidar data, object-based image analysis, and machine learning algorithms: Remote Sensing, v. 7, p. 9705–9726, doi: 10.3390/rs70809705.

Li, Y., Zhang, H., Xue, X., Jiang, Y., e Shen, Q., 2018, Deep learning for remote sensing image classification: A survey: WIREs Data Mining and Knowledge Discovery, v. 8, doi: 10.1002/widm.1264.

Litjens, G., Kooi, T., Bejnordi, B.E., Setio, A.A.A., Ciompi, F., Ghafoorian, M., van der Laak, J.A., van Ginneken, B., e Sánchez, C.I., 2017, A survey on deep learning in medical image analysis: Medical Image Analysis, v. 42, p. 60–88, doi: 10.1016/j.media.2017.07.005.

Liu, J.K., Chang, K.T., Rau, J.Y., Hsu, W.C., Liao, Z.Y., Lau, C.C., e Shih, T.Y., 2009, The geomorphometry of rainfall-induced landslides in Taiwan obtained by airborne LiDAR and digital photography, *in* Geoscience and remote sensing: p. 115–132.

Liu, P., Choo, K.K.R., Wang, L., e Huang, F., 2017, SVM or deep learning? A comparative study on remote sensing image classification: Soft Computing, v. 21, p. 7053–7065, doi: 10.1007/s00500-016-2247-2.

Longuet-Higgins, H.C., 1981, A computer algorithm for reconstructing a scene from two projections: Nature, v. 293, p. 133–135, doi: 10.1038/293133a0.

Lopes, E.S.S., e de Arruda Junior, E.R., 2015, Sensoriamento remoto para deslizamentos, *in* Sausen, T.M., e Lacruz, M.S.P., eds., Sensoriamento remoto para desastres: chap. 8, São Paulo, Oficina de Textos, p. 213–248.

Lowe, D.G., 2004, Distinctive image features from scale-invariant keypoints: International Journal of Computer Vision, v. 60, p. 91–110, doi: 10.1023/B:VISI.0000029664.99615.94.

Lowe, D., 1999, Object recognition from local scale-invariant features, : IEEE, p. 1150–1157 vol.2, doi: 10.1109/ICCV.1999.790410.

Lowe, D., 2001, Local feature view clustering for 3d object recognition, : IEEE Comput. Soc, p. 682–688, doi: 10.1109/CVPR.2001.990541.

Lu, X., Yuan, Y., e Zheng, X., 2017, Joint dictionary learning for multispectral change detection: IEEE Transactions on Cybernetics, v. 47, p. 884–897, doi: 10.1109/TCYB.2016.2531179.

Lucas, B.D., e Kanade, T., 1981, An iterative image registration technique with an application to stereo vision, : p. 674–679.

Lucieer, A., de Jong, S.M., e Turner, D., 2014, Mapping landslide displacements using structure from motion (sfm) and image correlation of multi-temporal uav photography: Progress in Physical Geography, v. 38, p. 97–116.

Luus, F.P.S., Salmon, B.P., van den Bergh, F., e Maharaj, B.T.J., 2015, Multiview deep learning for land-use classification: IEEE GEOSCIENCE AND REMOTE SENSING LETTERS, v. 12, p. 2448–2452.

Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., e Johnson, B.A., 2019, Deep learning in remote sensing applications: A meta-analysis and review: ISPRS Journal of Photogrammetry and Remote Sensing, v. 152, p. 166–177, doi: https://doi.org/10.1016/j.isprsiprs.2019.04.015.

Maggiori, E., Tarabalka, Y., Charpiat, G., e Alliez, P., 2017, Convolutional neural network for large-scale remote sensing image classification: IEEE Transactions on Geoscience and Remote Sensing, v. 55, p. 645–657, doi: 10.1109/IGRS.2016.2612821.

Mantovani, F., Soeters, R., e Westen, C.J.V., 1996, Remote sensing techniques for landslide studies and hazard zonation in europe: Geomorphology, v. 15, p. 213–225, URL https://ac.els-cdn.com/0169555X9500071C/1-s2.0-0169555X9500071C-main.pdf?_tid=e636cc36-64b3-45b5-9b18-41c5724cc837\&acdnat=1547762487_51f2ebff6e0f6d1e2568d0e647e7d2e1.

Marcelino, E.V., 2004, Mapeamento de áreas susceptíveis a escorregamento no município de caraguatatuba (sp) usando técnicas de sensoriamento remoto: , p. 1–230.

Marjanović, M., Kovačević, M., Bajat, B., e Voženílek, V., 2011, Landslide susceptibility assessment using svm machine learning algorithm: Engineering Geology, v. 123, p. 225–234, doi: 10.1016/j.enggeo.2011.09.006.

Marmanis, D., Datcu, M., Esch, T., e Stilla, U., 2016, Deep learning earth observation classification using imagenet pretrained networks: IEEE Geoscience and Remote Sensing Letters, v. 13, p. 105–109, doi: 10.1109/LGRS.2015.2499239.

Martins, T.D., Oka-fiori, C., Vieira, B.C., Bateira, C.V.M., e Montgomery, D.R., 2017, Dtm assesment in slope instability modeling: Revista Ra'e Ga, v. 41, p. 07–19, doi: 10.5380/raega.

Matikainen, L., e Karila, K., 2011, Segment-based land cover mapping of a suburban area—comparison of high-resolution remotely sensed datasets using classification trees and test field points: Remote Sensing, v. 3, p. 1777–1804, doi: 10.3390/rs3081777.

Maxwell, A.E., Warner, T.A., e Fang, F., 2018, Implementation of machine-learning classification in remote sensing: an applied review: International Journal of Remote Sensing2, v. 39, p. 2784–2817.

McKean, J., e Roering, J., 2004, Objective landslide detection and surface morphology mapping using high-resolution airborne laser altimetry: Geomorphology, v. 57, p. 331–351, doi: 10.1016/S0169-555X(03)00164-8.

Meena, S.R., e Nachappa, T.G., 2019, Impact of spatial resolution of digital elevation model on landslides susceptibility mapping: a case study in kulu valley, himalayas: Geosciences, v. 9, p. 17, doi: 10.3390/geosciences9080360.

Meigs, A., 2013, Active tectonics and the lidar revolution: Lithosphere, v. 5, p. 226–229, doi: 10.1130/RF.L004.1, URL http://pubs.geoscienceworld.org/lithosphere/article/5/2/226/145661/Active-tectonics-and-the-LiDAR-revolution.

Metternicht, G., Hurni, L., e Gogu, R., 2005, Remote sensing of landslides: An analysis of the potential contribution to geo-spatial systems for hazard assessment in mountainous environments: Remote Sensing of Environment, v. 98, p. 284–303, doi: 10.1016/j.rse.2005.08.004.

Mokhtar, N.M., Darwin, N., Ariff, M.F.M., Majid, Z., e Idris, K.M., 2019, The capabilities of unmanned aerial vehicle for slope classification, : p. 451–459, doi: https://doi.org/10.5194/isprs-archives-XLII-4-W16-451-2019.

Mondini, A.C., Marchesini, I., Rossi, M., Chang, K.T., Pasquariello, G., e Guzzetti, F., 2013, Bayesian framework for mapping and classifying shallow landslides exploiting remote sensing and topographic data: Geomorphology, v. 201, p. 135–147, doi: 10.1016/j.geomorph.2013.06.015, URL https://linkinghub.elsevier.com/retrieve/pii/S0169555X13003371.

Moravec, H., 1983, The stanford cart and the cmu rover: Proceedings of the IEEE, v. 71, p. 872–884, doi: 10.1109/PROC.1983.12684.

Morocho, V., Espana, D.A., Serrano, A.C., Achig, R., e Crompvoets, J., 2019, Mass movement detection from uav images analysis, : p. 461–467, doi: https://doi.org/10.5194/isprs-archives-XLII-2-W13-461-2019.

Murillo-García, F.G., Alcántara-Ayala, I., Ardizzone, F., Cardinali, M., Fiourucci, F., e Guzzetti, F., 2015, Satellite stereoscopic pair images of very high resolution: a step forward for the development of landslide inventories: Landslides, v. 12, p. 277–291, doi: 10.1007/s10346-014-0473-1, URL http://link.springer.com/10.1007/s10346-014-0473-1.

Netto, A.L.C., Sato, A.M., Avelar, A.S., Vianna, L.G.G., Araújo, I.S., Ferreira, D.L.C., Lima, P.H., Silva, A.P.A., e Silva, R.P., 2011, January 2011: the extreme landslide disaster in Brazil, *in* Proceedings of the 2nd worl landslide forum: p. 6, doi: 10.1007/978-3-642-31319-6_51.

Neves, R., 2022, Chuvas deixam mais de 200 mortos em cinco estados desde outubro: URL https://noticias.uol.com.br/cotidiano/ultimas-noticias/2022/02/17/mortos-chuvas-brasil.html.

Niethammer, U., Rothmund, S., James, M.R., Travelletti, J., e Joswig, M., 2010, Uav-based remote sensing of landslides, : p. 496–501.

Nohani, E., Moharrami, M., Sharafi, S., Khosravi, K., Pradhan, B., Pham, B.T., Lee, S., e Melesse, A.M., 2019, Landslide susceptibility mapping using different gis-based bivariate models: Water, v. 11, p. 1–22.

Nonato, V.S.B., 2022, Eventos extremos de fevereiro de 2022 no brasil: URL https://portal.inmet.gov.br/noticias/eventos-extremos-de-fevereiro-de-2022-no-brasil.

Oliveira, M.R.P., Vieira, B.C., e Ross, J.L.S., 2018, Morphological and geological susceptibility to landslides in the paratinga-paraibuna plateau (sp): Revista do Departamento de Geografia, p. p. 93–106, doi: DOI:10.11606/rdg.v0ispe.148486.

Pal, M., 2007, Random forest classifier for remote sensing classification: International Journal of Remote Sensing2, v. 26, p. 217–222.

Pal, M., e Mather, M., 2006, Support vector machines for classification in remote sensing: Internation Journal of Remote Sensing, v. 26, p. 1007–1011.

Passalacqua, P., Tarolli, P., e Foufoula-Georgiou, E., 2010, Testing space-scale methodologies for automatic geomorphic feature extraction from lidar in a complex mountainous landscape: Water Resources Research, v. 46, p. 1–17, doi: 10.1029/2009WR008812.

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., e Duchesnay, E., 2011, Scikit-learn: Machine learning in Python: Journal of Machine Learning Research, v. 12, p. 2825–2830.

Pellicani, R., Argentiero, I., Manzari, P., Spilotro, G., Mazzo, C., Ermini, R., e Apollonio, C., 2019, Uav and airborne lidar data for interpreting kinematic evolution of landslide movements: the case study of the montescaglioso landslide (southern italy): Geosciences, v. 9, p. 1–18, doi: https://doi.org/10.3390/geosciences9060248.

Pfeifer, N., e Briese, C., 2007, Geometrical aspects of airborne laser scanning and terrestrial laser scanning, : p. 311–319, URL https://publik.tuwien.ac.at/files/pub-geo_1935.pdf.

Pike, R.J., Evans, I.S., e Hengl, T., 2009, Geomorphometry:a brief guide: Geomorphometry: concepts, software, applications, v. 33, no. 1944, p. 3–30, doi: 10.1016/S0166-2481(08)00001-9.

Poder360, 2022, Chuvas em petrópolis resultam em 250 deslizamentos em 24h: URL https://www.poder360.com.br/brasil/chuvas-em-petropolis-resultam-em-250-deslizamentos-em-24-h/.

Portela, V.D.A., 2014, Avaliação da vegetação como indicadora de areas suscetiveis a escorregamentos na serra do mar em caraguatatuba (sp). áreas suscetíveis a escorregamentos na serra do mar em caraguatatuba (sp) viviane dias alves portela avaliação da vegetação como indicad: , p. 122.

Prakash, N., Manconi, A., e Loew, S., 2020, Mapping landslides on eo data: Performance of deep learning vs. traditional machine learning models: Remote Sensing, v. 12, p. 24.

Roering, J.J., Mackey, B.H., Marshall, J.A., Sweeney, K.E., Deligne, N.I., Booth, A.M., Handwerger, A.L., e Cerovski-Darriau, C., 2013, 'you are here': Connecting the dots with airborne lidar for geomorphic fieldwork: Geomorphology, v. 200, p. 172–183, doi: 10.1016/j.geomorph.2013.04.009, URL https://linkinghub.elsevier.com/retrieve/pii/S0169555X13002031.

Romero, A., Gatta, C., e Camps-Valls, G., 2016, Unsupervised deep feature extraction for remote sensing image classification: IEEE Transactions on Geoscience and Remote Sensing, v. 54, p. 1349–1362, doi: 10.1109/TGRS.2015.2478379.

Ronneberger, O., Fischer, P., e Brox, T., 2015, U-net: Convolutional networks for biomedical image segmentation, : p. 234–241, doi: 10.1007/978-3-319-24574-4_28.

Rosenblatt, F., 1958, The perceptron: A probabilistic model for information storage and organization in the brain.: Psychological Review, v. 65, p. 386–408, doi: 10.1037/h0042519.

Rossi, G., Tanteri, L., Tofani, V., Vannocci, P., Moretti, S., e Casagli, N., 2018, Multitemporal uav surveys for landslide mapping and characterization: Landslides, v. 15, p. 1045–1052, doi: DOI10.1007/s10346-018-0978-0.

Sameen, M.I., e Pradhan, B., 2019, Landslide detection using residual networks and the fusion of spectral and topographic information: IEEE Access, v. 7, p. 114,363 – 114,373, doi: 10.1109/ACCESS.2019.2935761.

Scaioni, M., Longoni, L., Melillo, V., e Papini, M., 2014, Remote sensing for landslide investigations: An overview of recent achievements and perspectives: Remote Sensing, v. 6, p. 53, doi: doi:10.3390/rs60x000x.

Schmaltz, E.M., Steger, S., e Glade, T., 2017, The influence of forest cover on landslide occurrence explored with spatio-temporal information: Geomorphology, v. 290, p. 250–264, doi: 10.1016/j.geomorph.2017.04.024, URL https://linkinghub.elsevier.com/retrieve/pii/S0169555X16312235.

Schulz, W.H., 2007, Landslide susceptibility revealed by lidar imagery and historical records, seattle, washington: Engineering Geology, v. 89, p. 67–87, doi: 10.1016/j.enggeo.2006.09.019.

Scott, G.J., England, M.R., Starms, W.A., Marcum, R.A., e Davis, C.H., 2017, Training deep convolutional neural networks for land-cover classification of high-resolution imagery: IEEE Geoscience and remote sensing letters, v. 14, p. 549–553.

Shahabi, H., e Hashim, M., 2015, Landslide susceptibility mapping using gis-based statistical models and remote sensing data in tropical environment: Scientific Reports, v. 5, p. 15, doi: DOI:10.1038/srep09899.

Shan, J., e Toth, C.K., 2009, Topographic laser ranging and scanning: Principles and processing: 1st edn., Taylor & Francis Group LLC, 1-593 p.

Sharma, A., Liu, X., Yang, X., e Shi, D., 2017, A patch-based convolutional neural network for remote sensing image classification: Neural Networks, v. 95, p. 19–28, doi: 10.1016/j.neunet.2017.07.017.

Shikada, M., Suzuki, Y., Kusaka, T., e Got, S., 1997, An application of gis information and remotely sensed data: Geoscience and Remote Sensing, 1997. IGARSS'97. Remote Sensing-A Scientific Vision for Sustainable Development, p. 7–9.

Silveira, F.J.C., e Brito, J.L.N.S., 2005, Fototriangulação pelo método dos feixes perspectivos, : .

Skansi, S., 2018, Introduction to deep learning: Springer International Publishing, doi: 10.1007/978-3-319-73004-2.

Slama, C.C., 1980, Manual of photogrammetry: American Society of Photogrammetry, 1-1056 p.

Snavely, K.N., 2008, Scene reconstruction and visualization from internet photo collections, [Ph.D. thesis]: 210 p.

Soares, L.P., Dias, H.C., Garcia, G.P.B., e Grohmann, C.H., 2022, Landslide segmentation with deep learning: Evaluating model generalization in rainfall-induced landslides in brazil: Remote Sensing, v. 14, p. 2237, doi: 10.3390/rs14092237.

Sterzai, P., Vellico, M., Berti, M., Coren, F., Corsini, A., Rosi, A., Mora, P., Zambonelli, F., e Ronchetti, F., 2010, Lidar and hyperspectral data integration for landslide monitoring: the test case of valoria landslide: Italian Journal of Remote Sensing, v. 42, p. 89–99, doi: 10.5721/ItJRS20104237.

Stumpf, A., Malet, J.P., Kerle, N., Niethammer, U., e Rothmund, S., 2013, Image-based mapping of surface fissures for the investigation of landslide dynamics: Geomorphology, v. 186, p. 12–27, doi: 10.1016/j.geomorph.2012.12.010, URL http://dx.doi.org/10.1016/j.geomorph.2012.12.010.

Summerfield, M.A., 1991, Global Geomorphology: 1st edn., Edinburgh, Pearson Education Limited, 537 p p.

Tarolli, P., 2014, High-resolution topography for understanding earth surface processes: Opportunities and challenges: Geomorphology, v. 216, p. 295–312, doi: 10.1016/j.geomorph.2014.03.008, URL http://dx.doi.org/10.1016/j.geomorph.2014.03.008.

Telling, J., Lyda, A., Hartzell, P., e Glennie, C., 2017, Review of earth science research using terrestrial laser scanning: Earth-Science Reviews, v. 169, p. 35–68, doi: 10.1016/j.earscirev.2017.04.007, URL http://dx.doi.org/10.1016/j.earscirev.2017.04.007.

Tominaga, L.K., Santoro, J., e do Amaral, R., 2009, Desastres naturais: conhecer para prevenir: Instituto geológico, 196 p p.

Tsunetaka, H., Hotta, N., Hayakawa, Y.S., e Imaizumi, F., 2020, Spatial accuracy assessment of unmanned aerial vehicle-based structures from motion multi-view stereo photogrammetry for geomorphic observations in initiation zones of debris flows, ohya landslide, japan: Progress in Earth and Planetary Science, v. 7, p. 1–14, doi: 10.1186/s40645-020-00336-0.

UNISDR, 2015, Sendai framework for disaster risk reduction 2015-2030: .

van Westen, C.J., Castellanos, E., e Kuriakose, S.L., 2008, Spatial data for landslide susceptibility, hazard, and vulnerability assessment: An overview: Engineering Geology, v. 102, p. 112–131, doi: 10.1016/j.enggeo.2008.03.010, URL http://dx.doi.org/10.1016/j.enggeo.2008.03.010.

Varnes, D.J., 1978, Slope Movement Types and Processes: Transportation Research Board Special Report, , no. 176, p. 11 – 33, doi: InSpecialreport176:LandslidesAnalysisandControl, TransportationResearchBoard,Washington,D.C.

Ventura, G., Vilardo, G., Terranova, C., e Sessa, E.B., 2011, Tracking and evolution of complex active landslides by multi-temporal airborne lidar data: The montaguto landslide (southern italy): Remote Sensing of Environment, v. 115, p. 3237–3248, doi: 10.1016/j.rse.2011.07.007, URL http://dx.doi.org/10.1016/j.rse.2011.07.007.

Vetrivel, A., Gerke, M., Kerle, N., Nex, F., e Vosselman, G., 2018, Disaster damage detection through synergistic use of deep learning and 3d point cloud features derived from very high resolution oblique aerial images, and multiple-kernel-learning: ISPRS Journal of Photogrammetry and Remote Sensing, v. 140, p. 45–59, doi: 10.1016/j.isprsjprs.2017.03.001.

Viana, C.D., 2021, Fotogrametria digital multi-escala para aquisição de dados estruturais, Tese de doutorado: 258 p.

Viana, C.D., Grohmann, C.H., dos Santos Toledo Busarello, M., e Garcia, G.P.B., 2018, Structural analysis of clastic dikes using structure from motion - multi-view stereo: a case-study in the paraná basin, southeastern brazil: Brazilian Journal of Geology, v. 48, p. 839–852, doi: 10.1590/2317-4889201800201898.

Viana, C.D., Grohmann, C.H., Monticelli, J.P., Albuquerque, R.W., Cacciari, P.P., e Futai, M.M., 2019, Slope stability assessment based on a digital outcrop model: A case-study at jardim garcia quarry., : CRC Press, p. 3604–3611.

Vosselman, G., e Maas, H.G., 2010, Airborne and terrestrial laser scanning: 1st edn., Whittles Publishing, 318 p., doi: 10.1080/17538947.2011.553487, URL http://www.amazon.com/dp/1439827982.

Wang, G., Joyce, J., Phillips, D., Shrestha, R., e Carter, W., 2013, Delineating and defining the boundaries of an active landslide in the rainforest of puerto rico using a combination of airborne and terrestrial lidar data: Landslides, v. 10, p. 503–513, doi: 10.1007/s10346-013-0400-x.

Wang, H., Zhang, L., Yin, K., Luo, H., e Li, J., 2020, Landslide identification using machine learning: Geoscience Frontiers, v. 12, p. 14, doi: https://doi.org/10.1016/j.gsf.2020.02.012.

Wang, H., Zhang, L., Yin, K., Luo, H., e Li, J., 2021, Landslide identification using machine learning: Geoscience Frontiers, v. 12, no. 1, p. 14, doi: https://doi.org/10.1016/j.gsf.2020.02.012.

Wehr, A., e Lohr, U., 1999, Airborne laser scanning-an introduction and overview: ISPRS Journal of Photogrammetry & Remote Sensing, v. 54, p. 68–82, URL http://knightlab.org/rscc/readings/airborne_laser_scanning.pdf.

Wilson, J.P., e Gallant, J.C., 2000, Terrain analysis: Principles and applications: Wiley, 1-469 p.

Wolle, C.M., 1988, Análise de escorregamentos translacionais numa região da Serra do Mar no contexto de uma classificação de mecanismos de instabilização de encostas, [Ph.D. thesis]: Universidade de São Paulo, 394 p p.

Yu, B., Chen, F., Xu, C., Wang, L., e Wang, N., 2021, Matrix segnet: A practical deep learning framework for landslide mapping from images of different areas with different spatial resolutions: Remote Sensing, v. 13, p. 16, doi: 10.3390/rs13163158.

Yu, M., Huang, Y., Zhou, J., e Mao, L., 2017a, Modeling of landslide topography based on micro-unmanned aerial vehicle photography and structure-from-motion: Environmental Earth Sciences, v. 76, no. 520, p. 9, doi: DOI10.1007/s12665-017-6860-x.

Yu, X., Wu, X., Luo, C., e Ren, P., 2017b, Deep learning in remote sensing scene classification: a data augmentation enhanced convolutional neural network framework: GIScience & Remote Sensing, v. 54, p. 741–758, doi: https://doi.org/10.1080/15481602.2017.1323377.

Zhang, L., Zhang, L., e Du, B., 2016, Deep learning for remote sensing data: IEEE Geoscience and Remote Sensing Magazine, p. 22–40.

Zhang, Q., e Seto, K.C., 2011, Mapping urbanization dynamics at regional and global scales using multi-temporal dmsp/ols nighttime light data: Remote Sensing of Environment, v. 115, p. 2320–2329, doi: 10.1016/j.rse.2011.04.032.

Zhao, W., Du, S., e Emery, W.J., 2017, Object-based convolutional neural networks for high-resolution imagery classification: IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, v. 10, p. 3386–3396, doi: 10.1109/JSTARS.2017.2680324.

Zhao, W., Guo, Z., Yue, J., Zhang, X., e Luo, L., 2015, On combining multiscale deep learning features for the classification of hyperspectral remote sensing imagery: International Journal of Remote Sensing, v. 36, p. 3368–3379, doi: 10.1080/2150704X.2015.1062157.

Zhong, C., Liu, Y., Gao, P., Chen, W., Li, H., Hou, Y., Nuremanguli, T., e Ma, H., 2020, Landslide mapping with remote sensing: challenges and opportunities: International Journal of Remote Sensing, v. 41, p. 1555–1581, doi: 10.1080/01431161.2019.1672904.

Zhong, L., Hu, L., e Zhou, H., 2019, Deep learning based multi-temporal crop classification: Remote Sensing of Environment, v. 221, p. 430–443, doi: https://doi.org/10.1016/j.rse.2018.11.032.

Zhong, Y., Fei, F., Liu, Y., Zhao, B., Jiao, H., e Zhang, L., 2016, Satcnn: satellite image dataset classification using agile convolutional neural networks: Remote Sensing Letters, v. 8, p. 136–145, doi: https://doi.org/10.1080/2150704X.2016.1235299.

Zou, Q., Ni, L., Zhang, T., e Wang, Q., 2015, Deep learning based feature selection for remote sensing scene classification: IEEE Geoscience and Remote Sensing Letters, v. 12, p. 2321–2325, doi: 10.1109/LGRS.2015.2475299.

Zuidam, R.v., 1986, Aerial photo-interpretation in terrain analysis and geomorphologic mapping, , Smits Publishers.

Anexos

Anexo A. Coorientação do trabalho de formatura apresentado ao Instituto de Geociências da Universidade de São Paulo

Anexo A.1. *Aplicação de análise de suscetibilidade a movimentos de massa em encostas naturais a partir de modelo digital de terreno de alta resolução*

UNIVERSIDADE DE SÃO PAULO

INSTITUTO DE GEOCIÊNCIAS

APLICAÇÃO DE ANÁLISE DE SUSCETIBILIDADE A MOVIMENTOS DE MASSA EM ENCOSTAS NATURAIS A PARTIR DE MODELO DIGITAL DE TERRENO DE ALTA RESOLUÇÃO

Elton Barbosa Gomes

Orientador: Prof. Dr. Carlos Henrique Grohmann de Carvalho

IEE - USP

Co-Orientador: Geol. MSc.Guilherme Pereira Bento Garcia

IGc - USP

Monografia do Trabalho de Formatura

(TF-18/10)

São Paulo, outubro de 2018

UNIVERSIDADE DE SÃO PAULO

INSTITUTO DE GEOCIÊNCIAS

APLICAÇÃO DE ANÁLISE DE SUSCETIBILIDADE A MOVIMENTOS DE MASSA EM ENCOSTAS NATURAIS A PARTIR DE MODELO DIGITAL DE TERRENO DE ALTA RESOLUÇÃO

Elton Barbosa Gomes

Orientador: Prof. Dr. Carlos Henrique Grohmann de Carvalho

IEE - USP

Co-Orientador:Geol. MSc. Guilherme Pereira Bento Garcia

IGc - USP

Monografia do Trabalho de Formatura

(TF-18/10)

São Paulo, outubro de 2018

Agradecimentos

A realização deste projeto só foi possível por que meus pais sempre me apoiaram. Meu pai e minha mãe, Antônio e Iraides, junto com minha irmã Eliana sempre estavam me ajudando e incentivando, além de bancarem toda a minha estadia fora de casa. Ao meu irmão Emerson que me ajudou em boa parte do cursinho. A minha namorada Camila que sempre esteve ao meu lado nos mais difíceis momentos durante a minha graduação, apoiando e incentivando. Agradecimentos especiais a toda minha família.

Agradeço ao meu orientador Carlos Grohmann e ao meu co-orientador Guilherme Garcia por toda a ajuda na elaboração deste trabalho. Sempre solícitos e dispostos a esclarecer minhas dúvidas. A Camila Duelis Viana que nos acompanhou durante o trabalho de campo e também me ajudou em alguns questionamentos.

Agradeço a FAPESP por financiar este trabalho através do projeto 2016/06628-0, e também a todas as pessoas do SPAMLab que estavam sempre dispostas a ajudar.

SUMÁRIO

RESUMO **2**

ABSTRACT **3**

1. INTRODUÇÃO **4**

2. METAS E OBJETIVOS **5**

2.1. LOCALIZAÇÃO DA ÁREA DE ESTUDO 6

3. FUNDAMENTAÇÃO BIBLIOGRÁFICA **6**

3.1. CONTEXTO GEOMORFOLÓGICO E GEOLÓGICO 6

3.2. PEDOLOGIA 8

3.3. CLIMA E VEGETAÇÃO 8

3.4. MOVIMENTOS GRAVITACIONAIS DE MASSA 9

Escorregamentos *9*

Quedas de blocos *10*

Subsidências *10*

Escoamentos *10*

4. MATERIAIS E MÉTODOS **12**

5. RESULTADOS **18**

MAPA HIPSOMÉTRICO 18

MAPA DE DECLIVIDADE 18

MAPA DE CURVATURAS 20

MAPA DE ASPECTO 22

MAPA DE RUGOSIDADE 23

CARTA DE SUSCETIBILIDADE 24

6. INTERPRETAÇÃO E DISCUSSÃO DOS RESULTADOS **26**

7. CONCLUSÕES **27**

8. REFERÊNCIAS BIBLIOGRÁFICAS **28**

RESUMO

Encostas de morros, principalmente com ausência de vegetação, sofrem diversos processos erosivos que podem comprometer sua estabilidade. A ocorrência de movimentos gravitacionais de massa nesses taludes geralmente é causada por fenômenos naturais como chuvas e terremotos, e quando próximo a rodovias ou regiões habitadas podem causar enormes prejuízos econômicos, perdas ambientais e mortes. Um dado importante sobre qualquer área é a probabilidade de ocorrência desses movimentos de massa. Estudos mostram que dados como o SRTM (*Shuttle Radar Topographic Mission*) são capazes de fornecer informações suficientes para uma escala regional. A utilização do LiDAR (*Light detection and Ranging*) permite obter dados com precisão milimétrica a centimétrica, melhorando o grau de precisão para uma escala local. Este trabalho tem o objetivo de apresentar dados morfológicos e ao final uma carta de suscetibilidade à movimentos de massa, baseado em um Modelo Digital de Terreno gerado por LiDAR terrestre. Foram gerados mapas de declividade, curvaturas e rugosidade e atribuídos “pesos” para esses mapas. A partir de uma análise estatística bivariada baseada no valor informativo, foi gerada uma carta de suscetibilidade para o local em que ocorreu movimento de massa. Os resultados mostraram que embora haja locais com altas declividades próximas ao escorregamento, esses locais possuem baixa suscetibilidade, e que o local do escorregamento possuía uma alta suscetibilidade antes de ocorrer, o que foi possível determinar através da reconstituição da superfície original do modelo de terreno.

ABSTRACT

Hillslopes, mainly with absence of vegetation, undergo several erosive processes that can compromise their stability. The occurrence of mass gravitational movements on these slopes is usually caused by natural phenomena such as rains and earthquakes, and when near to highways or inhabited regions can cause huge economic and environmental losses, and deaths. Studies show that data such as SRTM (Shuttle Radar Topographic Mission) are able to provide sufficient information for a regional scale. Use of LiDAR (Light detection and Ranging) allows data survey to be obtained with millimeter-to-centimeter precision, improving the accuracy for a local scale. This work presents morphological data and a landslide-susceptibility map, based on a terrestrial LiDAR Digital Terrain Model. Slope, curvature and roughness were weighted to compute and generate susceptibility map for a landslide area. Identification of other landslides prone areas were also achieved. In conclusion, high slope areas near the slide usually shows low susceptibility values, and original surface reconstruction demonstrates that landslide occurrence is associated with major susceptibility.

1. INTRODUÇÃO

Encostas de morros, principalmente com ausência de vegetação, sofrem diversos processos erosivos que podem comprometer sua estabilidade. A ocorrência de movimentos gravitacionais de massa nesses taludes geralmente é causada por fenômenos naturais como chuvas e terremotos, e quando próximo a rodovias ou regiões habitadas podem causar enormes prejuízos econômicos, perdas ambientais e mortes (Guerra *et al.* 2007).

Um dos maiores limitantes na previsão e mapeamento dos deslizamentos é a falta de compreensão dos processos como erosão, precipitação e fraturamento das rochas (Glenn et al. 2006).

O estudo de estabilidade de taludes e movimentos de massa é fundamental para um planejamento quando se deseja realizar algum tipo de intervenção, seja para prevenção em locais que estejam em risco ou para a tomada de decisão de locais para a instalação de uma futura obra.

Nos últimos anos diversas técnicas estão sendo desenvolvidas para aumentar as informações obtidas através de sensores remotos que utilizam parâmetros geomorfológicos para identificar processos e produtos. Tecnologias que podem ser aerotransportadas ou terrestres como o LiDAR (*Light detection and Ranging*) para obtenção de dados topográficos em alta resolução e permitem identificar escorregamentos de terra, processos de canalização de vertentes, morfologia de rios, áreas tectônicas ativas etc (Tarolli 2014).

O LiDAR possui algumas vantagens quando comparado com as técnicas tradicionais de sensoriamento remoto, como conseguir filtrar a vegetação ou objetos que estão na superfície e produzir Modelos Digitais de Terreno (MDTs) (Tarolli 2014).

Segundo Rowlands *et al.* (2003) o escaneamento a laser aplicado à deslizamentos oferece muitas vantagens em relação ao método de fotografias áreas, como a elaboração de um modelo topográfico tridimensional; sendo um método mais preciso e com pouca interferência humana na aquisição dos dados. O processamento de dados rápido e com varreduras repetidas exalta mudanças quantitativas na topografia que podem ser indicativos de atividades de escorregamentos.

2. METAS E OBJETIVOS

O título e objetivos do projeto foram alterados devido as mudanças ocorridas durante a etapa de campo e a falta de recursos para realizar um estudo mais aprofundado e classificar os riscos da área estudada.

Os principais objetivos desse projeto são mostrar uma forma rápida e precisa de adquirir dados de terreno para análise de superfície, apresentar uma carta de suscetibilidade para o local analisado e gerar mapas temáticos (hipsometria, declividade, aspecto, curvaturas em planta e perfil), para caracterizar os escorregamentos, assim como identificar através de características semelhantes, locais dentro da área de estudo que são suscetíveis a novos escorregamentos, utilizando para este fim dados topográficos de alta resolução obtidos por LiDAR. A figura 1 mostra o LiDAR gerando a nuvem de pontos e a figura 2 o local do escorregamento.

Figura 1: Imagem do LiDAR (Light Detecting and Ranging) gerando a nuvem de pontos.

Figura 2: Imagem do escorregamento.

2.1. Localização da área de estudo

A área de estudo está localizada no município de Cunha-SP e possui uma área de 15196,3 m². O acesso até a área é realizado de São Paulo pela Rodovia Presidente Dutra até a cidade de Guaratinguetá, utiliza-se a saída para a Rodovia Paulo Virgínio (SP-171), seguindo até a cidade de Cunha (Figura 3). A escolha da encosta para ser estudada nesse projeto foi efetuada durante a primeira etapa de campo.

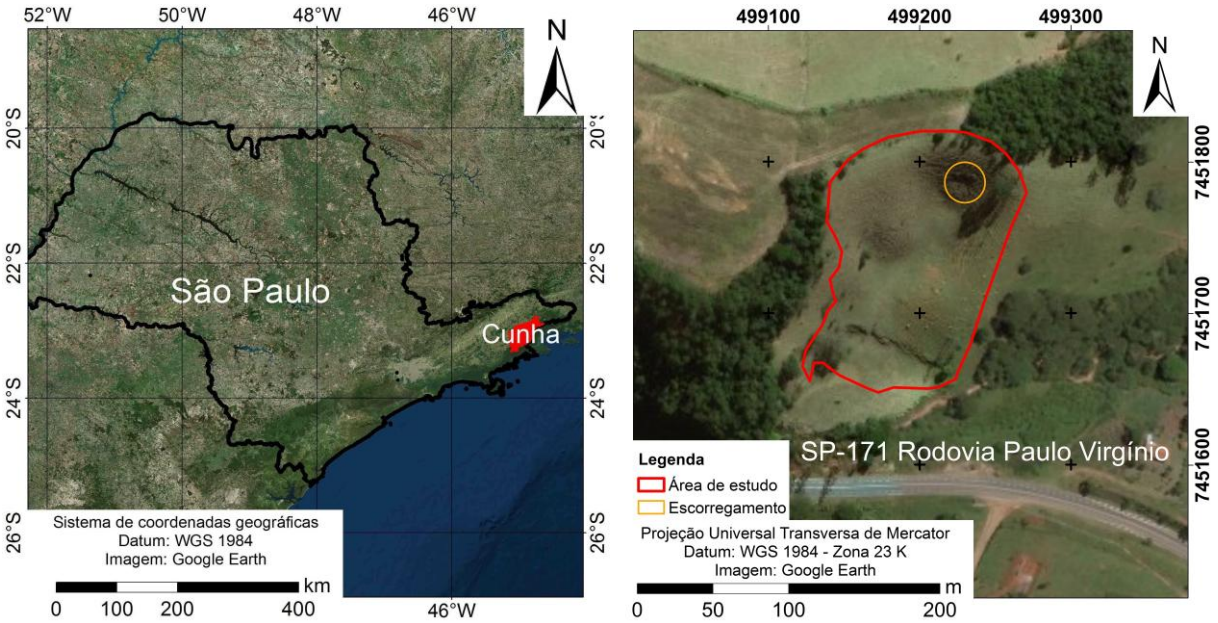

Figura 3: Localização da área de estudo (Fonte: Google Earth Pro. Satélite: Landsat, acessado em 20/07/2018).

O local escolhido foi um escorregamento no km 39,5 da Rodovia Paulo Virgínio (SP-171), composto principalmente por um pasto (Figura 3). Esse local se mostrou ideal, pois havia pouca vegetação que poderia atrapalhar na coleta de dados e de fácil acesso através de uma das fazendas.

3. FUNDAMENTAÇÃO BIBLIOGRÁFICA

3.1. Contexto Geomorfológico e Geológico

A área de estudo está inserida no conjunto de escarpas festonadas da Serra do Mar com aproximadamente 100 km de extensão que se estende do Rio de Janeiro ao Norte de Santa Catarina. Próximo ao município de Cunha, a Serra do Mar se localiza na borda do planalto com altitudes que variam entre 800 a 1200 metros (Almeida & Carneiro 1998).

A direção geral da Serra do Mar acompanha a orientação ENE das estruturas do Escudo Atlântico. A complexa história registrada entre o Pré-Cambriano e o Eopaleozóico que originou diversas associações migmatíticas e metamórficas, assim como inúmeros

complexos ígneos, explica a ampla variedade de tipos litológicos do embasamento exposto (Almeida & Carneiro 1998).

Localmente na região de estudo ocorrem as zonas de cisalhamento Caucaia-Rio-Jaguari a norte e a zona de cisalhamento Cubatão na porção sul, ambos de direção N70ºE e cortado transversalmente pela zona de cisalhamento Taxaquara-Guararema com direção N80ºE (Silva 2017).

A área de estudo está situada na Província Planalto Atlântico (Almeida 1964), apresentando segundo a classificação do IPT (1981) relevo de morros e relevo montanhoso.

O Planalto Paraitinga (Almeida 1964) constitui a região de drenagem da bacia do rio Paraíba e apresenta-se como um planalto cristalino de estrutura complexa. Dentro desta zona estão presentes três domínios: Mar de Morros, Morros Paralelos e Serras Alongadas. O Domínio de Mar de Morros é caracterizado por formas suavizadas de topos arredondados e vertentes com perfis convexos a retilíneos sem herança estrutural acentuada e drenagem de alta densidade. O Domínio de Morros Paralelos, na porção central da área, é caracterizado por formas de topos arredondados e vertentes de perfis retilíneos a convexos. A drenagem é de alta densidade com padrão em treliça a localmente subdendrítica, e declividades médias a altas (superiores a 15%). O terceiro domínio, Serras Alongadas, ocorre entre os domínios de morros. O relevo é do tipo montanhoso com predomínio de declividades médias a altas e amplitudes locais acima de 300 metros, sendo caracterizado por formas de topos angulosos e vertentes ravinadas com perfis retilíneos e algumas vezes abruptos (Viana et al., 2012).

Segundo Perrota *et al.* (2005) o local de estudo está inserido dentro do Complexo Rio Capivari – Núcleo Cunha (Figura 4A). Esse complexo ocorre entre as cidades de São José dos Campos e Paraibuna, representa o embasamento do Complexo Embu, o qual ocorre intercalado em forma de estreitas faixas concordantes com a estruturação (Fernandes 1991).

O Complexo Rio Capivari apresenta uma estrutura alongada e encravada em zonas de cisalhamento (Heilbron *et al.* 2004), sendo caracterizado por migmatitos com mesossoma de biotita-hornblenda gnaisses de composição quartzo diorítica-tonalítica, com duas gerações de neossomas, sendo o mais antigo trondhjemítico ou granodiorítico, cinza, e o mais jovem granítico, róseo. Anfibolitos e, mais raramente, rochas calcissilicáticas ocorrem em meio a estas rochas. Ortognaisses de aspecto homogêneo, localmente mais migmatíticos, e de composição granítica a tonalítica são abundantes e se associam aos migmatitos (Fernandes 1991).

O Complexo Rio Capivari – Núcleo Cunha apresenta 19 km comprimento e 2 km de largura, com predomínio de hornblenda-biotita gnaisses tonalíticos, inequigranulares médios

a finos com raríssimos feldspatos potássicos. A maior abundância de leucossomas portadores de hornblenda, em bandas com até 2 cm de espessura, cinzas claros ou rosados, leucocráticos a hololeucocráticos, conferem-lhe em alguns locais, aspecto de migmatito. Boudins centimétricos a decimétricos, anfibolíticos e boudins mais escassos centímetricos de rochas calciossilicáticas são englobadas pelas rochas descritas (Fernandes 1991).

3.2. Pedologia

A pedologia do local (Figura 4B) com base no mapa da Embrapa (1999) é composta por Latossolos Vermelhos-Amarelos, que são profundos, possuem cores vermelha e amarela, com boa drenagem e geralmente baixa fertilidade natural. São constituídos por material mineral não hidiomórficos e são solos menos resistentes ao intemperismo devido a ausência de mineriais primários e secundários, assim tem um estágio avançado de intemperização e são muito evoluídos. O latossolo Vermelho-Amarelo está associado ao Complexo Embu e ao Complexo Rio Capivari (IBGE 2007).

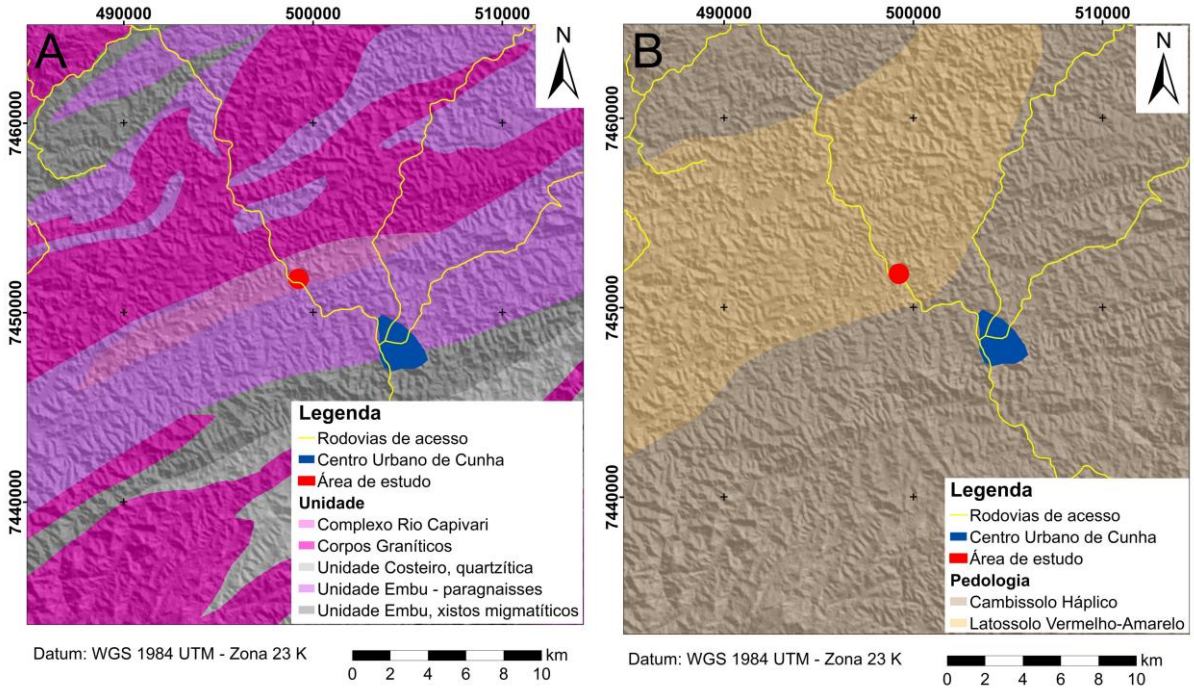

Figura 4: Mapas Geológico e pedológico. Em A, Mapa geológico com destaque em vermelho para o local estudado, modificado de Perrota et al. (2005), escala 1:750.000. Em B, Mapa pedológico com destaque em vermelho para a área de estudo, modificado de Embrapa (1999), escala 1:500.000.
Utilizado o MDE do SRTM (Shuttle Radar Topography Mission) com resolução de 1 arco de segundo. Os mapas são sobrepostos ao relevo sombreado com o azimute a 45º e inclinação a 20º para mostrar feições de relevo e padrões que possam auxiliar na caracterização da topografia.

3.3. Clima e Vegetação

Segundo Da Silva et al. (2005), a cidade de Cunha é classificada como o clima do tipo Cfb pela classificação de Koppen & Geiger (1936), caracterizado como um clima temperado úmido, com período úmido de outubro a março (estação chuvosa) e o período

seco de abril a setembro. A temperatura média anual é de 16,5 ºC, com média de 10 ºC no inverno e 22 ºC no verão. A precipitação média anual é de 2276 mm (Ranzini 2002), com forte efeito da neblina, o que provoca altos índices pluviométricos na região (Anido 2002).

Segundo Da Silva et al. (2005), a cobertura da área é uma vegetação natural secundária, sucessora da vegetação primária Mata Atlântica, o que foi um resultado da exploração madeireira ocorrida no século passado (Da Silva et al., 2005).

O município de Cunha é predominantemente rural onde o uso e ocupação do solo por atividades agropecuárias são bastante expressivos por todo o território do município (Secretaria de Agricultura e Abastecimento, CATI/IEA, Projeto LUPA, 2008).

3.4. Movimentos gravitacionais de massa

Segundo Summerfield (1991), os movimentos de massa são caracterizados como movimentos descendentes do material da encosta sob influência diretamente da força gravitacional e sem o auxílio de movimentos de água, gelo ou ventos.

Os diferentes tipos de movimentos de massa dependem de condições locais, como estrutura geológica, tipo de materiais, declividade, orientação e forma de vertente, área de contribuição, intensidade e distribuição das precipitações (Guimarães *et al.* 2008).

Segundo Guidicini e Nieble (1984) e IPT (1991), as classificações dos movimentos de massa são: escorregamentos (translacionais e rotacionais), quedas de blocos, subsidências e escoamentos (rastejos e corridas).

Escorregamentos

Os escorregamentos caracterizam-se como processos que ocorrem de forma rápida, com um plano de ruptura definido, o qual separa o material escorregado do não movimentado. São divididos em dois tipos: rotacionais e translacionais (Figura 5) (Guimarães *et al.* 2008).

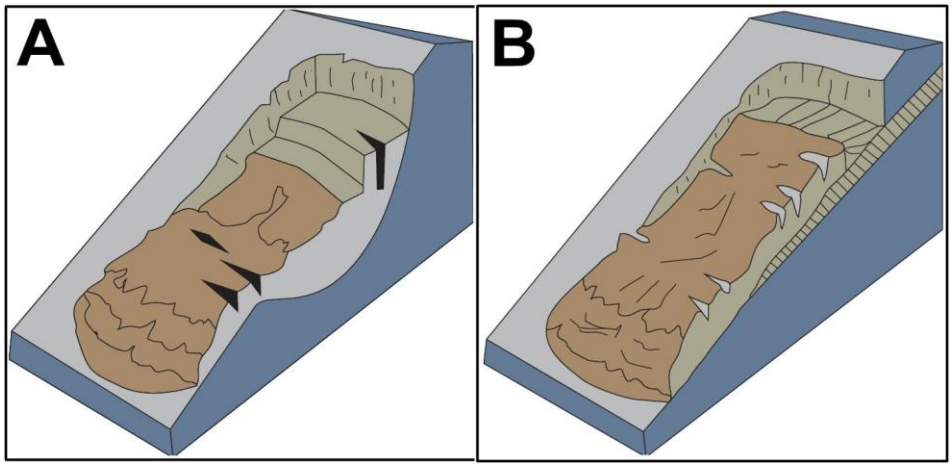

Figura 5: Tipos de escorregamentos. Em A, escorregamento do tipo Rotacional. Em B, escorregamento do tipo Translacional. (USGS 2004).

Os escorregamentos rotacionais são caracterizados por possuírem uma superfície de ruptura curva e côncava que desloca normalmente uma grande quantidade de material de forma rotacional (Guidicini & Nieble 1984; IPT 1991). Esse tipo de escorregamento está vinculado a regiões com formações de pacotes de solo bem desenvolvidos. Seu início, muitas vezes, vincula-se ao desgaste natural da base da encosta, devido ao sistema fluvial, ou então, ao desenvolvimento de condições artificiais, como, cortes de encostas para a construção de estradas (Guimarães *et al.* 2008).

Os escorregamentos translacionais caracterizam-se por apresentarem um plano de ruptura abrupto, bem definido, planar, e por serem um movimento de curta duração (Guidicini & Nieble 1984; IPT 1991). Esses movimentos ocorrem durante chuvas intensas, quando é elevada a poropressão em uma superfície de descontinuidade. A poropressão positiva da água no plano de ruptura altera a estabilidade da encosta, reduzindo a tensão efetiva do solo e a tensão normal. A ruptura ou a instabilidade da encosta depende do equilíbrio entre as forças estabilizadoras e desestabilizadoras (Guimarães *et al.* 2008).

Quedas de blocos

As quedas de blocos podem ser divididas em quedas de rocha ou de solo, são movimentos rápidos em queda livre pela ação da gravidade e típicos de áreas muito íngremes (Guidicini & Nieble 1984). Nos locais onde esse tipo de movimentos ocorre, normalmente existem fraturas nos paredões rochosos ou um desgaste na base da encosta, o que provoca a queda superior do bloco. Além disso, descontinuidades e/ou alívios de tensão poderão ocasionar quedas (Guimarães *et al.* 2008).

Subsidências

As subsidências são movimentos em que o deslocamento da massa normalmente é vertical, com uma componente horizontal nula ou praticamente nula (Guidicini & Nieble 1984). O fenômeno pode ser de origem natural (epirogenia e falhamentos) ou antrópica, pela retirada de material subterrâneo como: água, petróleo, gás e minério (Guimarães *et al.* 2008).

Escoamentos

Os escoamentos são movimentos contínuos e não apresentam necessariamente uma superfície definida. Podem ser divididos de acordo com suas velocidades, em lentos (rastejo) e rápidos (corridas de massa) (Guimarães *et al.* 2008).

Os rastejos são movimentos lentos e contínuos, que ocorrem nas vertentes sem limites definidos. Podem envolver grande quantidade de material, cuja movimentação normalmente é provocada pela ação da gravidade. Pode ser deflagrada por eventos de chuva de longa duração e altos índices pluviométricos acumulados, que acarreta elevação

progressiva do nível d´água subterrâneo e tendem a instabilizar os terrenos. Desenvolve-se segundo superfícies de rupturas irregulares e pode ser acelerado por intervenções humanas. Pode ocorrer de modo isolado ou associado a escorregamentos (Guimarães *et al.* 2008).

As corridas de massa são caracterizadas por movimentos rápidos, nos quais os materiais se comportam como fluidos altamente viscosos (Guidicini & Nieble 1984; IPT 1991). Esses movimentos mobilizam um expressivo volume de material em um curto período de tempo, com grande velocidade e capacidade de transporte, o qual alcança grandes distâncias (Gramani & Augusto Filho 2004).

Os principais métodos de previsão de movimentos de massa podem ser divididos em quatro grupos: análise da distribuição dos movimentos de massa no campo; análise baseada em mapeamentos geomorfológicos e/ou geotécnicos; aplicação com modelos de bases estatísticas e aplicação de modelos matemáticos (Montgomery & Dietrich, 1994; Fernandes *et al.* 2001).

Neste trabalho será utilizada a análise baseada em parâmetros geomorfológicos, nos quais os mapas temáticos serão gerados a partir dos dados obtidos em campo por LiDAR. Nesses mapas são obtidas ponderações, sendo atribuídos “pesos”, levando em consideração a relevância da característica do mapa analisado para o cálculo da suscetibilidade do terreno a partir do método de Yin & Yan (1988) que utiliza a análise estatística bivariada aplicada.

4. MATERIAIS E MÉTODOS

O método utilizado permite uma interpretação precisa das características morfométricas e morfológicas da área, utilizando dados obtidos com o LiDAR. Para isso, a meotodologia adotada foi constituída por revisão bibliográfica, usos de material cartográfico e *softwares* para processamento de dados SIG que foram coletados em campo, confecção de mapas temáticos (hipsometria, declividade, curvatura, rugosidade) e como produto final a elaboração da carta de suscetibilidade.

As atividades de campo foram realizadas entre os dias 06 a 08 de maio e foram divididos em duas partes. A primeira parte, realizada no dia 06 de maio, foi programada para identificação da área de estudo, e consistiu basicamente em percorrer a Rodovia Paulo Virgínio (SP-171) e algumas estradas vicinais a fim de efetuar o reconhecimento de encostas que sofreram movimentos gravitacionais de massa, e fossem acessíveis para a coleta de dados através do equipamento de escaneamento a laser. Buscou-se também escolher uma encosta com vegetação esparsa ou mesmo ausência de vegetação, pois a mesma poderia interferir no processo de escaneamento prejudicando a qualidade dos dados.

O local escolhido foi um escorregamento no km 39,5 da Rodovia Paulo Virgínio (SP-171), composto principalmente por um pasto e de fácil acesso através de uma das fazendas.

Na segunda parte da atividade de campo no dia 07/05, foi realizada a coleta de 11 visadas para geração de uma nuvem de pontos do talude, para isso foi utilizado o equipamento LiDAR da marca FARO, modelo Focus^{s} 150, um equipamento que permite varreduras precisas até 150 metros de distância.

Segundo Jones (2010), o LiDAR acoplado com um sistema de posicionamento GPS (*Ground Positioning System*) permite uma digitalização precisa do modelo de terreno tridimensional, podendo realizar varias varreduras independente do período escolhido e compara-las, avaliando diferenças na morfologia, tanto quantitativa como qualitativa.

A coleta de dados ocorrerá seguindo a metodologia proposta por Buckley *et al.* (2008), utilizando vários pontos de visada para realizar a varredura, a fim de ter uma sobreposição de imagens e preencher porções sombreadas. A figura 6 mostra o posicionamento do LiDAR em dois pontos distintos.

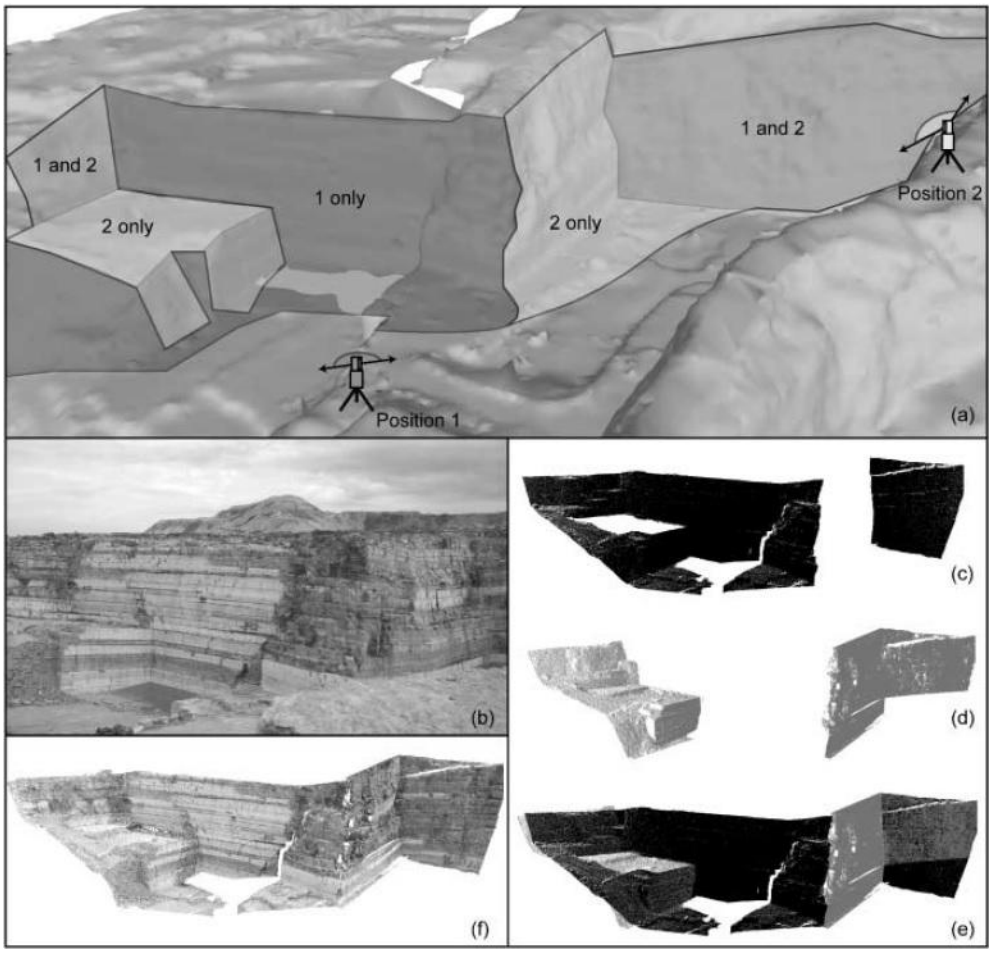

Figura 6: Sobreposição entre varreduras para preencher sombras. Exemplo mostra os carbonatos do Cretáceo Inferior expostos na pedreira de Apricena na Itália, no local foram necessárias várias varreduras para capturar as diversas faces. (a) Ilustração esquemática de sobreposição de duas varreduras. (b) Imagem do afloramento. Foram necessárias duas varreduras (c) e (d) para cobrir as faces mostradas em (a). (e) Nuvens de pontos mesclados, (f) nuvem de ponto colorido. Extraído de Buckley *et al.* (2008).

A aquisição de dados contou com a ajuda de um técnico contratado da empresa Tomasini, juntamente com o Orientador e Co-Orientador. Após a coleta de dados, o pós-processamento da nuvem de pontos foi efetuado pela própria empresa Tomasini, e consistiu basicamente no georreferenciamento, filtragem e geração de uma malha. Dessa forma, o arquivo final que foi utilizado nesse projeto era uma única nuvem de pontos formada pela intersecção das 11 nuvens obtidas em campo.

Analise geomorfológica

A análise geomorfológica se inicia com o processamento de dados para a interpretação de dados morfométricos a partir da nuvem de pontos gerada pelo LiDAR. O *software CloudCompare* foi utilizado para a aplicação de filtros e retirada de pontos não representativos do relevo, como árvores e moitas ou até mesmo erros gerados pela nuvem, conhecidos como *outliers*. Utilizando o filtro *Cloth Simulation Filter* (CSF) (Zhang *et al.* 2016), e tendo como parâmetro de entrada a resolução espacial de 10 centímetros, foram retirados os *outliers* que distavam 50 centímetros ou mais da superfície da nuvem, restantes

apenas pequenos arbustos, cupins e demais elementos menores. Em seguida, os dados foram processados no software GRASS GIS. O primeiro *raster* gerado a partir da nuvem de pontos foi para mostrar sua densidade de pontos com resolução espacial de 1 metro, ou seja, os valores mostrados no mapa representam a quantidade de pontos coletados pelo LiDAR por metro quadrado (Figura 7).

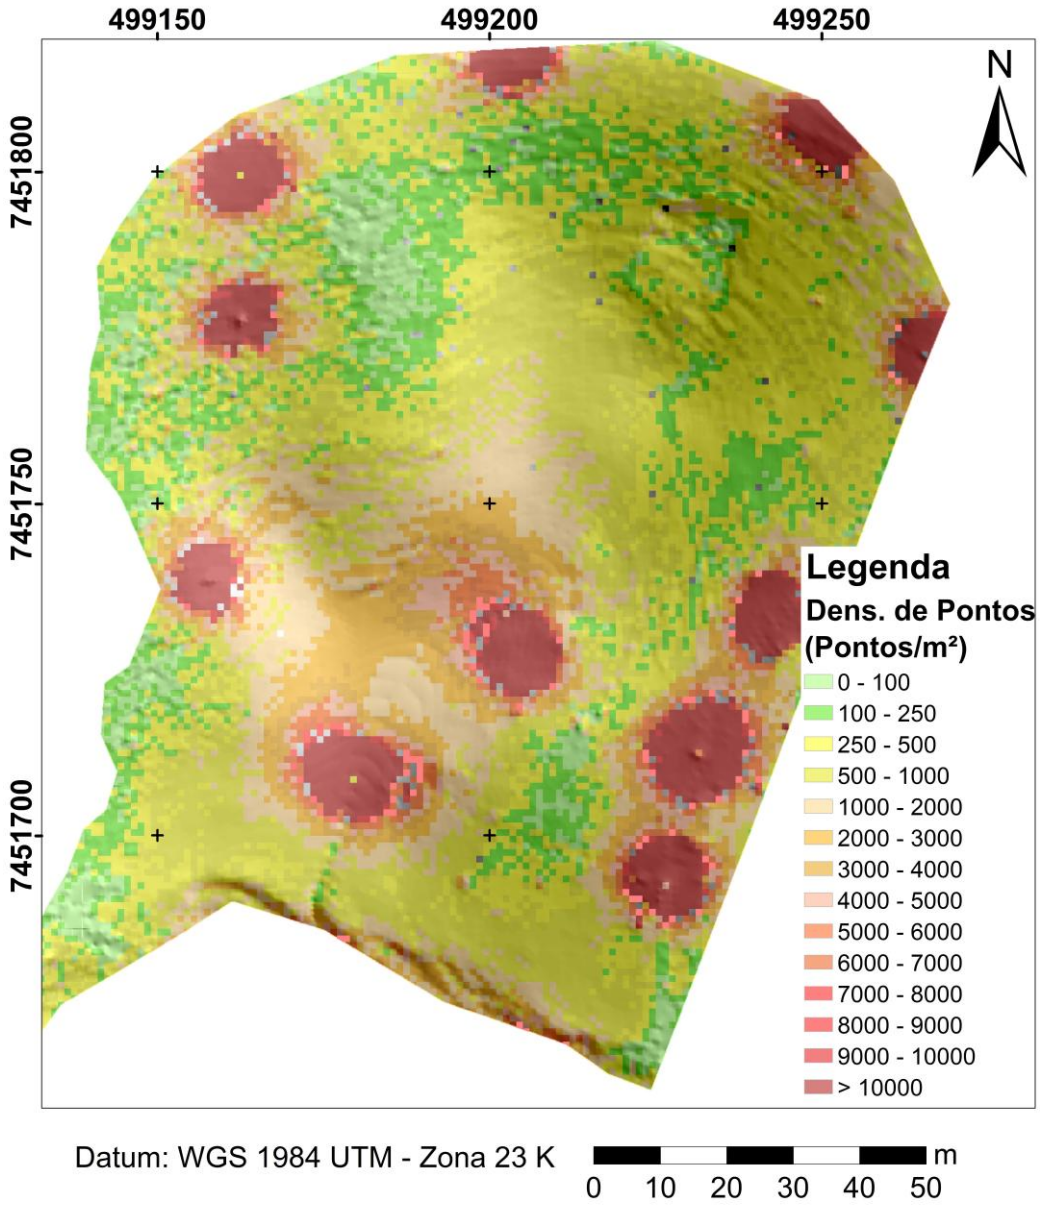

Figura 7: Mapa de densidades de pontos gerados pelo LiDAR.

O mapa de densidade de pontos mostra que a maior quantidade de pontos se concentra perto dos locais onde o sensor LiDAR foi posicionado para efetuar as visadas do escorregamento. Como o ângulo entre os feixes emitidos pelo sensor é constante, quanto maior for a distância de alcance, maior será a distância entre os pontos e menor a densidade (Buckley *et al.* 2008).

A resolução da nuvem de pontos é dada pela distância entre cada ponto, em média essa distância foi de 10 centímetros para os locais mais distantes do sensor, assim todos os processos seguintes serão realizados nessa resolução espacial.

A densidade dos pontos é maior próxima ao sensor, fazendo com que a resolução seja maior nesse local. Para homogeneizar os dados os pontos com menor valor de elevação dentro da resolução de 10 centímetros serão usados para atribuir o valor do pixel correspondente e gerar o MDE. Como após esse processo existiram lacunas no modelo, devido a ausência de pontos com essa resolução em locais mais afastados das visadas, as lacunas foram preenchidas pelo método de interpolação das médias dos vizinhos mais próximos (Mainar Ruiz & Perez Cortes 2006).

Com o MDE com resolução espacial de 10 centímetros gerado a partir da nuvem de pontos foi possível criar um arquivo vetorial das curvas de nível com intervalos de 50 centímetros entre as elevações.

O relevo original da encosta, anterior ao escorregamento, foi reconstituído manualmente a partir do arquivo vetorial das curvas de nível e na sequência interpolado para gerar um novo MDE, que representa a reconstituição da encosta (Figura 8).

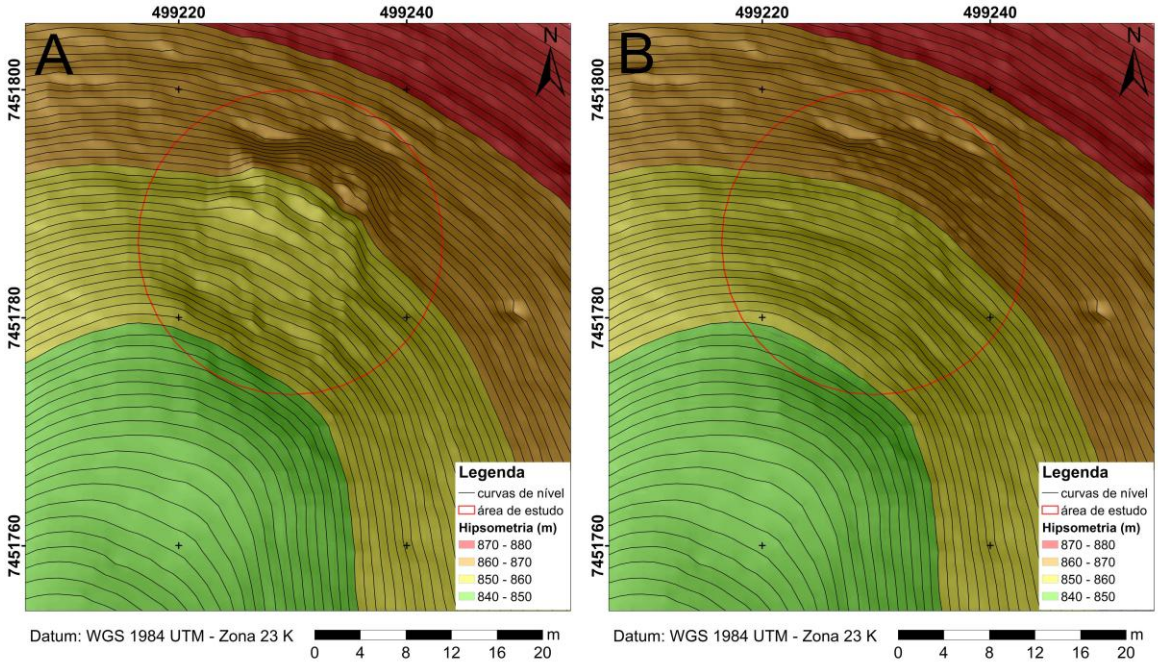

Figura 8: Mapa hipsométrico com curva de nível, com detalhe para o escorregamento. Em A as curvas de nível foram geradas a partir do MDE original. Em B as curvas de nível foram reconstruídas manualmente a partir das curvas de nível de A.

Com o MDE gerado pelos dados coletados em campo e o MDE reconstituído foi possível calcular o volume do material deslocado realizando uma operação aritmética entre os *rasters*. Assim puderam ser comparados os volumes de material que se depositaram na base do escorregamento com o material removido.

Além desses processos foram gerados mapas de declividade, curvatura em planta, curvatura em perfil, aspecto e rugosidade que serão utilizados para a análise morfométrica e geomorfológica da encosta.

Os procedimentos adotados para a elaboração da caracterização da suscetibilidade são baseados em Fell *et al.* (2008) e Julião *et al.* (2009). As suscetibilidades são analisadas seguindo Bitar *et al.* (2014), no qual é elaborado um mapa de áreas suscetíveis a movimentos gravitacionais de massa, compartimentando o terreno em zonas através dos comportamentos homogêneos desses processos. Assim serão considerados como fatores fundamentais a elevação, a declividade do terreno, a curvatura das encostas e a rugosidade. As zonas foram classificadas denotando os distintos graus de incidência espacial, denominados classes de suscetibilidade (alta, mediana, baixa, muito baixa e insignificante) e indicam a propensão relativa dos terrenos ao fenômeno abordado.

Os procedimentos para a elaboração do mapeamento da suscetibilidade a movimentos gravitacionais de massa estão fundamentados no paradigma de que os registros do passado são um guia para a análise do futuro, áreas com características geomorfológicas e geológicas semelhantes às de lugares afetados por escorregamentos são propensas a novas ocorrências (Fell *et al.* 2008).

A definição classes dos graus de suscetibilidade serão delimitados utilizando a análise estatística bivariada aplicada que utiliza o valor informativo (Yin e Yan, 1988). A metodologia se baseia na densidade de escorregamentos em cada uma das classes morfológicas para cada parâmetro, gerando um valor informativo (Ii) para cada classe (Equação 1) após se define a suscetibilidade(ij) (Equação 2) (Dias *et al* 2018).

Equação 1

$$Ii = log \frac{Si/Ni}{S/N}$$

Onde:

Si: número de pixels com escorregamentos rasos na variável Xi, sendo Xi uma variável para cada classe;

Ni: número de pixels com a variável Xi;

S: número total de pixels com escorregamentos na área de estudo total;

N: número total de pixels na área total de estudo.

Equação 2

$$Ij = \sum_{i=1}^{n} Xji * li$$

Onde:

n: número de variáveis;

Xij: igual a 1 ou 0, dependendo se a variável Xi está ou não presente no pixel j.

Utilizando a equação 1 e o *GRASS GIS*, foi calculada a quantidade de pixels existentes em cada classe de cada parâmetro, da mesma forma calculada a quantidade de pixels existentes que continham o escorregamento e a quantidade de pixels do escorregamento. Assim foi obtido o valor informativo (Ii), juntamente com o valor da suscetibilidade (ii), utilizando a equação 2.

5. RESULTADOS

Com a reconstrução manual das curvas de nível e a partir de métodos de interpolação, foi efetuada a restauração da superfície anterior ao escorregamento, sendo possível comparar as duas superfícies, a observada em campo e a restaurada a fim de calcular o volume do material e possivelmente sua massa movida através do escorregamento. Para o material que foi deslocado, o volume foi de 71,69 m^3, enquanto que para o que se depositou na base do escorregamento o volume foi de 77,74 m^3, uma diferença de 6,05 m^3, que pode indicar que houve um acúmulo de material de outra proveniência ou ainda, e mais provável, que o material sofreu uma expansão.

Segundo o mapa e caracterização de solos da Embrapa (1999), na área de estudo o solo é composto pelo Latossolo Vermelho-Amarelo, e é conhecido que a densidade do solo varia de acordo com as suas características (Torres & Saraiva, 1999). Na área de estudo o solo é definido como argilo-arenoso, sendo que sua densidade pode variar de 1,0 a 1,4 g/cm^3, considerando uma média desse valor e a partir dos volumes calculados pela álgebra dos MDE, é possível inferir que a massa deslocada é de aproximadamente 86 toneladas. O escorregamento possui uma dimensão de aproximadamente 14,5 metros de comprimento por 10 metros de largura, totalizando uma área calculada de 140,7 m^2, com volume de 71,69 m^3 e possui quase 2 metros de escarpa de talude.

A análise da geomorfologia consistiu na elaboração de mapas temáticos a partir da nuvem de pontos, os mapas foram sobrepostos ao relevo sombreado com o azimute a 45º e inclinação a 20º para mostrar feições de relevo e padrões que possam auxiliar na caracterização da topografia.

Mapa hipsométrico

A hipsometria é o modelo digital de elevação (MDE) que representa a elevação do relevo em metros, com cotas altimétricas hierarquizadas e classificadas, permitindo a identificação da amplitude altimétrica do terreno. Com essa divisão se observa que a porção norte possui as maiores altitudes enquanto que a porção centro-sul até a porção sul, as menores, dando a forma de uma “ferradura”.

Mapa de declividade

Mapas de declividade representam as inclinações do terreno, fornecidas em graus ou percentuais. A declividade é a primeira derivada do MDE, no qual foi calculado utilizando o *software ArcGIS*®, as Equações 3 e 4 apresentam etapas preliminares e a Equação 5 destaca a etapa final para a obtenção da declividade em graus. A Tabela 1 ilustra os significados de cada variável utilizada nas fórmulas. A Figura 9 destaca a estrutura das variáveis que fazem menção das células vizinhas do pixel central de um *raster*, no qual cada

letra representa 1 pixel. Todas as fórmulas foram obtidas por meio do sítio do *ArcGis* (ESRI, 2018) e baseado no trabalho de Burrough e McDonell (1998).

a	b	c
d	e pixel central	f
g	h	i

Figura 9: Estrutura das células para calcular o valor da declividade, em relação ao pixel central. (ESRI 2018)

Elementos da fórmula	**Significado**
$\left[\frac{dz}{dx}\right]$	Taxa da variação da superfície em relação ao eixo horizontal.
$\left[\frac{dz}{dy}\right]$	Taxa da variação da superfície em relação ao eixo vertical.
$x_{resolução}$	Resolução espacial do raster no eixo horizontal.
$y_{resolução}$	Resolução espacial do raster no eixo vertical.
$ATAN$	Arco tangente.
D_{graus}	Declividade em graus.
a, b, c, d, f, g, h, i	Valores das células vizinhas ao pixel central (e), conforme mostrado na Figura 8.

Tabela 1: Variáveis e constantes das Equações 3, 4 e 5

Equação 3

$$\left[\frac{dz}{dx}\right] = \frac{(c + 2f + i) - (a + 2d + g)}{8 * x_{resolução}}$$

Equação 4

$$\left[\frac{dz}{dy}\right] = \frac{(g + 2h + i) - (a + 2b + c)}{8 * y_{resolução}}$$

Equação 5

$$D_{graus} = \left(ATAN \sqrt{\left[\frac{dz}{dx}\right]^2 + \left[\frac{dz}{dy}\right]^2} \right) * \left(\frac{180}{\pi}\right)$$

O local apresenta uma grande variação das inclinações do terreno, que permite estabelecer uma compartimentação da área, no qual as porções norte e oeste apresentam inclinações geralmente superiores a 35º, e as porções sul e centro possuem as menores

inclinações não ultrapassando 10º. Vale ressaltar que a porção nordeste, no qual ocorreu o escorregamento, possui as maiores inclinações da área de estudo, normalmente superiores a 45º.

Mapa de curvaturas

Os mapas de curvatura estão relacionados à superfície do relevo e possibilitam identificar se as superfícies possuem formas côncavas ou convexas em relação a uma superfície horizontal ou vertical (Figura 10). Para isso foram criados um mapa de curvatura em planta e um mapa de curvatura em perfil. A curvatura é calculada pela segunda derivada do MDE, no qual foi calculado utilizando o *software ArcGIS®*.

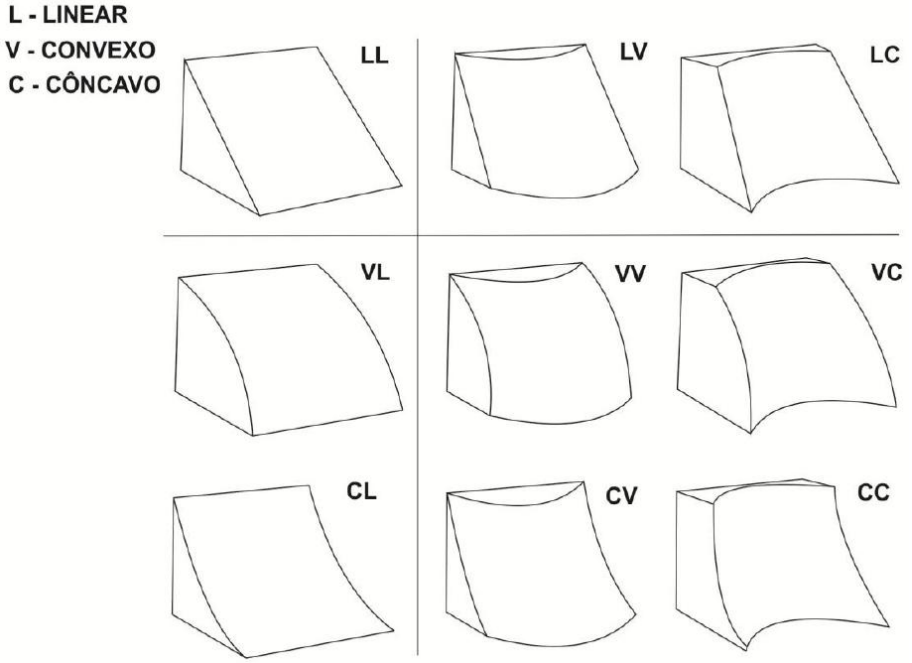

Figura 10: Tipos e formas das geometrias das encostas (Chorley 1975).

Observado em planta as formas convexas se referem a superfícies de espalhamento e por isso dispersam o material em ocasionais instabilizações dos taludes, por sua vez as formas côncavas são superfícies favoráveis a concentração e por isso essas superfícies sempre recebem o material proveniente de erosões e escorregamentos (Chorley 1975). Na comparação entre o mapa de curvatura em planta (Figura 11C) e o mapa hispométrico (Figura 11A), pode se notar que as formas convexas se localizam nas partes mais altas do terreno, enquanto que as formas côncavas se localizam nas áreas mais baixas. As formas convexas, principalmente no local do escorregamento como na porção leste, se posicionam alinhadas, o que pode indicar a movimentação de massa que ocorre até chegar aos locais de deposição. Na porção centro noroeste esse alinhamento das formas convexas existe, porém se encontra mais disperso.

Quando se observa o mapa de curvatura em perfil, as formas côncavas e convexas são vistas em seção. As superfícies convexas são superfícies de espalhamento e, portanto são potenciais dispersivos de massa em eventuais instabilizações de encostas. Nas superfícies côncavas a estabilidade é menor, porém o fluxo desacelera progressivamente e se acumula no sopé do talude (Chorley 1975). Aparentemente as formas côncavas progridem até se tornarem formas convexas e mais estáveis. No mapa de curvatura em perfil (Figura 11D) pode se notar que as formas convexas se concentram nas partes mais baixas do terreno e também mais estáveis. A figura 11B mostra o mapa de declividade com detalhe para os altos valores para a área do escorregamento.

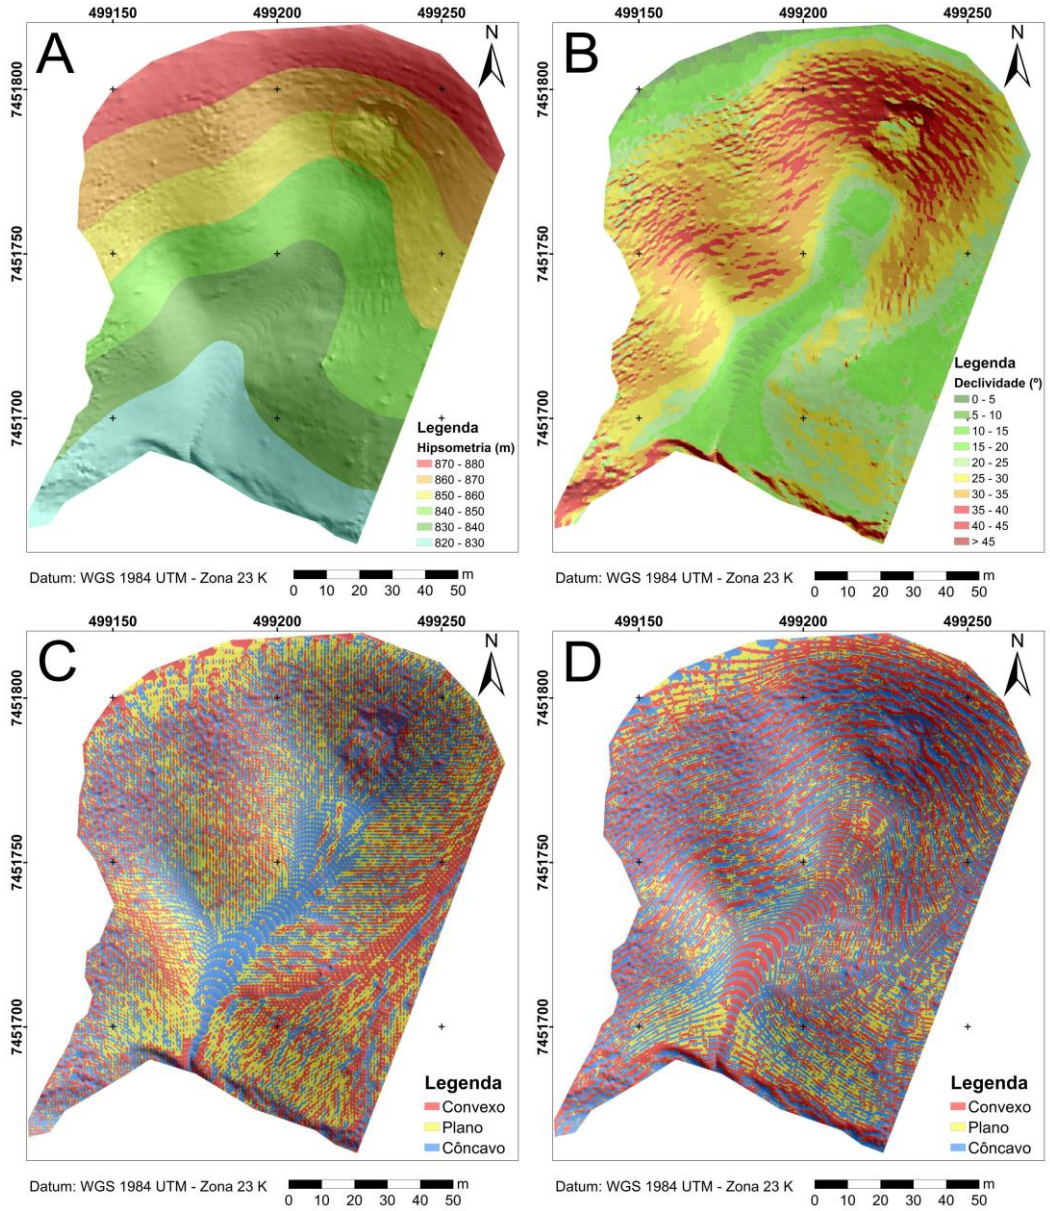

Figura 11: Mapas temáticos. Em A, mapa hipsométrico com cores representando os valores da altitude em metros. Em destaque na porção nordeste o escorregamento.

Em B, mapa de declividade com cores representando a declividade em graus.

Em C, mapa de Curvatura em planta. Áreas em vermelho são referentes a formas convexas, enquanto que as azuis são formas côncavas.

Em D, mapa de curvatura em perfil. Áreas em vermelho são referentes a formas convexas, enquanto que as azuis são formas côncavas.

Mapa de Aspecto

O mapa de aspecto representa as orientações do terreno. A área estudada está orientada principalmente para as porções sul a noroeste; no local onde ocorreu o escorregamento, o talude está voltado para sudoeste/oeste (Figura 12). Essas orientações não representam um atributo para o cálculo do valor da suscetibilidade, uma vez que esses dados foram testados, e o resultado não condiz com o observado em campo.

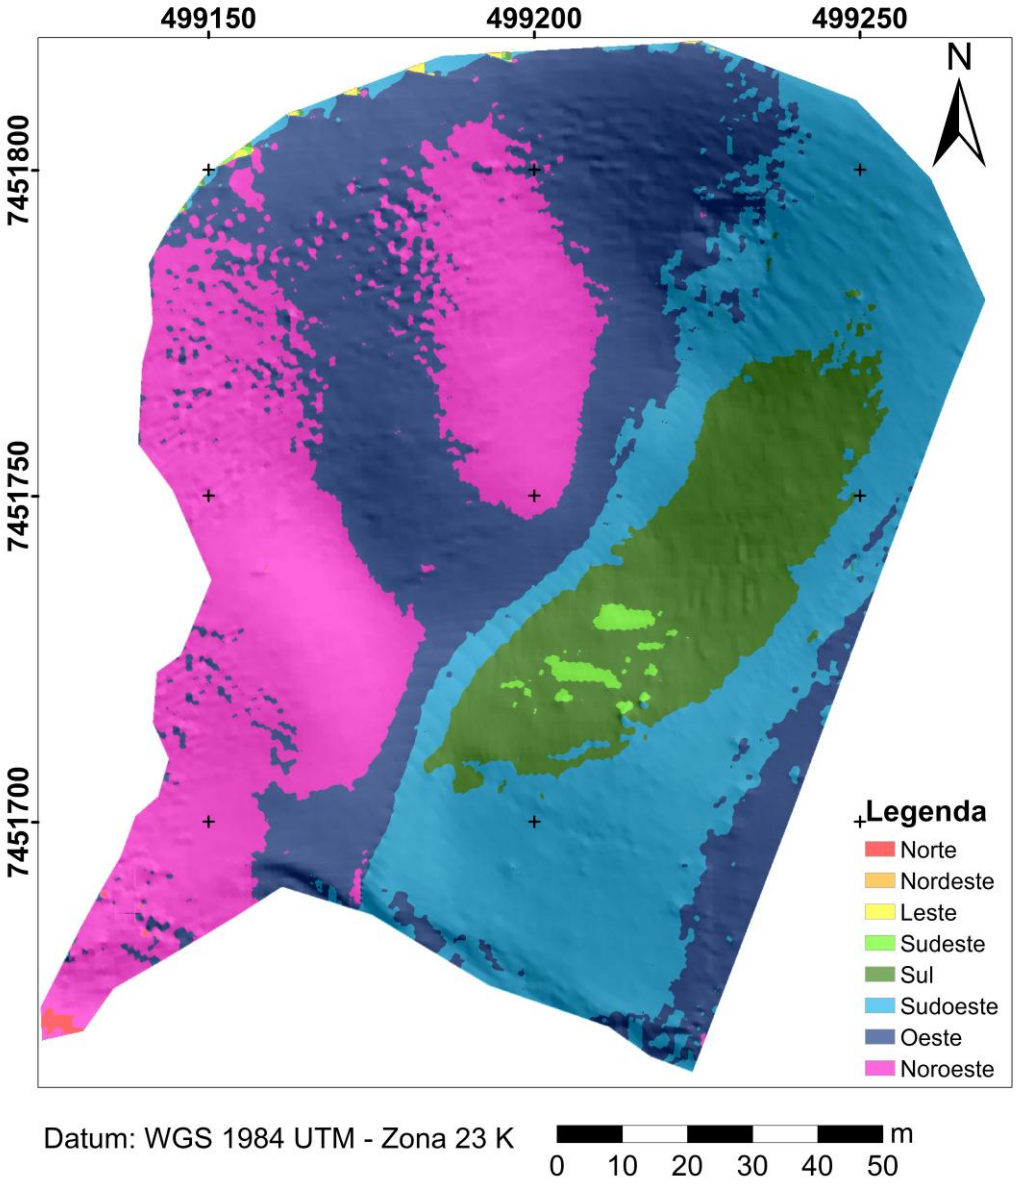

Figura 12: Mapa de aspecto.

Mapa de Rugosidade

O mapa de rugosidade esta relacionado com a heterogeneidade do terreno, também chamado de *Terrain Ruggedness Index* (TRI). O TRI é um índice que permite a medição objetiva da heterogeneidade do terreno, definida como a diferença média da elevação entre o pixel central e os oitos pixels circundantes (Cardoso 2014).

Para este trabalho foi utilizado a ferramenta do TRI, disponibilizado pela *Geospatial Data Abstraction Library* (GDAL) e disponível no software *QGIS* para a utilização, como parâmetros de entrada estão o *raster* de elevação. Essa ferramenta gera uma varredura de banda única com valores calculados a partir da elevação.

O mapa apresentado possui valores variando de 0 a 0.16 (Figura 13). Estes valores foram classificados em 5 classes de intervalos de 0.02 até o valor de 0.08, sendo a última classe no intervalo de 0.08 a 0.16. Essas classes foram classificadas como sendo índices de valores muito baixos a índices de valores muito altos. Quanto menor o valor do TRI, menor é a rugosidade e mais regular é o terreno (Riley *et al.* 1999).

O local apresenta o maior TRI na parte superior do escorregamento e ao seu redor, evidenciando que no local antes do ocorrer o escorregamento, provavelmente já existia um valor maior de TRI se comparado com o restante da área analisada.

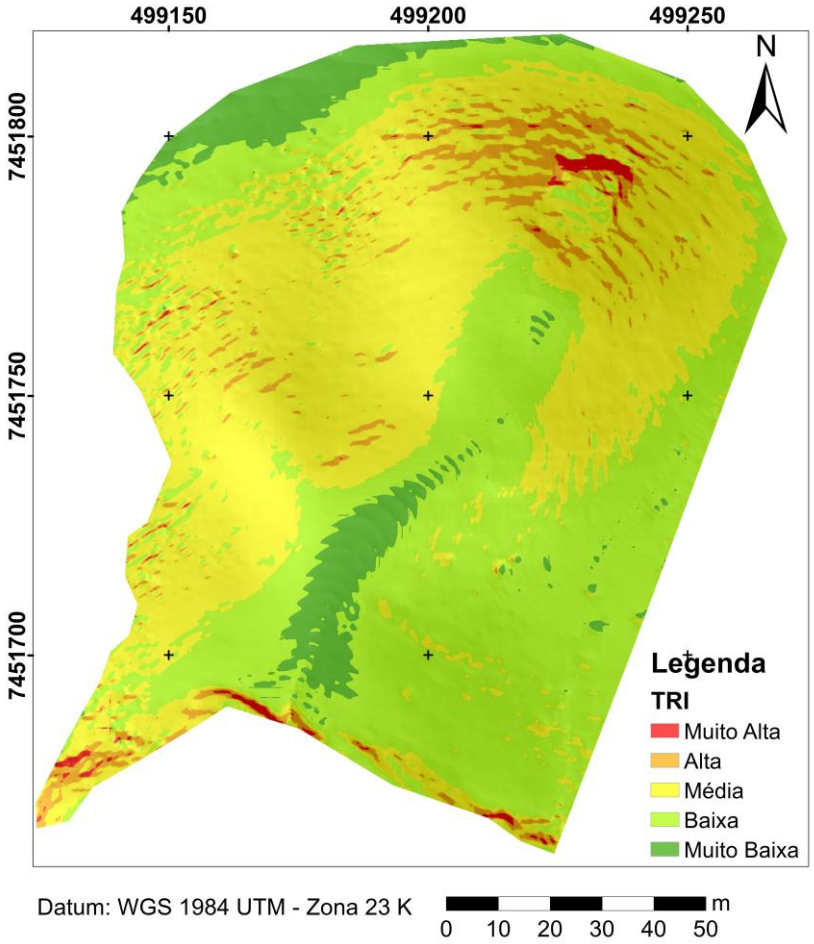

Figura 13: Mapa do índice de heterogeneidade do terreno.

Carta de Suscetibilidade

Partindo da aplicação estatística dos mapas morfológicos (Figura 11 e Figura 13), se observa que a declividade e rugosidade são os parâmetros com valores mais altos, mostrando favorável a ocorrência de escorregamentos, assim a Tabela 2 mostra o valor informativo (Ii) para cada classe dentro de cada parâmetro estudado, assim como o valor da suscetibilidade (ij).

Parâmetro	Classes	Pixels Totais	Si	Valor Informativo	Valor da Suscetibilidade
Elevação (m)	820 - 830	233370	0		0,005
	830,1 - 840	315236	0		
	840,1 - 850	302169	976	-0,800	
	850,1 - 860	241514	23705	0,683	
	860,1 - 870	232355	6272	0,122	
	870,1 - 880	194985	0		
Declividade (º)	0 -5	8837	0		-1,688
	5,1 - 10	29017	0		
	10,1 - 15	79814	5	-2,512	
	15,1 - 20	190222	570	-0,832	
	20,1 - 25	291444	1512	-0,594	
	25,1 - 30	336773	6196	-0,044	
	30,1 - 35	387977	8501	0,032	
	35,1 - 40	149475	6940	0,358	
	40,1 - 45	31783	3391	0,719	
	45,1 - 65	12293	3838	1,185	
Aspecto	norte	1812	0		-3,360
	nordeste	45	0		
	leste	882	0		
	sudeste	7897	0		
	sul	184961	106	-1,551	
	sudoeste	428787	18483	0,326	
	oeste	476708	12315	0,103	
	noroeste	416479	49	-2,238	
	Plano / retilineo	2058	0		
Curvatura Perfil	Côncava	598011	15225	0,097	-0,290
	Plano	322358	2480	-0,423	
	Convexa	599260	13248	0,036	
Curvatura Plana	Côncava	529961	14654	0,133	-0,127
	Plano	506308	4893	-0,324	
	Convexa	483360	11406	0,064	
TRI	0 - 0.02	106686	0		1,501
	0.02 - 0.04	655000	4240	-0,500	
	0.04 - 0.06	672804	16608	0,082	
	0.06 - 0.08	68944	6809	0,684	
	0.08 - 0.16	9373	3296	1,235	

Tabela 2: Parâmetros morfológicos e número de pixels de suas respectivas classes.

Os valores informativos de cada classe morfológica variam entre negativos e positivos. A classe com maior valor está no parâmetro TRI, com valores dentro do intervalo 0.08 a 0.16. Outro parâmetro com valor informativo alto é a declividade que está dentro do intervalo de 45,1º a 65º. Ambas as classes pertencem ao escorregamento, mostrando a importância do valor das mesmas para o cálculo da suscetibilidade.

Os valores da suscetibilidade para cada parâmetro foram multiplicadas pelo seu respectivo raster, ao final os produto foram somados para gerar a carta de suscetibilidade. Como o método só permite criar valores de suscetibilidade para locais onde ocorreram escorregamentos, não foi possível realizar o mesmo método para o relevo original da encosta, anterior ao escorregamento. Assim afim de comparar, foi gerada a carta de suscetibilidade do modelo anterior ao escorregamento utilizando os valores da suscetibilidade da tabela 2 e os mapas do modelo anterior ao escorregamento.

O parâmetro aspecto não foi utilizado para gerar a carta de suscetibilidade, pois ele apresentava divergências, como caracterizando um local plano e com baixa rugosidade em valores com alta suscetibilidade.

As cartas de suscetibilidade para ambos os modelos são apresentados lado a lado para comparação (Figura 14).

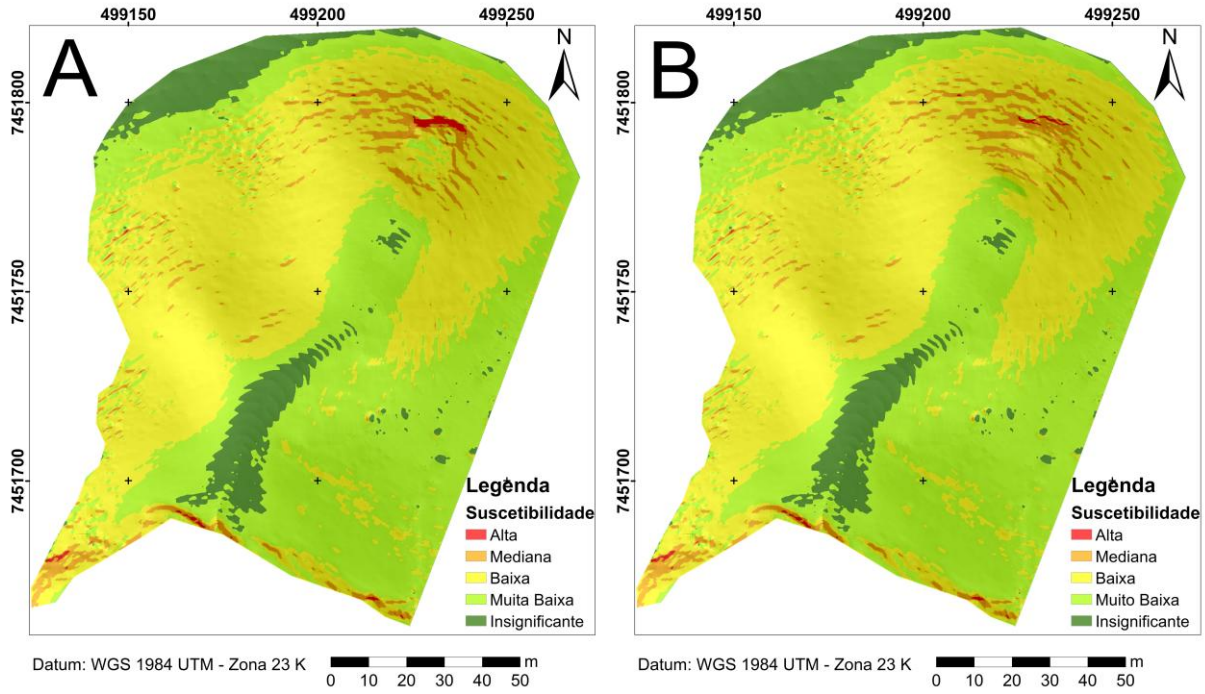

Figura 14: Carta de suscetibilidade. Em A carta de suscetibilidade do modelo estudado. Em B carta de suscetibilidade do modelo anterior ao escorregamento.

6. INTERPRETAÇÃO E DISCUSSÃO DOS RESULTADOS

A aquisição de dados do LiDAR não é homogênea, visto que há uma concentração de pontos nas proximidades do sensor devido a própria técnica de escaneamento, porém isso não se demonstrou um problema para gerar o modelo digital de elevação com resolução de 10 centímetros. Em áreas de 100 cm² ainda existiam pelo menos um ponto que permitiu a geração do MDE. Os mapas temáticos mostraram que o escorregamento apresenta altos índices de rugosidade assim como elevada declividade, o que coincide com o relevo de morros de mapas geomorfológicos do IPT. O Valor informativo calculado a partir dos mapas temáticos e aritmética entre *raster,* se obteve a carta de suscetibilidade que evidenciou que o local do escorregamento pelo modelo reconstituído a partir das curvas de nível também possuía uma alta suscetibilidade. A porção com valores altos de declividade na porção oeste apresentou baixa suscetibilidade, dessa forma a não ser que existam chuvas fortes, a probabilidade de ocorrer escorregamentos nesse local é baixa.

O mapa de aspecto apresentado não foi utilizado para gerar a carta de suscetibilidade, uma vez que a associação desse parâmetro com os demais gerava uma carta com valores diferentes aos que se observava em campo, pois a alta precisão do MDE impossibilitou o uso do mapa de aspecto, a utilização desse tipo de mapa é interessante para escalas regionais.

O valor de alta suscetibilidade apresentado para o local do escorregamento, também possuía alto índice de rugosidade e declividade, a tabela 2 mostra os valores informativos, nos quais os maiores valores da suscetibilidade são do índice de rugosidade e declividade respectivamente, desconsiderando o parâmetro do aspecto.

Com base nas análises do escorregamento, pode ser verificado que na base não houve movimentação e ainda que a escarpa do talude é plana, pode-se deduzir que o escorregamento seja do tipo translacional.

7. CONCLUSÕES

O método utilizado apresenta dificuldades quanto ao processamento dos dados para áreas muito grandes, quanto maior o local analisado, maior será a quantidade de visadas necessárias para caracterizar o objeto em estudo, pois se o objeto estiver muito longe a resolução espacial irá diminuir. A dificuldade de posicionar o LiDAR nas proximidades do escorregamento, devido as altas declividades ao redor, impossibilitou a obtenção de maiores densidades de pontos e gerou uma baixa resolução no local de interesse.

Em locais com presença de vegetação, a resolução é menos detalhada e são perdidos muitos pontos após a filtragem. Para compensar isso deve ser realizar mais visadas, o que em um local com vegetação mais abundante pode ser inviável.

A proposta de utilizar o LiDAR para obtenção de dados se mostrou eficaz dentro da escala do projeto, gerando dados significativos para os mapas morfométricos e a criação da carta de suscetibilidade.

Os parâmetros morfométricos utilizados, como a curvaturas das enconstas, evidenciam que o local do escorregamento possuem uma maior proporção de formas convexas, alta declividade e alta rugosidade, o que classificaria o local com alta suscetibilidade.

Analisando os mapas apresentados, se nota que o local em que ocorreu o escorregamento se encontra na zona de maior declividade e ainda, pelo mapa de curvatura em planta, se percebe que o local do escorregamento continha a maior densidade de alinhamentos de formas convexas, provavelmente tais fatores morfométricos juntamente com a precipitação e pouca vegetação foram responsáveis pela ocorrência desse escorregamento. Ainda com base nesses dados, a porção noroeste possui uma alta declividade e também uma grande densidade de alinhamentos de formas convexas, ou seja, está quase que nas mesmas condições do local que ocorreu o escorregamento, portanto, propício a movimentação de massa.

8. REFERÊNCIAS BIBLIOGRÁFICAS

Almeida, F. F. M. 1964. Fundamentos geológicos do relevo paulista. Bol. IGC, 41: 167-263.

Almeida, F.F.M. & Carneiro, C.D.R. 1998. Origem e evolução da Serra do Mar. Revista Brasileira de Geociências, 28, 135–150.

Anido, N.M.R. 2002. Caracterização Hidrológica de uma microbacia experimental visando identificar indicadores de monitoramento ambiental. Dissertação de mestrado apresentada a escola Superior de Agricultura Luiz de Queirós da Universidade de São Paulo.

Bitar, O. Y. (Coord) *et al*. 2014. Cartas de suscetibilidade a movimentos gravitacionais de massa e inundações - 1:25.000. Nota técnica explicativa. CPRM, IPT. Disponível em: < http://rigeo.cprm.gov.br/xmlui/bitstream/handle/doc/16588/NT-Carta_Suscetibilidade.pdf?sequence=1>. Acesso em: 27 set. 2018.

Buckley, S. J.; Howell, J. A.; Enge, H. D; Kurz, T. H. 2008. Terrestrial laser scanning in geology: data acquisition, processing and accuracy considerations. Journal of the Geological Society, 165, 625–638.

Burrough, P. A.; Mcdonell, R. A. 1998. Principles of Geographical Information Systems. Oxford University Press, New York, 190 pp.

Cardoso, J. M. M. A. 2014 Análise morfométrica das redes de polígonos em Permafrost - Adventdalen, Svalbard. Dissertação de mestrado apresentado ao Instituto de Geografia e Ordenamento do Território, da Universidade de Lisboa.

Chorley, R. J. (1975). Modelos em Geomorfologia. In CHORLEY, R. J., HAGGET, P. Modelos físicos e de informação em Geografia. Rio de Janeiro: Livros Técnicos e Científicos; São Paulo: EDUSP, 60p.

Da Silva, A. M.; Ranzini, M.; Guandique, M. E. G.; Arcova, F.C.S.; De Cicco, V. 2005. Estudo integrado do processo erosivo numa microbacia experimental localizada no Município de Cunha - SP. Geociências, 24, 43–53.

Dias, H.; Bateira, C.; Pissato, E.; Martins, T.; Vieira, B. (2018). Avaliação da Suscetibilidade a Escorregamentos Rasos com Base na Aplicação de Estatística Bivariada: Resultados Preliminares. Revista Do Departamento De Geografia, (spe), 34-42. https://doi.org/10.11606/rdg.v0ispe.144537

EMBRAPA – EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. 1999. Mapa pedológico do estado de São Paulo, escala 1:500.000.

ESRI. 2018. How Slope works. ArcGIS Resource Center, Desktop 10. Disponível em: <http://help.arcgis.com/EN/arcgisdesktop/10.0/help/index.html#/How_Slope_works/009z

000000vz000000/>. Acesso em 05 ago. 2018.

FELL, R. et al. 2008. Guidelines for landslide susceptibility, hazard and risk zoning for land-use planning. Engineering Geology, v. 102, p. 83-111.

Fernandes, A. J. 1991. O Complexo Embu no leste do estado de São Paulo: Contribuição ao conhecimento da litoestratigrafia e da evolução estrutural e metamórfica. Dissertação de mestrado apresentado ao Instituto de Geociências, da Universidade de São Paulo.

Fernandes, N. F; Guimarães, R. F.; Gomes, R. A. T.; Vieira, B. C.; Montgomery, D. R.; Greenberg, H. 2001. Condicionantes geomorfológicos dos deslizamentos nas encostas: teoria, evidências de campo e aplicação de modelo de previsão de áreas susceptíveis. Revista brasileira de geomorfologia, V. 2, n.1, p. 51-71.

Glenn, N.F.; Streutker, D.R.; Chadwick, D.J.; Thackray, G.D.; Dorsch, S.J. 2006. Analysis of LiDAR-derived topographic information for characterizing and differentiating landslide morphology and activity. Geomorphology, 73, 131–148.

Gramani, M.; Augusto Filho, O. 2004. Analysis of the triggering of debris flow potentiality and the run-out reach estimative: an application essay in the Serra do Mar Mountain Range. In: INTERNATIONAL SYMPOSIUM ON LANDSLIDES. Rio de Janeiro. Proceedings London: Balkema, 2004. v. 2, p. 1477-1483.

Guerra, A. J. T; Gonçalves, L. F. H., Lopes, P. B. M. 2007. Evolução Histórico-Geográfica da Ocupação Desordenada e Movimentos de Massa no Município de Petrópolis, nas Últimas Décadas. Revista Brasileira de Geomorfologia. Ano 8, 35–43.

Guidicini, G.; Nieble, C. M. 1984. Estabilidade de taludes naturais e de escavação. São Paulo: Edgard Blücher.

Guimarães, R. F.; Carvalho Júnior, O. A.; Gomes, R. A. T.; Fernandes, N. F. 2008. Movimentos de massa, cap. 6 in Geomorfologia: Conceitos e tecnologias atuais. Oficina de Textos. Org. Teresa G. Florenzano. 318p.

Heilbron M.; Pedrosa-Soares A. C.; Campos Neto M. C.; Silva L. C.; Janasi V. A. 2004. Província Mantiqueira. In: V. Mantesso-Neto, A. Bartorelli, C. Dal Ré Carneiro, B.B. Brito Neves (eds.) Geologia do Continente Sulamericano: Evolução da Obra de Fernando Flávio Marques de Almeida. Beca. São Paulo, p.: 203-234.

IBGE. 2007. Manual Técnico de Pedologia IBGE. Segunda edição.

IPT – INSITUTO DE PESQUISAS TECNOLÓGICAS. 1981. Mapa geomorfológico do Estado de São Paulo. São Paulo, mapa geomorfológico, escala 1:1.000.000.

IPT – INSITUTO DE PESQUISAS TECNOLÓGICAS. 1991. Ocupação de encostas. São Paulo. Publicação IPT n. 1831.

Jones, L. 2010. Monitoring landslides in hazardous terrain using terrestrial LiDAR: an example from Montserrat. Quarterly Journal of Engineering Geology and Hydrogeology, 39, 371–373.

JULIÃO, R. P. (Coord.) et al. 2009. Guia metodológico para a produção de cartografia municipal de risco e para a criação de Sistemas de Informação Geográfica (SIG) de base municipal. Lisboa: Autoridade Nacional de Protecção Civil; Direcção-Geral do Ordenamento do Território e Desenvolvimento Urbano; Instituto Geográfico Português. Disponível em: <http://www.prociv.pt/bk/Documents/guia_metodologico_SIG.pdf>. Acesso em: 27 set. 2018.

Köppen, W. G.; Geiger, R. M. 1936. Das geographische System der Klimate in Fünf Bänden. Berlim.

Mainar-Ruiz, G. & Perez-Cortes, J. 2006. Approximate Nearest Neighbor Search using a Single Space-filling Curve and Multiple Representations of the Data Points. 18th International Conference on Pattern Recognition (ICPR'06), 502–505, https://doi.org/10.1109/ICPR.2006.275.

Montgomery, D. R. & Dietrich, W. E. 1994. A physically based model for the topographic control on shallow landsliding. Water Resources Research, v. 30, p. 1153-1171.

Perrota, M. M.; Salvador, E. D.; Lopes, R. C.; D'Agostino, L. Z.; Peruffo, N.; Gomes, S. D.; Sachs, L. L. B.; Meira, V. T., Garcia, M. G. M.; Lacerda Filho, J. V. 2005. Mapa Geológico do Estado de Sao Paulo, escala 1:750.000. Programa Geologia do Brasil - PGB, CPRM, São Paulo.

Ranzini, M. 2002. Modelagem hidrológica de uma microbacia florestada da serra do mar, SP, com o modelo topmodel — simulação do comportamento hidrológico em função do corte raso. Tese de doutorado apresentada à Escola de Engenharia de São Carlos, da Universidade de São Paulo.

Riley, s.; Degloria, s.; Elliot, r. 1999. A terrain ruggedness index that quantifies topographic heterogeneity. intermountain Journal of sciences.

Rowlands, K. A.; Jones, L. D.; Whitworth, M. 2003. Landslide Laser Scanning: a new look at an old problem. Quarterly Journal of Engineering Geology and Hydrogeology, 36, 155–157.

Secretaria de Agricultura e Abastecimento, CATI/IEA, Projeto LUPA, 2008. Disponível em http://www.cati.sp.gov.br/projetolupa/dadosmunicipais/pdf/t151.pdf.

Silva, B. Y. B. 2017. Evolução tectônica da porção central do Terreno Embu ao norte da zona de cisalhamento Taxaquara-Guararema. Dissertação de mestrado apresentado ao Instituto de Geociências, da Universidade de São Paulo.

Summerfield M. A. 1991. Global Geomorphology. Pearson Education Limited, Harlow, 537 p.

Tarolli, P. 2014. High-resolution topography for understanding Earth surface processes: Opportunities and challenges. Geomorphology, 216, 295–312.

Torres, E. & Saraiva, O.F. 1999. Camadas de impedimento mecânico do solo em sistema agrícolas com soja. Londrina, Embrapa-CNP Soja. 58p. (Circular Técnica, 23).

USGS – UNITED STATES GEOLOGICAL SURVEY 2004. Landslides Types and Processes. Disponível em: http://pubs.usgs.gov/fs/2004/3072/. Acessado em Julho de 2018.

Viana, C.D.; Roldan, L.F.; Grohmann, C.H. 2012. Descrição e Avaliação dos Condicionantes Geológicos, Geomorfológicos e Estruturais das Instabilidades Geotécnicas Observadas em Trecho da SP-171, Município de Cunha - SP.

YIN, K. L. & YAN, T. Z. 1988. Statistical prediction models for slope instability of metamorphosed rocks. In: Landslides. Proceedings of the Fifth International Symposium on Landslides, 2, Balkema, Rotterdam: Bonnard C (ed.), p.1269-1272.

Zhang W; Qi J.; Wan P.; Wang H.; Xie D.; Wang X.; Yan G. An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. Remote Sensing. 2016; 8(6):501.

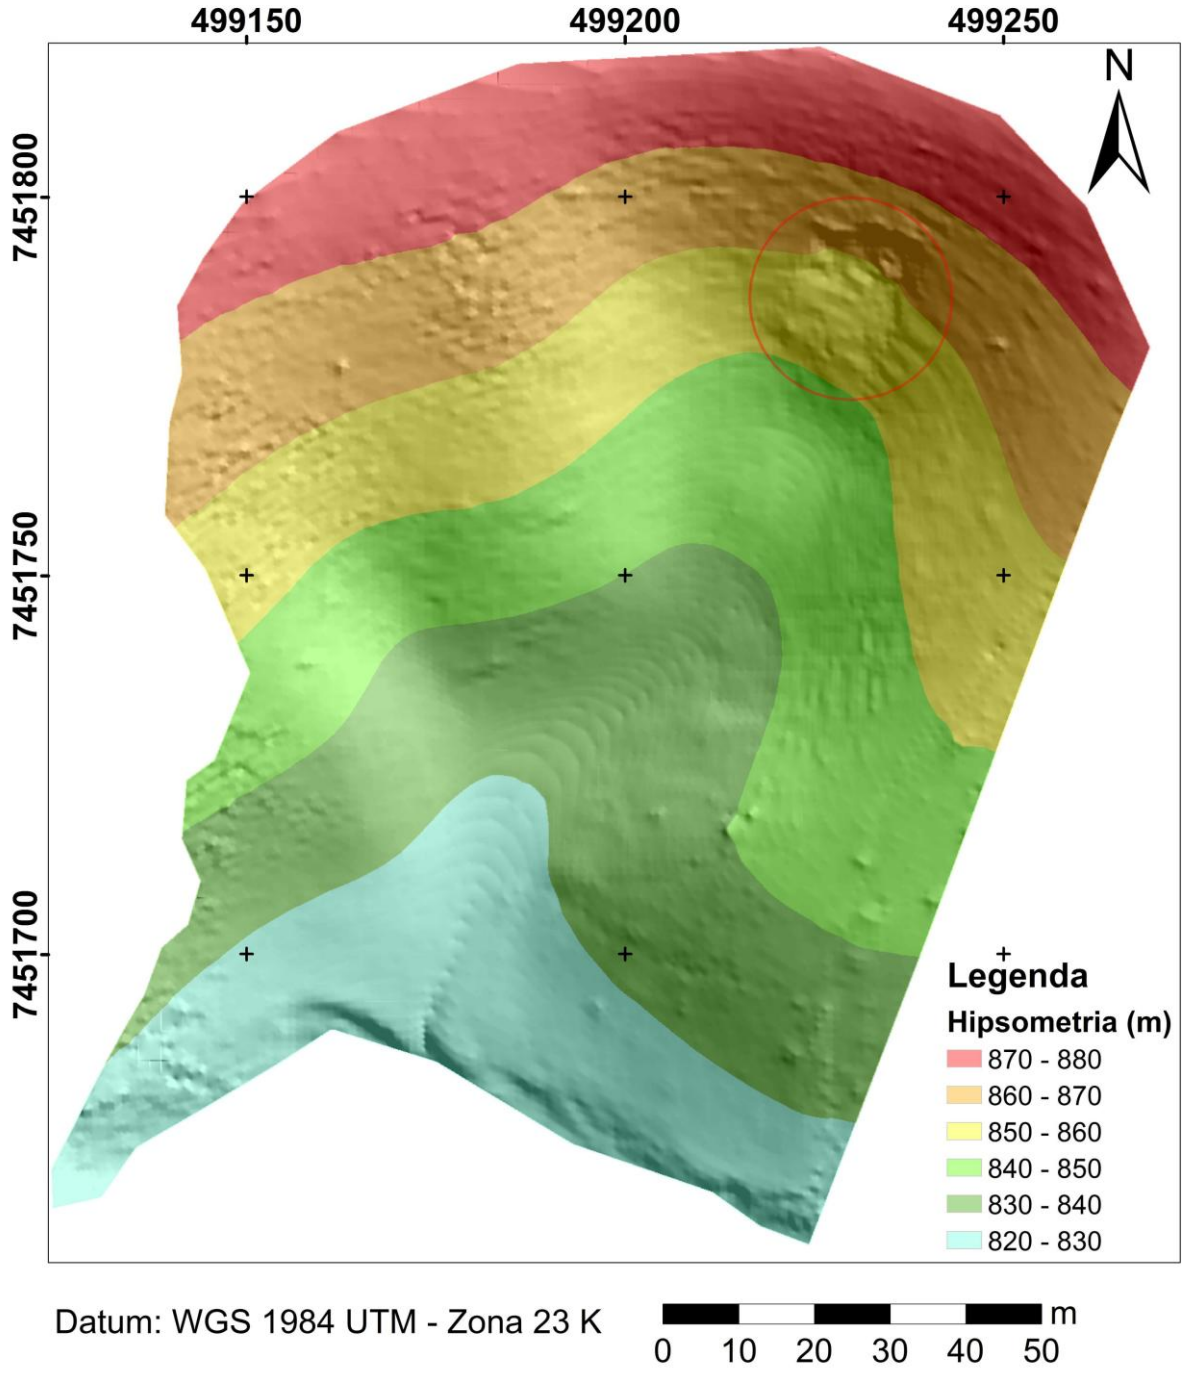

Figura 15: Mapa hipsométrico com cores representando os valores da altitude em metros. Em destaque na porção nordeste o escorregamento.

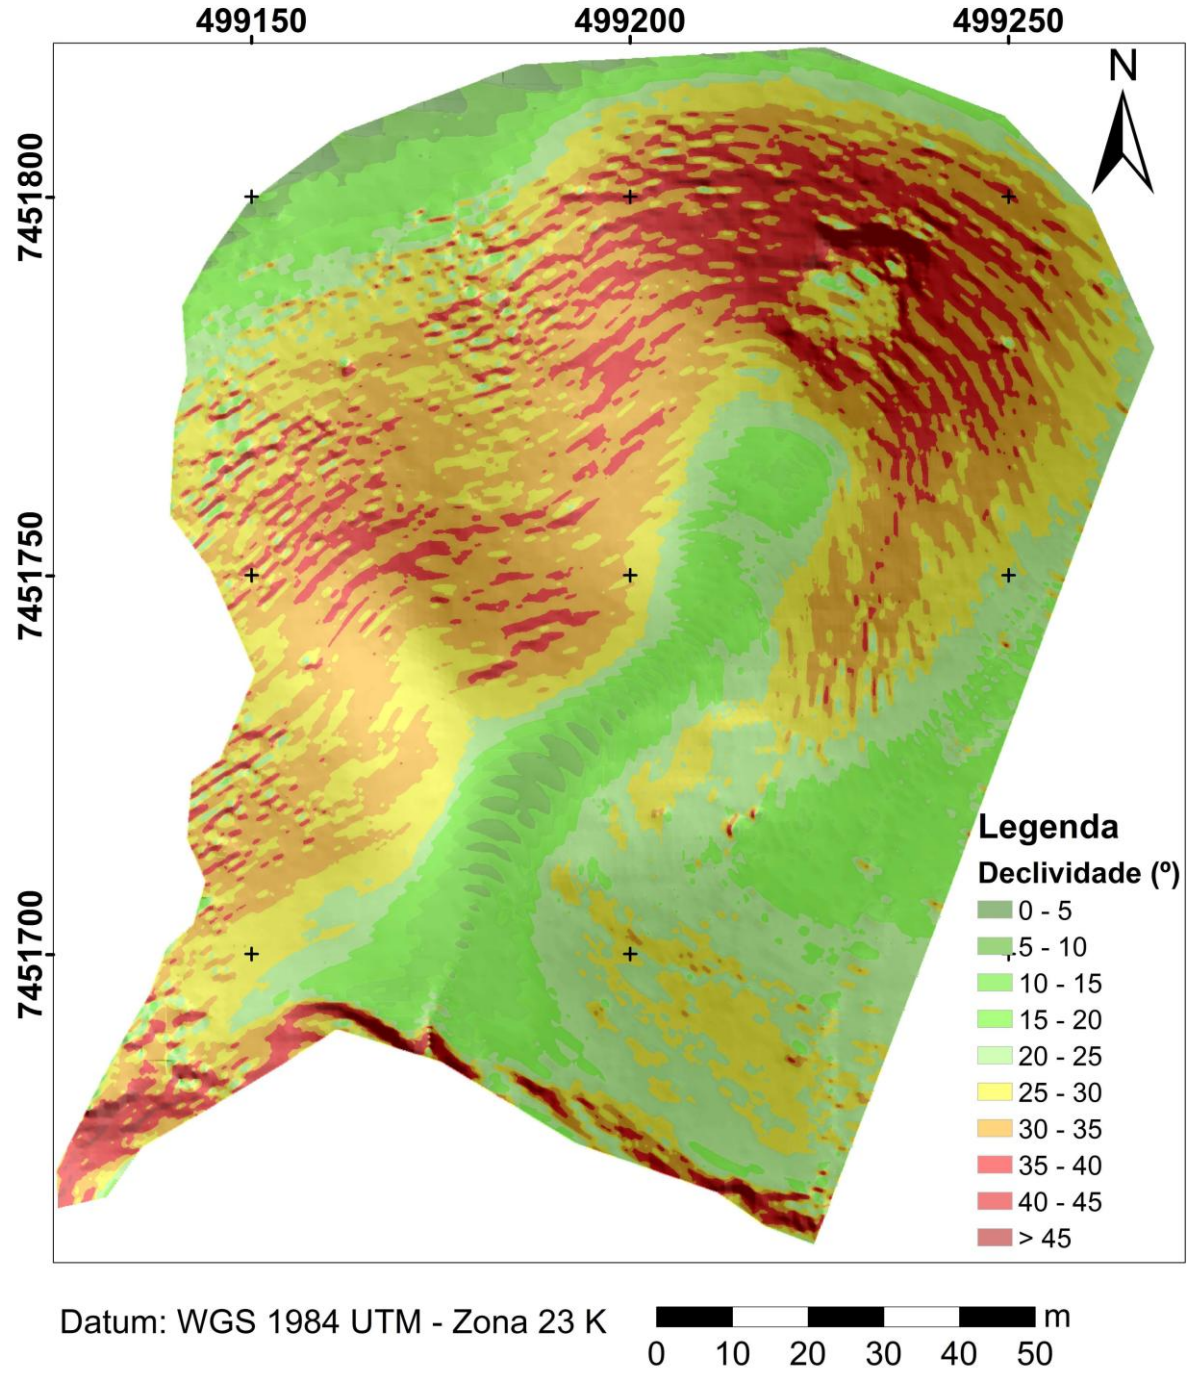

Figura 16: Mapa de declividade com cores representando a declividade em graus.

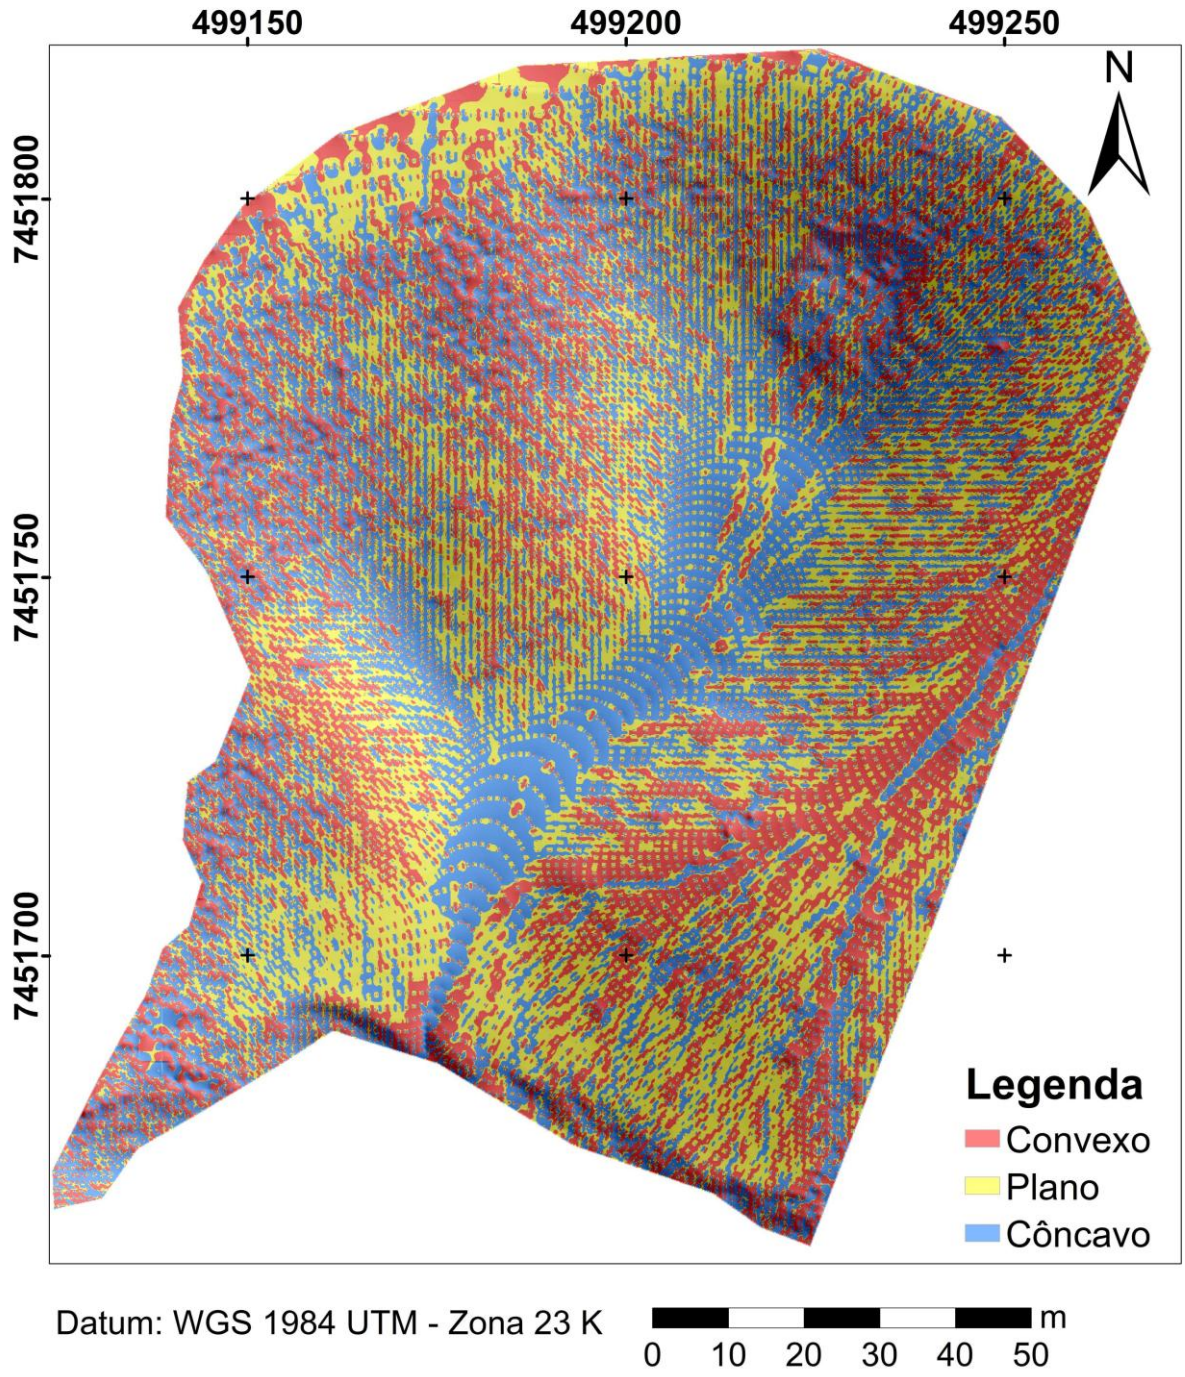

Figura 17: Mapa de Curvatura em planta. Áreas em vermelho são referentes a formas convexas, enquanto que as azuis são formas côncavas.

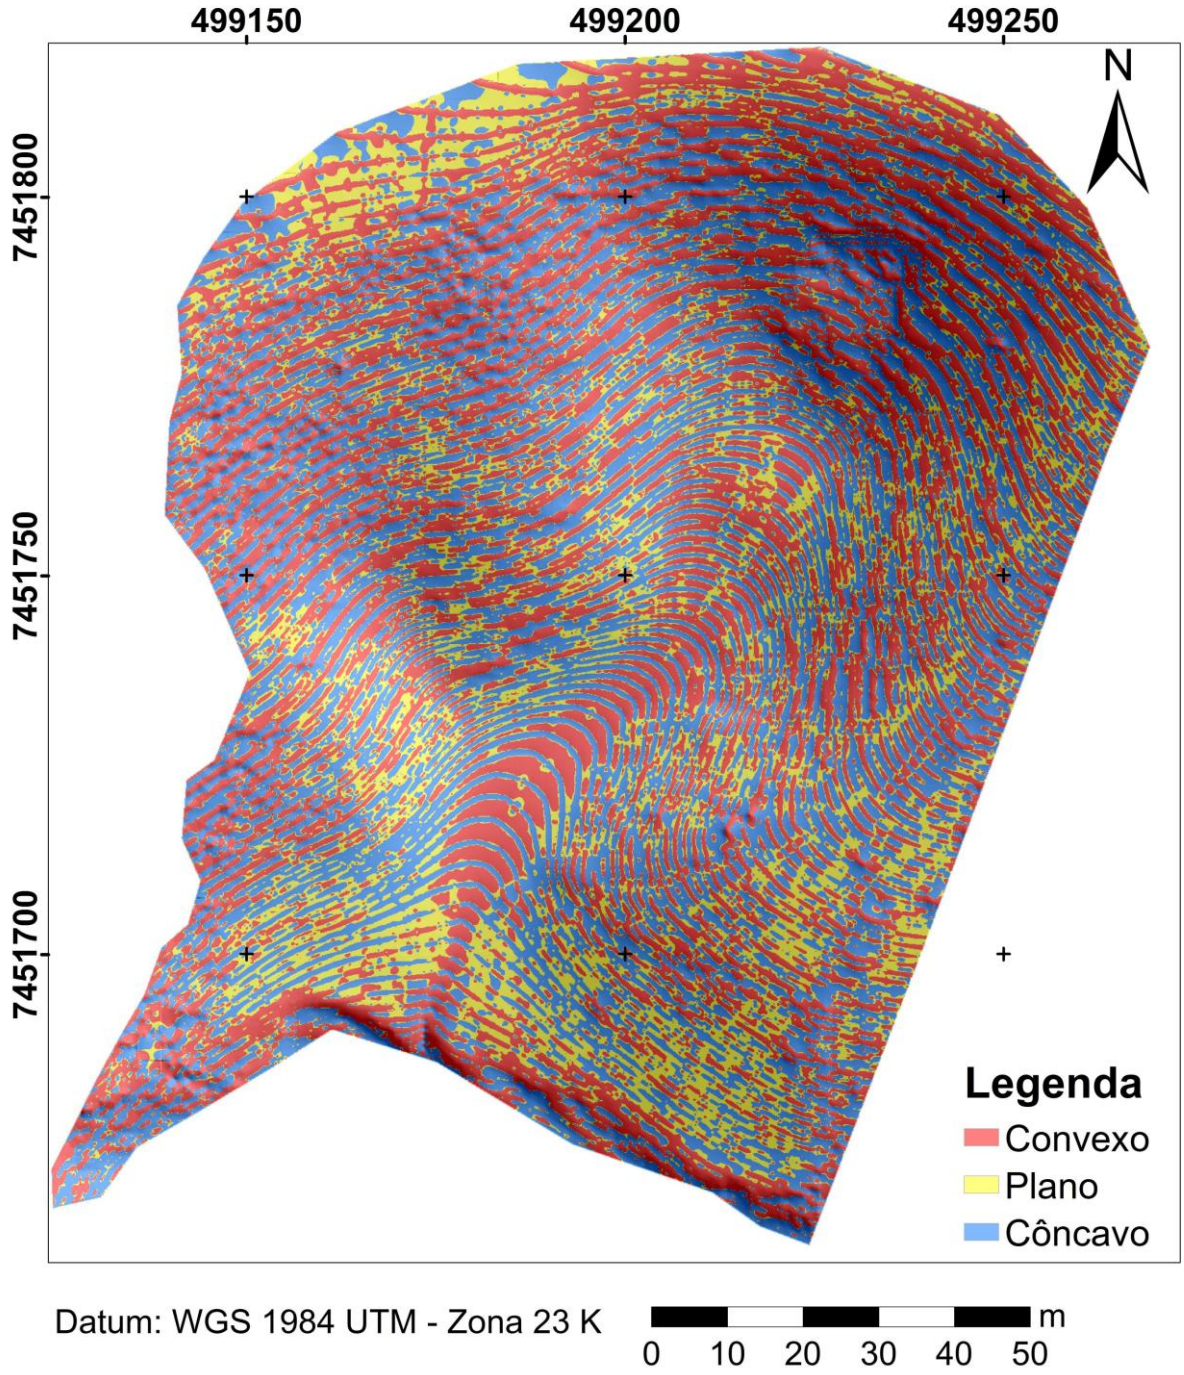

Figura 18: Mapa de curvatura em perfil. Áreas em vermelho são referentes a formas convexas, enquanto que as azuis são formas côncavas.

Anexo B. Coautoria em artigo científico publicado no *Brazilian Journal of Geology*

Anexo B.1. *Structural analysis of clastic dikes using Structure from Motion - Multi-View Stereo: a case-study in the Paraná Basin, southeastern Brazil*

DOI: 10.1590/2317-4889201800201898

ARTICLE

Structural analysis of clastic dikes using Structure from Motion - Multi-View Stereo: a case-study in the Paraná Basin, southeastern Brazil

Camila Duelis Viana[1]*, Carlos Henrique Grohmann[2], Mariana dos Santos Toledo Busarello[1], Guilherme Pereira Bento Garcia[1]

ABSTRACT: *This work presents the development of a three-dimensional (3D) model of an outcrop of the Corumbataí Formation (Permian, Paraná Basin, Brazil) using Structure from Motion - Multi-View Stereo (SfM-MVS) technique in order to provide a structural analysis of clastic dikes cutting through siltstone layers. While traditional photogrammetry requires the user to input a series of parameters related to the camera orientation and its characteristics (such as focal distance), in SfM-MVS the scene geometry, camera position and orientations are automatically determined by a bundle adjustment, an iterative procedure based on a set of overlapping images. It is considered a low-cost technique in terms of hardware and software, also being able to provide point density and accuracy on par to the ones obtained with Terrestrial Laser Scanning. The results acquired on this research have good agreement with previous works, yielding a NNW main orientation for the dikes measured in the field and on the 3D model. The development of this work showed that SfM-MVS use and practice on geosciences still needs more studies on the optimization of the involved parameters (such as camera orientation, image overlap and angle of illumination), which, when accomplished, will result in less processing time and more accurate models.*

KEYWORDS: *clastic dikes; structure from motion; digital outcrop model; photogrammetry; structural geology.*

INTRODUCTION

In geology, the understanding of structures can be too complex to be reached using only field methods. Remote sensing topographic survey techniques such as LiDAR (Light Detection And Ranging, also called laser scanning), and photogrammetry are able to provide greater amount of information, as their resulting digital models allow (Bistacchi *et al.* 2015, Hodgetts 2013):

- Detailed quantitative description of geological features regarding geometry and spatial relationships;
- Collection of large amounts of data, evenly distributed along an area or outcrop, providing a statistical basis for modeling;
- Unified analysis of large-scale outcrops, even at reservoir scale;
- True and reliable documentation that can be used for multiple purpose;
- Three-dimensional (3D) outcrop navigation/exploration, providing "access" to out-of-reach or hazardous areas.

Among such techniques, SfM-MVS (Structure from Motion - Multi-View Stereo) workflow has gained strength in the geosciences over the past years (Tab. 1), mostly because when compared to other digital surveying it is capable of producing high-resolution data at low cost, fast and virtually independent of spatial scale. The final result of SfM-MVS is a detailed 3D model — also referred by some authors as Digital Outcrop Model (DOM) (Pringle *et al.* 1999, Zahm *et al.* 2016, Silva *et al.* 2014), or virtual outcrop (Pringle *et al.* 2001, Tavani *et al.* 2014) —, that can be used as a point cloud or as a triangular mesh.

[1]Institute of Geosciences, Universidade de São Paulo – São Paulo (SP), Brazil. *E-mails: camila.duelis@gmail.com, mariana.busarello@gmail.com, guilherme.pereira.garcia@usp.br*

[2]Institute of Energy and Environment, Universidade de São Paulo – São Paulo (SP), Brazil. *E-mail: guano@usp.br*

*Corresponding author.

Manuscript ID: 20180098. **Received on:** 09/05/2018. **Approved on:** 10/23/2018.

As shown in Table 1, most applications of SfM-MVS are dedicated to extraction of geometrical properties of discontinuities, mostly faults and fractures, which are simple structures. An example of a complex structure that can take advantage of the use of SfM-MVS are clastic dikes, which are discordant subvertical sheets, tabular bodies of clastic sediments that can form by hydraulic fracturing and infilling (Hargitai & Levi 2014). Even for traditional field survey, the analysis of such structures can be challenging and, to date, no work has presented it through the use of 3D models.

Thus, the objectives of this paper are twofold:

1) use SfM-MVS to generate a DOM of an outcrop of the Corumbataí Formation (Permian, Paraná Basin), which contains a remarkable exposition of clastic dikes;
2) extract geological attitudes of clastic dikes from the DOM and compare them with field-collected data in order to discuss the pros and cons of using digitally-derived data in structural analysis.

Considering that the use of SfM-MVS in the geosciences is expanding rapidly, and that a successful DOM generation might involve more factors than initially considered by the non-experienced user, we also present a brief summary of the processes and algorithms involved in the SfM-MVS workflow, as well a list of best practices for fieldwork, derived from the experience gained by the authors in the development of this project.

STUDY AREA AND GEOLOGICAL SETTING

This study focused on a NE-SW (facing NW) roadside rocky outcrop near Limeira city, state of São Paulo, Brazil, km 161.5 of SP-348 Bandeirantes highway (Fig. 1). The outcrop is a ~500 m-long and ~30 m-high exposition of the Corumbataí Formation (Permian, Paraná Basin), composed of siltstone intercalated with fine sandstone and carbonate

Table 1. Examples of Structure from Motion - Multi-View Stereo (SfM-MVS) applications in the geosciences.

Subject	Application	References
Structural geology and geotechnics	Structural mapping	Gates & Haneberg (2012)
	Extraction of the orientations of the discontinuities	Deb *et al.* (2008), Sturzenegger & Stead (2009), Assali *et al.* (2014), Vasuki *et al.* (2014), Buyer & Schubert (2016), Viana *et al.* (2016), Riquelme *et al.* (2017)
	Surveys of trenches, rock exposures and hand specimens for paleo-seismology and structural geology	Bemis *et al.* (2014)
	Fault analysis	Tavani *et al.* (2016)
	Geo-mechanical classification	Riquelme *et al.* (2016)
	Kinematic analysis of rock slopes	Jorda-Bordehore *et al.* (2017)
	Accuracy of SfM and LiDAR for structural measurements	Cawood *et al.* (2017)
	Orientation measurements of complex folds	Zachariah & Terry (2018)
Topography and bathymetry	Extracting shallow stream bathymetry	Dietrich (2017)
	Topography with UAVs	James & Robson (2014), James *et al.* (2017)
	Generation of high-resolution DEM	James & Robson (2012), Carbonneau & Dietrich (2017), Mali & Kuiry (2018)
General geology	Building a virtual outcrop (3D geology)	Tavani *et al.* (2014), Zahm *et al.* (2016)
	UAVs for mapping dolomite geobodies	Madjid *et al.* (2018)
Reservoir analysis	Geomechanical and fluid flow models	Bisdom *et al.* (2017)
	Characterization of reservoir analogs	Biber *et al.* (2018)

LiDAR: light detection and ranging; UAVs: Unmanned Aerial Vehicles; DEM: Digital Elevation Models; 3D: three-dimensional.

layers, intruded by a swarm of clastic dikes (Riccomini *et al.* 1992, Perinotto *et al.* 2008, Turra 2009).

Syn-depositional and postdepositional dikes are distinguished depending on time of fracture infilling (Allen 1982), and two subtypes can be categorized based on the formative process: injection clastic dikes and sedimentary (or depositional) dikes. The first type are liquefaction structures that form as water-saturated granular material experiences an increase in pore fluid pressure, typically occurring in cohesionless or nearly-cohesionless sediments and may be caused by cycles of sheer stresses during strong earthquake events (M > 6.5 — Hargitai & Levi 2014).

In the studied outcrop, clastic dikes are vertical to near-vertical tabular to ptygmatic-folded bodies of massive fine sandstone cutting through pelitic layers (Fig. 2). The dikes occur in four sedimentary levels, being more numerous on the lower level. The top of this level is marked by a well-defined surface with structures interpreted as sand extrusions. Despite the scattering of data, Turra (2009) described a general NNW orientation trend

Figure 1. Study area location in Brazil (inset). Positioning of the total station (TS), fixed points (FX01 and FX02) and targets distributed on the outcrop surface (blue points).

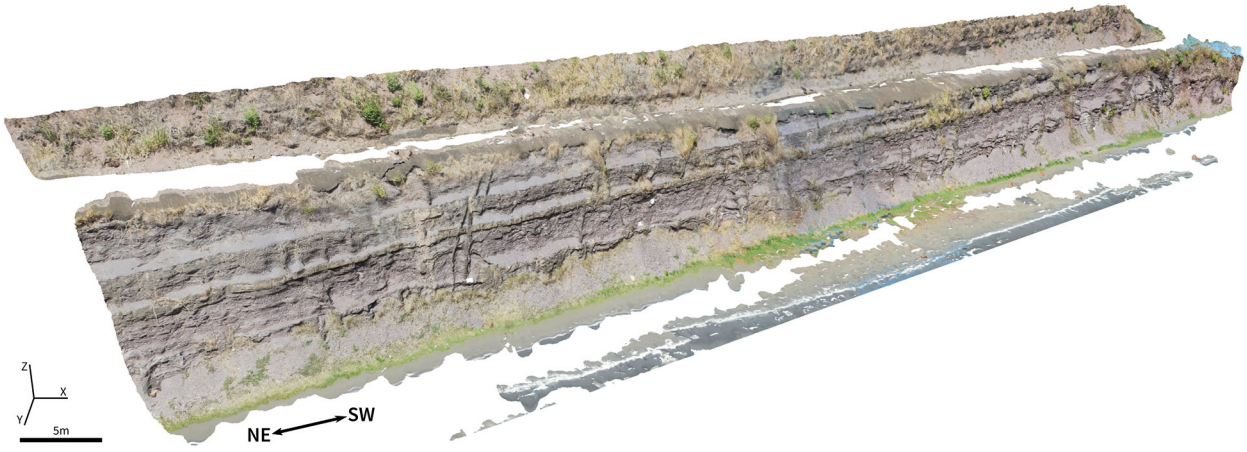

Figure 2. Perspective view of generated Digital Outcrop Model (DOM). See Supplemental Material for camera positions and ground control points (GCPs) (Suppl. Fig. S5).

of clastic dikes and a N-NE trend of sand extrusions' feeder dikes (Fig. 3A).

Riccomini *et al.* (1992) were the first authors to associate the formation of clastic dikes in the Corumbataí Formation to a seismic event. Later, Riccomini (1995) identified two sets of dikes orthogonal to each other with predominance in the NE-SW direction, interpreted as the direction of the maximum horizontal tension vector and associated with the early stages of the Pangea rupture. Chamani *et al.* (1992), Fernandes & Coimbra (1993) and Riccomini *et al.* (1996) also interpreted some features in the Permotriassic units of the Paraná Basin as seismites.

Perinotto *et al.* (2008), analyzing three different sites, concluded that due to the scatter of measurements the dikes occupied pre-existing fractures or those generated by hydrofracturing under local stress, being unrelated to regional tectonic patterns as suggested previously, although to Chamani (2015) the lack of a careful statistical analysis (presenting orientation data only as great circles in a stereonet, for example) by Perinotto *et al.* (2008) hinders an objective assessment of their conclusions. The discussion brought by these works point to the uncertainty in interpreting clastic dikes and their associated structural markers, which justifies the experimentation of structural analysis based on SfM-MVS models as a more objective mean for assessing/ascertaining orientation data. Recent studies (Tohver *et al.* 2013, 2018) related the seismicity that generated the dikes to the impact event that formed the Araguainha structure, at the Permian-Triassic boundary.

STRUCTURE FROM MOTION MULTI-VIEW STEREO

In the geosciences, the development of remote digital surveying methods allowed not only the increase in collection speed and data density, but also enabled the surveying in physically inaccessible places. Among such techniques, there are traditional photogrammetry, laser scanning and SfM-MVS.

Structure from Motion (SfM) is a recent tool that has had an impact on the field of geosciences in recent years. It enables the generation of high-precision 3D models from two-dimensional (2D) images in a simple way, bringing the power of digital models to non-experts. An important advantage of this method, compared with the traditional photogrammetric workflow, is that each feature is defined from a redundant number of photos (Snavely *et al.* 2006), and

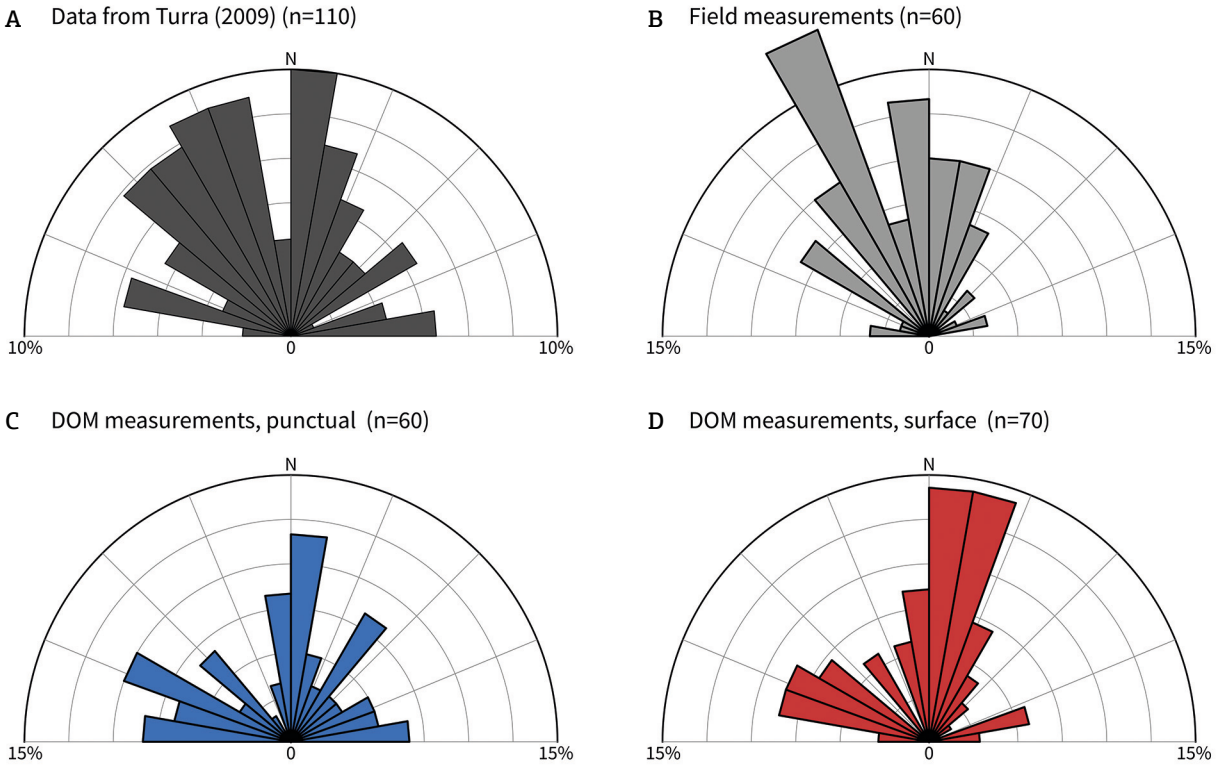

Figure 3. Rose diagrams: (A) measurements from Turra (2009); (B) all field measurements; (C) Digital Outcrop Model (DOM) measurements (punctual); (D) DOM measurements (surface). All diagrams have 10º petals.

error estimates are just another output from model inversion. This ensures the high quality of the results, because points with precision lower than a given threshold are automatically rejected by the inversion algorithm (Bistacchi *et al.* 2015).

As put by Carrivick *et al.* (2016), most authors in geosciences cite in a simplified way the SfM algorithm as the sole responsible for creating the 3D model. When we look at the processing of the set of images, in brief, it goes through three main steps:

- the recognition of points in common between the images of the set and the calculation of the *x*, *y*, *z* position of each point;
- construction of a sparse point cloud (also referred as coarse cloud);
- the refinement of the model and generation of a dense point cloud.

SfM algorithms are responsible only for the first two steps of the process. The third step is performed by the Multi-View Stereo (MVS) methods and, therefore, the most correct would be to refer to the SfM-MVS method.

In this section, we would like to give a brief summary of the processes and algorithms involved in SfM-MVS workflow to generate a Digital Outcrop Model (DOM) (Fig. 4). Most of the information provided here is from the work of Carrivick *et al.* (2016) and the reader is referred to it for further detailing.

Image acquisition and ground control

As the name suggest, SfM-MVS is entirely dependent on images "in motion", *i.e.*, images taken from different viewpoints. Planning the image survey should consider several recommendations to ensure a high-quality 3D model.

There is a wide range of platforms that can be employed for the photo shooting and each of which has advantages and disadvantages that must be evaluated according to the application (Conlin *et al.* 2018). There are ground-based options including hand-held, the use of poles, tripods or rovers and airborne approaches using unmanned aerial vehicles (UAVs), kites, balloons and manned light aircrafts.

The images should provide a full coverage of the object or scene of interest, keeping a minimum 60% lateral and 30% vertical overlap, but these values may vary depending on the scene conditions. Camera positions should be well distributed around the object, avoiding "fan" methods (*i.e.*, multiple images from a single point). Objects that produce low contrast require a higher percentage of overlap in order for the matches to be located and generate satisfactory results. For a feature to be digitally reconstructed, it must be observable in at least three images, so the number of images required for the reconstruction of an object or scene will then be a function of its size and the amount of overlap used.

Lighting conditions directly affect the quality of the DOM. Glare from reflective surfaces, variable contrast across a scene, the presence of shadows and changes in their length and surface albedo negatively affect point matching (Bemis *et al.* 2014). Ideally the survey should occur under the same light conditions. Bright cloudy days — the exterior lighting equivalent of a dome light — are recommended, since the lighting is more uniform and the casting of shadows is reduced. In some cases, the use of artificial lights may be feasible and the arrangement must be composed of main light sources of the same intensity with diffusers to ensure no visible signs of the lighting sources in the object or scene.

The occurrence of gaps, holes or distortions in the DOM usually results from the inadequate application of such parameters. Ideally, the larger the set of images generated, the greater the overlap between images and, consequently, the higher the quality of the model. However, an excessive number of images are computationally expensive, generating very large models, which makes it difficult to manipulate and post-process. Pre-processing image data is an optional step to improve overall quality and can be performed using image filters to correct color, brightness and sharpness or selecting the most adequate images from the set.

When given no reference information, the SfM-MVS generates a point cloud within a relative reference system (Westoby *et al.* 2012), but, for the majority of applications in geosciences, information like distance, size, volume and orientation are essential and in order to get those it is necessary to acquire ground control. When only the scale is desired, it is necessary that the distance between two points is known, which can be obtained by field measuring the distance between two markers or by adding an object of known size in the scene, such as a ruler (Verma & Bourke 2018).

For greater accuracy and full 3D referencing or georeferencing, at least three ground control points (GCPs) are required. The points should be widely distributed on the scene, avoiding linear configuration. There is a wide range of options to mark out GCP locations such as printed targets (Riquelme *et al.* 2017), spray paint (Viana *et al.* 2016), spray-painted CD (Matthews 2008) or targets (Turner *et al.* 2012), nails and colored flags (Haneberg 2008) or modeling clay (Jordá-Bordehore *et al.* 2017). The choice of the type of target must be made according to the conditions of the survey, considering that the size and the distinctiveness of the target in relation to its surroundings influence in the quality of the georeferencing. The GCPs survey is commonly done using Total Station or differential GPS, but for geological purposes great accuracy can be achieved using multiple approaches as shown by Sturzenegger and Stead (2009).

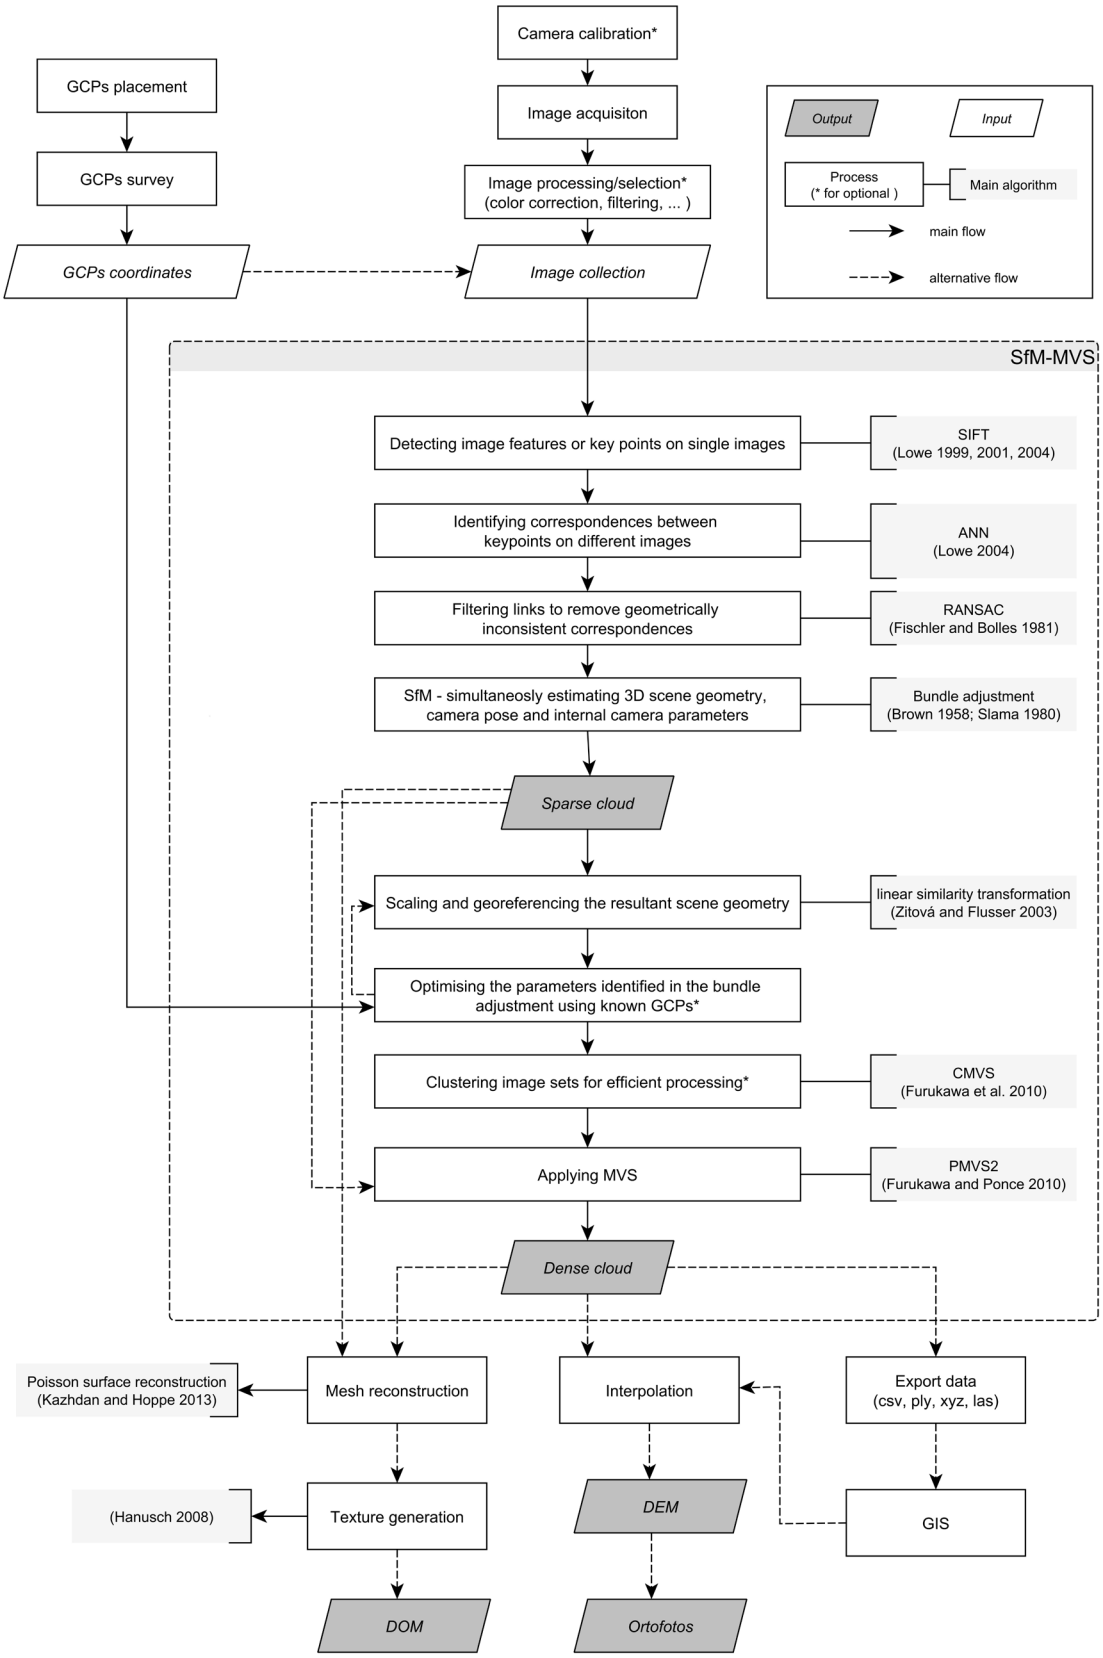

Figure 4. Simplified flowchart showing the main steps involved on a Digital Outcrop Model (DOM) generation using Structure from Motion - Multi-View Stereo workflow.

SfM-MVS workflow

There is a wide variety of SfM-MVS software, ranging from specific algorithms to stand-alone tools and web services. The commercial options include Pix4DMapper (Pix4D SA, 2017), PhotoModeler (Eos Systems Inc., 2014) and Agisoft PhotoScan (Agisoft, 2018). The latter is the most widely used in geosciences applications and the one used in this paper. Although commercial options are more user-friendly for non-experts, the main disadvantage is that their workflow is a black box, turning the identification of random and systematic errors difficult to handle (Ouédraogo *et al*. 2014). To get around this problem some of the open source options include Bundler (Snavely *et al*. 2006), PMVS (Furukawa & Ponce 2010), VisualSFM (Wu 2013, Wu *et al*. 2011), OpenDroneMap (OpenDroneMap 2014), Colmap (Schönberger *et al*. 2016, Schönberger & Frahm 2016) and MicMac (Rupnik *et al*. 2017).

Regardless of the software, as shown in Figure 4, the generic SfM-MVS process has around eight steps that may or may not constitute a single workflow. Ahead, we briefly describe each of the steps and algorithms commonly used in each one of them. It should be emphasized that the explanation provided here is simplified to be suitable for end users, since SfM-MVS is a combination of computer vision and traditional photogrammetry knowledge that goes beyond the scope of this work.

Given an image set, the first step is the detection of keypoints (common points between images) or feature points (sets of pixels) on single images. These points allow the different photos to be matched and the scene geometry to be reconstructed, but since the images are taken from multiple viewpoints it is a challenge to track those points. To solve this step, the scale-invariant feature transform (SIFT) object-recognition system (Lowe 1999, 2001, 2004) is the most popular approach. The performance of different region detectors is given in Mikolajczyk *et al*. (2005), and a comparison between other view-invariant local image descriptors is presented in Mikolajczyk & Schmid (2005).

Once keypoints are located in each image, the second step consists of finding the correspondences between the keypoints on different images. The keypoint matching is performed by identifying the nearest neighbor for each keypoint in a database containing all the keypoints identified during the first step, but there is no guarantee that any given keypoint will have a partner at another image, so the discarding of points with no good matching is required. Since the SIFT keypoint descriptor has a 128-dimensional feature vector, some search implementations can be both difficult and computationally expensive. Lowe (2004) modifies the best-bin-first algorithm (Beis & Lowe 1997) to cut off search after checking the first 200 nearest-neighbor candidates and only consider matches in which the nearest neighbor is less than 0.8 times the Euclidean distance to the second nearest-neighbor. This approach significantly increases the search speed with minimal loss in the number of correct matches and is known as approximate nearest neighbor (ANN).

Once the links between images have been established, the third step is responsible for filtering out geometrically inconsistent matches. The random sample consensus (RANSAC) method (Fischler & Bolles 1981) is the most commonly used to calculate the candidate fundamental matrices (a 3x3 matrix that "encode" the projective geometry between two views) over several iterations to filter out outliers and return the matrix with the largest number of inliers.

Using the geometrically consistent correspondences from the previous step, the fourth stage is the SfM itself, which consists of reconstructing simultaneously camera poses (position and orientation), 3D scene geometry and intrinsic camera calibration parameters. This is solved using a bundle adjustment (BA) (Brown 1958, Slama 1980), that, provided with an estimation of initial parameters values, simultaneously refines structure and motion by minimizing the re-projection error between the observed and predicted image points. The initialization of parameter values and the error minimization can be performed by several algorithms. Bundler (Snavely *et al*. 2006) is an example of a complete and efficient SfM system. This step produces a sparse (or coarse) point cloud and camera poses that, once georeferenced, can be used for applications (Lhuillier & Yu 2013, Fonstad *et al*. 2013), but most applications require a more detailed and denser point cloud, which is obtained through MVS in the following steps.

The fifth step is the point cloud georeferencing. For full 3D orientation, a minimum of three GCPs with X, Y, Z coordinates are required. The provided real world coordinates are paired with the relative coordinates derived from the previous step to derive a similarity transformation, which comprises three rotation parameters, three global translation parameters and one scaling parameter. This step can be performed on the image set at the beginning of the workflow, for the sparse point cloud or for the densified point cloud, depending on the desired result. When done at the beginning, GCPs can be used to better constrain the solution for the bundle adjustment. More information about registration methods can be found in Zitová & Flusser (2003).

After the georeferencing, the next step is optional and uses the provided GCPs to refine the parameter values

obtained during the SfM step. This option is available in Agisoft PhotoScan and can improve survey accuracy by an order of magnitude (Javernick *et al*. 2014), but the algorithm employed by it in this step is not disclosed.

The seventh step is also optional, but it is highly recommended in projects with large number of images. Before the MVS, the image set is decomposed into overlapping image clusters by a process called clustering views for MVS (CMVS — Furukawa *et al*. 2010). This operation allows the reconstruction of the dense points by MVS to be done globally in the individual clusters. Software like PhotoScan allows users to manually identify these clusters (or chunks) that are then aligned (merged) into a single point cloud.

The final stage of the SfM-MVS is the multi-view stereo (MVS) algorithm, which is responsible for the production of a dense point cloud with an increase of at least two orders of magnitude compared to the sparse point cloud. Patch-based MVS (PMVS — Furukawa & Ponce 2010) is widely used and comprises three main steps: matching features, expanding patches and filtering incorrect matches. The final output is the dense point cloud.

Results and processing

After the SfM-MVS process, the user has the freedom to decide how the data will be processed and which final product will be used. Both dense and sparse clouds can be exported and used directly in a GIS (Geographic Information System) environment, interpolated into Digital Elevation Models (DEMs) or converted to a 3D surface by generating a polygon mesh (Kazhdan & Hoppe 2013). The mesh — usually a Triangulated Irregular Network (TIN) — can also receive a texture provided by the photographs (Hanusch 2008), that assigns real-world color to the digital surface. Another result of the process that can be of great value in certain applications is the generation of ortophoto mosaics.

METHOD

The on-site study was conducted under five different days on July and September 2017. A total of 60 dikes were identified, described and had their geological attitude measured with a Brunton Geo Pocket Transit Compass. For georeferencing, two fixed points were placed ~1 km apart from each other and their coordinates obtained by post-processed static positioning using a Spectra Precision SP60 GNSS receiver, which yielded a final precision of 4 mm horizontal and 6 mm vertical. The two fixed points and 13 control points (printed markers) that were distributed on the outcrop were surveyed using a Topcon GPT-3200N reflectorless total station, which can provide a ± (3 mm + 2 ppm — D) m.s.e. accuracy (Fig. 1). All points were surveyed in UTM coordinate system (zone 23, southern hemisphere), SIRGAS2000 datum.

Weather conditions for all days of field work were of sunny, clear sky. Image acquisition was performed using two cameras, usually between 11:00 A.M.–02:00 P.M. A Nikon D7000 digital camera with a 23.6 mm × 15.6 mm CMOS sensor (4,928 × 3,264 pixels) and a 35 mm focal length lens was positioned ~15 m from the roadcut, generating 4 m wide windows. Perpendicular and left/right oblique images were taken from 1.5 m regularly spaced spots. This camera was set to ISO 100, "aperture-priority" (AP) mode, with f/8 aperture and shutter speed determined automatically. A Nikon Coolpix AW130 using 7.8 mm and 6.1 mm focal length was used for complementary oblique images at the same spots, for whole scene capture and detail photos, set to full automatic mode. The digital models were generated with Agisoft PhotoScan professional edition (version 1.1.6). The image selection was primarily based on illumination criteria, as the outcrop is prone to shadowing. The images were masked to remove vegetation and reduce processing time. No pre-calibration or post-editing were performed.

All the dikes measured in the field were identified on the digital model. Digital sampling and the calculation of geological attitudes using ply2atti algorithm was made using the workflow described in Viana *et al*. (2016). Plane selection was carried out on MeshLab (Cignoni *et al*. 2008) in two ways:

- a "punctual" measurement was made at the same locations of field survey using a 7 pixel circular brush;
- "surface" measurements were made painting in the whole visible surface of the dikes (Suppl. Fig. S3).

Where the DOM was not well reconstructed (distortions and artifacts), surface sampling was not performed (Suppl. Fig. S2), as the surface distortion would significantly affect measurement results.

RESULTS

For the model generation, different quality combinations on PhotoScan settings were tested (medium/high/highest). As there is no reference model, such as a LiDAR point cloud, the quality assessment of the generated DOM was done mainly by visual inspection. Due to its more resistant composition, the dikes stand out from the surrounding rocks generating shadows depending on the direction of illumination. This shadowing effect covers surface details of the dikes and results in voids or artifacts on the digital model. To work around this problem,

image sets taken at different scales and times of the day were combined to lighten some shadow areas, and this procedure has generated great improvement on the DOM quality (Suppl. Fig. S4).

The final digital outcrop was constructed from 473 images and comprises 7,524,684 vertices and 14,999,999 faces (based on a dense cloud with 51,314,241 points) (Fig. 2 and Suppl. Fig. S5). The image overlap is greater than 9 for almost all the model, georeferencing total error is 0.093 m, and the ground sampling distance (GSD) is 0.0023 m. The complete report can be seen on the Supplementary Material.

Clastic dikes are tabular bodies and as they stand out from the outcrop a box-shaped profile is expected. During the process of DOM construction, multiple settings were used on PhotoScan. In Figure 5, we compare the high quality model (the one used in this work) to one of the medium quality models that were generated during this process (using 106 images, generating a dense cloud with 30,660,551 vertices and 6,132,109 faces). We observe that the low quality DOM showed a more bell-shaped profile as a result of the surface construction. This effect is attenuated in the high-quality models, but it is not completely eliminated.

The digital surface sampling resulted in 70 measurements. Although some of the dikes that were measured in the field did not contribute to this sampling due to problems in surface generation, the increase in the number of measurements was mainly due to the fact that using the DOM it is possible to sample dikes that were inaccessible in the field.

Traditional geological compass, ply2atti (point and surface) and Turra (2009) geological attitudes were plotted on rose diagrams (Fig. 3) and stereonets (Fig. 6 and Suppl. Figs. S6, S7 and S8).

The angular deviation between dip directions and dips obtained through the traditional survey and the digital point sampling were calculated (Suppl. Tab. S1). Analyzing the angular difference between dips, 36.7% of the results are less than 5º apart, against 10% in dip directions. Increasing to 10º, 18.4% of dip directions results and 56.7% of dip results are below the threshold. For a visual comparison of the measurements with their respective errors (± 5º), small circles with a 5º radius were inserted into the stereonets (Fig. 6).

DISCUSSION AND CONCLUSIONS

Due to the great flexibility of SfM-MVS, it is necessary to emphasize that each application of the technique presents different difficulties and/or limitations. Since the studied outcrop is located in a dual carriage highway with heavy traffic, the constant activity of passing cars and trucks slowed down the positioning and surveying of GCPs. The terrain geometry and safety procedures constrained the access to the outcrop in terms of distance and viewpoints for image acquisition; given the desired level of detail for the DOM, the number of images obtained was high, consuming a considerable amount of storage memory.

The difference between the number of measurements taken in this work in relation to Turra (2009) also shows in the statistics, since we did not reconstruct the whole outcrop and that some dikes are now inaccessible or covered by vegetation. Due to this difference in the amount

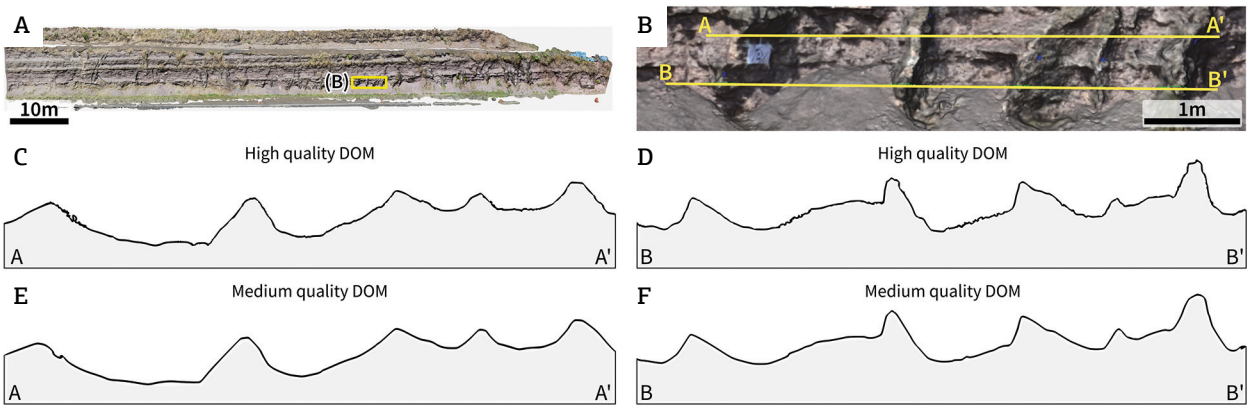

Figure 5. Digital Outcrop Models (DOMs) sections showing the difference between medium- and high-quality processing options of Agisoft PhotoScan. Sections were generated using CloudCompare (CloudCompare 2018). (A) Entire DOM showing location of inset (B) highlighted in yellow. (B) Inset of DOM showing location of sections (profiles) A-A' and B-B'. (C) Section A-A', high quality DOM. (D) Section B-B', high quality DOM. (E) Section A-A', medium quality DOM. (F) Section B-B', medium quality DOM.

of measurements, some variation in the statistical analysis, also reflected in the rose diagrams, is expected. However, we can observe that the NNW preferential direction observed in the outcrop remains, although there is a certain NNE variation present.

Comparing the measurements obtained in the field activity of this work with the punctual ones obtained by ply2atti, a certain variation is observable, mainly on dip directions (Fig. 6). This factor can be related to field practices, which do not necessarily provide an accurate measurement due to misuse of the compass, or caused by manual adjustment of the plane, but it can also be explained by the deviation of the walls of the dikes on the DOM that is reflected in the profiles of Figure 5.

Since the walls of the dikes present roughness and variable degree of undulation, a single measurement performed with magnetic compass may not represent the best-fit plane. Ply2atti was created to provide an average geological attitude based on hundreds to millions of points on the surface, so the best practice would be to select the entire side of the dike leading to the best possible adjustment, as done by the "surface" digital sampling. However, as mentioned earlier, voids and artifacts on the digital model may segment or distort these surfaces, making them unreliable for this type of sampling. Cawood *et al.* (2017) describe these distortions and voids caused by occlusion during sampling and emphasize that this is an effect of the characteristic morphology of the area; to work around this problem, the authors used an UAV to provide the camera positions and angles to fully reconstruct the outcrop. A careful analysis of the study area should consider the geometry of the features of interest and more than one source for the complete imaging of the outcrop whenever possible.

According to the goals established for the project, it is possible to conclude that the objectives were reached, although the case addressed does not represent a simple application for the chosen techniques, due to the lithological and structural complexity of the outcrop.

Three-dimensional reconstruction with SfM-MVS was successfully performed. However, it can still be improved. A study on the combination of the following factors can provide answers on this question: resolution of the photographs, area of overlap, imaging geometry (perpendicular to the outcrop or convergent) and influence of the direction of illumination.

ACKNOWLEDGMENTS

We would like to thank CCR AutoBAn for the authorization to execute this research on the highway area and all the on-site support. This project is supported by Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) (grant #2016/06628-0). M.S.T. Busarello carried out an initial analysis of the data as her Bachelor degree final project, under the supervision of C.H. Grohmann and C.D. Viana. C.D. Viana and G.P.B. Garcia are PhD students of the graduate program in Mineral Resources and Hydrogeology, at Institute of Geoscience at the Universidade de São

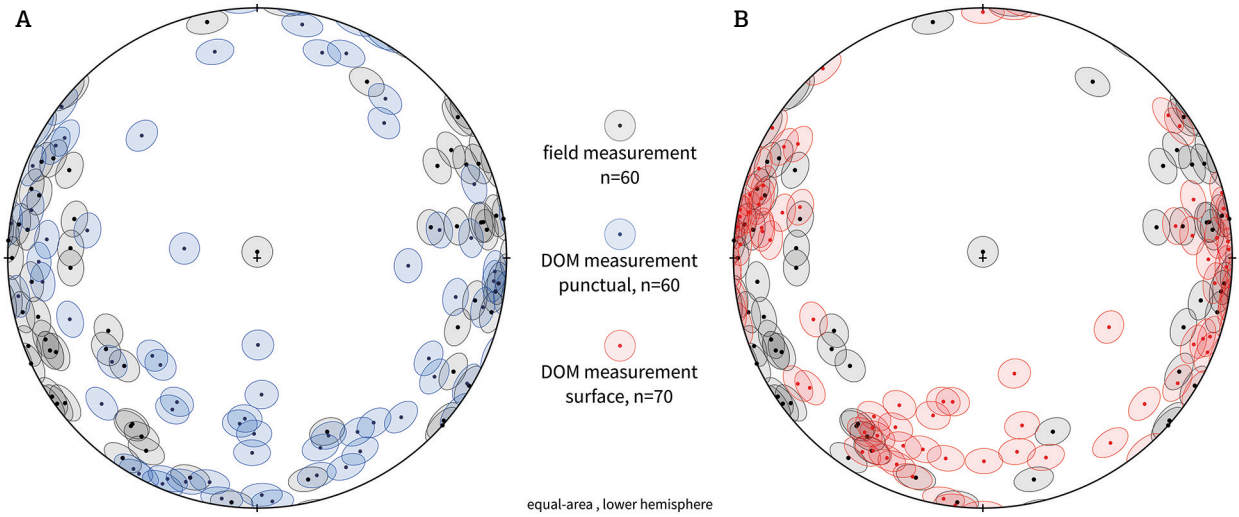

Figure 6. Stereonets: (A) poles of planes measured in the field (grey) and digital measurement in "punctual" mode (blue); (B) poles of planes measured in the field (grey) and digital measurement in "surface" mode (red). Small circles represent a ± 5º error tolerance for each measurement.

Paulo (IGc-USP), with scholarships from Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) (grant #1770206 to C.D.V.) and Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (grant #133050/2013-0 to G.P.B.G.). C.H. Grohmann is a CNPq research fellow (grant #307647/2015-3). Acknowledgments are extended to the associate editor and the anonymous reviewers for their criticism and suggestions, which helped to improve this paper.

APPENDIX

Best Practices For Fieldwork

In this section, we present a small set of guidelines to increase efficiency and avoid common mistakes during fieldwork for SfM-MVS data collecting, derived from the experience gained by the authors during the development of this project.

- *Know thy enemy:* it is very important to know the area to be surveyed beforehand. A simple "visit" with GoogleEarth™ won't be enough to properly plan the activities. Visit the area and check for access paths, parking areas, places to position the equipment (GPS, Total Station, etc.) and physical constraints for image acquisition (can you get close of the outcrop, or do you need telephoto lens?);
- *Rome wasn't built in a day:* always plan for more than one day of fieldwork (or plan more than one short trip). Acquiring DGPS data and total station readings will take at least a day. With post-processing of DGPS data, the precise coordinates will only be available after you return to the office. Usually there's not enough time to collect total station, DGPS data and take the photographs on the same day (unless there's a big team working at the same time);
- *Let there be light:* good lightning is the key to a successful SfM-MVS reconstruction. If the target outcrop is not so large, and you plan to do all (DGPS, total station and photographs) on one day, attach the targets to the outcrop and take the photographs before setting up the total station and DGPS, to take advantage of the mid-morning light. Try to avoid very sunny days since the shadows will be harder. If at all possible, try to take the photographs in cloudy days. There are several mobile applications that can help to predict the position of the sun (and shadows) for any place on Earth at any desired date and time;
- *The need for speed:* always use the best (and fastest) memory cards, to avoid file corruption. If taking photographs in RAW format, there is usually a 1- to 2-seconds delay for the file to be written before you can take another one. With UAVs (drones) this delay is accounted for in the time it takes for the aircraft to move from one waypoint to the next, but with handheld cameras it's easy to forget about this and take several pictures in sequence, just to realize the files weren't recorded correctly after you're back in the office. Respect the limitations of your equipment and avoid adapters such as using mini-SD cards with a SD-compatible camera. Take a laptop to the field and download the photos immediately, to check for any errors;
- *Need for speed II:* try to take the photographs in a timely manner. Don't take too long to acquire the images of the entire outcrop, as the light can change both in position and in quality (with a passing cloud, for instance). If possible, take pictures in the morning and in the afternoon;
- *Fixed point in time:* use permanent markers for the survey points (total station, GPS) such as a steel screw with a small metal washer inserted into the asphalt of a roadway. This will allow you to re-occupy the same point in case additional surveys are necessary, without the need to collect more DGPS data. If possible, insert at least a couple of screws in the outcrop, placed far from each other. In case you need/want to return another day and make a new set of photographs, most likely you will need to place a new set of targets for georeferencing. It will be much faster to set the total station from the known X, Y, Z coordinates of the outcrop points than from the (distant) DGPS points;
- *Get the big picture:* take photographs of the outcrop from a larger distance, to create a preliminary 3D model that can help you plan for the next steps of the project, like positioning of targets, effects of illumination, etc. This model can be built in the field with "low-quality" settings of any SfM-MVS software, which do not require much RAM memory or processing power;
- *Power to the people:* check all your batteries the day beforehand, but carry a "power bank" to the field. It can save the trip if by any chance the GPS Data Collector, a small camera or even your cellphone runs out of juice.

SUPPLEMENTARY DATA

Supplementary data associated with this article can be found in the online version: Supplementary Table: S1 and Supplementary figures S1-S8.

REFERENCES

Agisoft. 2018. *Agisoft photoscan user manual professional edition, version 1.4*. Agisoft. Available at: <http://www.agisoft.com/pdf/photoscan-pro_1_4_en.pdf>. Accessed on: August, 2018.

Allen J.R.L. 1982. *Sedimentary Structures Their Character and Physical Basis*. v. II. Volume 30B of Developments in Sedimentology. Amsterdam, New York: Elsevier.

Assali P., Grussenmeyer P., Villemin T., Pollet N., Viguier F. 2014. Surveying and modeling of rock discontinuities by terrestrial laser scanning and photogrammetry: Semi-automatic approaches for linear outcrop inspection. *Journal of Structural Geology* **66**:102-114. https://doi.org/10.1016/j.jsg.2014.05.014

Beis J.S., Lowe D.G. 1997. Shape indexing using approximate nearest-neighbour search in high-dimensional spaces. *In*: Conference on Computer Vision and Pattern Recognition. *Proceedings...* IEEE Computer Society. p. 1000. Available at: <http://dl.acm.org/citation.cfm?id=794189.794431>. Accessed on: August, 2018.

Bemis S.P., Micklethwaite S., Turner D., James M.R., Akciz S., Thiele S.T., Bangash H.A. 2014. Ground-based and UAV-Based photogrammetry: A multi-scale, high-resolution mapping tool for structural geology and paleoseismology. *Journal of Structural Geology*, **69**(Part A):163-178. https://doi.org/10.1016/j.jsg.2014.10.007

Biber K., Khan S.D., Seers T.D., Sarmiento S., Lakshmikantha M. 2018. Quantitative characterization of a naturally fractured reservoir analog using a hybrid lidar-gigapixel imaging approach. *Geosphere*, **14**(2):710-730. https://doi.org/10.1130/GES01449.1

Bisdom K., Nick H.M., Bertotti G. 2017. An integrated workflow for stress and flow modelling using outcrop-derived discrete fracture networks. *Computers and Geosciences*, **103**:21-35. https://doi.org/10.1016/j.cageo.2017.02.019

Bistacchi A., Balsamo F., Storti F., Mozafari M., Swennen R., Solum J., Tueckmantel C., Taberner C. 2015. Photogrammetric digital outcrop reconstruction, visualization with textured surfaces, and three-dimensional structural analysis and modeling: Innovative methodologies applied to fault-related dolomitization (Vajont Limestone, Southern Alps, Italy). *Geosphere*, **11**(6):2031-2048. https://doi.org/10.1130/GES01005.1

Brown D.C. 1958. A solution to the general problem of multiple station analytical stereotriangulation. Technical Report 43. RCA-MTP. Available at: <https://books.google.com.br/books?id=FikPPwAACAAJ>. Accessed on: August, 2018.

Buyer A., Schubert W. 2016. Extraction of discontinuity orientations in point clouds. *In*: Ulusay R., Gercek H., Hindistan M.A., Aydan O., Tuncay E. (Eds.), *Rock Mechanics and Rock Engineering:* from the Past to the Future. Ürgüp: CRC Press, p. 1133-1138.

Carbonneau P.E., Dietrich J.T. 2017. Cost-effective non-metric photogrammetry from consumer-grade sUAS: implications for direct georeferencing of structure from motion photogrammetry. *Earth Surface Processes and Landforms*, **42**(3):473-486. https://doi.org/10.1002/esp.4012

Carrivick J.L., Smith M.W., Quincey D.J. 2016. *Structure from Motion in the Geosciences*. West Sussex: John Wiley & Sons. https://doi.org/10.1002/9781118895818

Cawood A.J., Bond C.E., Howell J.A., Butler R.W., Totake Y. 2017. LiDAR, UAV or compass-clinometer? Accuracy, coverage and the effects on structural models. *Journal of Structural Geology*, **98**:67-82. https://doi.org/10.1016/j.jsg.2017.04.004

Chamani M.A. 2015. *Tectônica Sinsedimentar no Siluro-Devoniano da Bacia do Parnaíba, Brasil: O Papel de Grandes Estruturas do Embasamento na Origem e Evolução de Bacias Intracratônicas*. PhD Thesis, Instituto de Geociências, Universidade de São Paulo, São Paulo. https://doi.org/10.11606/T.44.2016.tde-04052016-111511

Chamani M.A., Martin M., Riccomini C. 1992. Estruturas de liqüefação induzidas por abalos sísmicos no permo–triássico da Bacia do Paraná, Estado de São Paulo, Brasil. *In*: Congresso Brasileiro de Geologia. *Annals...* p. 508-510.

Cignoni P., Callieri M., Corsini M., Dellepiane M., Ganovelli F., Ranzuglia G. 2008. MeshLab: an Open-Source Mesh Processing Tool. *In*: Scarano V., Chiara R.D., Erra U. (Eds.), *Eurographics Italian Chapter Conference*. Salerno: The Eurographics Association. https://doi.org/10.2312/LocalChapterEvents/ItalChap/ItalianChapConf2008/129-136

CloudCompare. 2018. *Cloudcompare 2.9.1*. Available at: <https://www.cloudcompare.org>. Accessed on: August, 2018.

Conlin M., Cohn N., Ruggiero P. 2018. A Quantitative Comparison of Low-Cost Structure from Motion (SfM) Data Collection Plat- forms on Beaches and Dunes. *Journal of Coastal Research*. https://doi.org/10.2112/JCOASTRES-D-17-00160.1

Deb D., Hariharan S., Rao U., Ryu C.H. 2008. Automatic detection and analysis of discontinuity geometry of rock mass from digital images. *Computers and Geosciences*, **34**(2):115-126. https://doi.org/10.1016/j.cageo.2007.03.007

Dietrich J.T. 2017. Bathymetric Structure-from-Motion: extracting shallow stream bathymetry from multi-view stereo photogrammetry. *Earth Surface Processes and Landforms*, **42**(2):355-364. https://doi.org/10.1002/esp.4060

Eos Systems Inc. 2014. *Photomodeler quick start guide*. Eos Systems Inc. Available at: <https://www.photomodeler.com/order/PhotoModeler_QuickStartGuide.pdf>. Accessed on: August, 2018.

Fernandes L., Coimbra A. 1993. Registros de episódios sísmicos na parte superior da Formação Rio do Rasto no Paraná, Brasil. *In*: Simpósio de Geologia do Sudeste. *Annals...*, p. 271-275.

Fischler M.A., Bolles R.C. 1981. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, **24**(6):381-395. https://doi.org/10.1145/358669.358692

Fonstad M.A., Dietrich J.T., Courville B.C., Jensen J.L., Carbonneau P.E. 2013. Topographic structure from motion: A new development in photogrammetric measurement. *Earth Surface Processes and Landforms*, **38**(4):421-430. https://doi.org/10.1002/esp.3366

Furukawa Y., Curless B., Seitz S.M., Szeliski R. 2010. Towards Internet-scale multi-view stereo. *In*: Computer Vision and Pattern Recognition, IEEE Conference. *Annals...* p. 1434-1441. https://doi.org/10.1109/CVPR.2010.5539802

Furukawa Y., Ponce J. 2010. Accurate, Dense, and Robust Multi-View Stereopsis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **32**(8):1362-1376. https://doi.org/10.1109/TPAMI.2009.161

Gates W.C.B., Haneberg W.C. 2012. Comparison of Standard Structural Mapping Results to 3-D Photogrammetric Model Results: Boundary Transformer Banks Rockfall Mitigation Project, Metaline Falls, Washington. *In*: US Rock Mechanics / Geomechanics Symposium, 46. *Annals...* Chicago: American Rock Mechanics Association.

Haneberg W.C. 2008. Using close range terrestrial digital photogrammetry for 3-D rock slope modeling and discontinuity mapping in the United States. *Bulletin of Engineering Geology and the Environment*, **67**(4):457-469. https://doi.org/10.1007/s10064-008-0157-y

Hanusch T. 2008. A new texture mapping algorithm for photorealistic reconstruction of 3D objects. *In*: ISPRS Congress, 21. Proceedings... p. 699-706. Available at: <http://www.isprs.org/proceedings/XXXVII/congress/5_pdf/123.pdf>. Accessed on: August, 2018.

Hargitai H., Levi T. 2014. Clastic Dike. *In*: Hargitai H., Kereszturi A. (Eds.), *Encyclopedia of Planetary Landforms*. New York: Springer, p. 1-9. https://doi.org/10.1007/978-1-4614-9213-9_99-1

Hodgetts D. 2013. Laser scanning and digital outcrop geology in the petroleum industry: A review. *Marine and Petroleum Geology*, **46**:335-354. https://doi.org/10.1016/j.marpetgeo.2013.02.014

James M.R., Robson S. 2012. Straightforward reconstruction of 3D surfaces and topography with a camera: Accuracy and geoscience application. *Journal of Geophysical Research: Earth Surface*, **117**(F3):1-17. https://doi.org/10.1029/2011JF002289

James M.R., Robson S. 2014. Mitigating systematic error in topographic models derived from UAV and ground-based image networks. *Earth Surface Processes and Landforms*, **39**(10):1413-1420. https://doi.org/10.1002/esp.3609

James M.R., Robson S., d'Oleire-Oltmanns S., Niethammer U. 2017. Optimising UAV topographic surveys processed with structure-from-motion: Ground control quality, quantity and bundle adjustment. *Geomorphology*, **280**:51-66. https://doi.org/10.1016/j.geomorph.2016.11.021

Javernick L., Brasington J., Caruso B. 2014. Modeling the topography of shallow braided rivers using Structure-from-Motion photogrammetry. *Geomorphology*, **213**:166-182. https://doi.org/10.1016/j.geomorph.2014.01.006

Jordá-Bordehore L., Riquelme A., Cano M., Tomás R. 2017. Comparing manual and remote sensing field discontinuity collection used in kinematic stability assessment of failed rock slopes. *International Journal of Rock Mechanics and Mining Sciences*, **97**:24-32. https://doi.org/10.1016/j.ijrmms.2017.06.004

Kazhdan M., Hoppe H. 2013. Screened Poisson Surface Reconstruction. *ACM Transactions on Graphics*, **32**(3). https://doi.org/10.1145/2487228.2487237

Lhuillier M., Yu S. 2013. Manifold surface reconstruction of an environment from sparse Structure-from-Motion data. *Computer Vision and Image Understanding*, **117**(11):1628-1644. https://doi.org/10.1016/j.cviu.2013.08.002

Lowe D. 1999. Object recognition from local scale-invariant features. *Proceedings of the Seventh IEEE International Conference on Computer Vision*, **2**:1150-1157. https://doi.org/10.1109/ICCV.1999.790410

Lowe D. 2001. Local feature view clustering for 3D object recognition. Proceedings of the 2001 *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. CVPR 2001. https://doi.org/10.1109/CVPR.2001.990541

Lowe D.G. 2004. Distinctive Image Features from Scale-Invariant Keypoints. International *Journal of Computer Vision*, **60**(2):91-110. https://doi.org/10.1023/B:VISI.0000029664.99615.94

Madjid M., Vandeginste V., Hampson G., Jordan C., Booth A. 2018. Drones in carbonate geology: Opportunities and challenges, and application in diagenetic dolomite geobody mapping. *Marine and Petroleum Geology*, **91**:723-734. https://doi.org/10.1016/j.marpetgeo.2018.02.002

Mali V.K., Kuiry S.N. 2018. Assessing the accuracy of high-resolution topographic data generated using freely available packages based on SfM-MVS approach. *Measurement: Journal of the International Measurement Confederation*, **124**:338-350. https://doi.org/10.1016/j.measurement.2018.04.043

Matthews N.A. 2008. Aerial and Close-Range Photogrammetric Technology: Providing Resource Documentation, Interpretation, and Preservation. Technical Note 428. Technical Report. Denver, Colorado: U.S. Department of the Interior, Bureau of Land Management, National Operations Center. Available at: <https://www.blm.gov/download/file/fid/20806>. Accessed on: August, 2018.

Mikolajczyk K., Schmid C. 2005. A performance evaluation of local descriptors. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **27**(10):1615-1630. https://doi.org/10.1109/TPAMI.2005.188

Mikolajczyk K., Tuytelaars T., Schmid C., Zisserman A., Matas J., Schaffalitzky F., Kadir T., Van Gool L. 2005. A comparison of affine region detectors. *International Journal of Computer Vision*, **65**(1-2):43-72. https://doi.org/10.1007/s11263-005-3848-x

OpenDroneMap. 2014. *OpenDroneMap*. Available at: <https://www.opendronemap.org/>. Accessed on: August, 2018.

Ouédraogo M.M., Degré A., Debouche C., Lisein J. 2014. The evaluation of unmanned aerial system-based photogrammetry and terrestrial laser scanning to generate DEMs of agricultural watersheds. *Geomorphology*, **214**:339-355. https://doi.org/10.1016/j.geomorph.2014.02.016

Perinotto J.A.J., Etchebehere M.L.C., Simões L.S.A., Zanardo A. 2008. Diques clásticos na formação Corumbataí (P) no nordeste da Bacia do Paraná, SP: Análise sistemática e significações estratigráficas, sedimentológicas e tectônicas. *Geociências*, **27**(4):469-491. Available at: <http://www.periodicos.rc.biblioteca.unesp.br/index.php/geociencias/article/view/3417>. Accessed on: August, 2018.

Pix4D SA. 2017. *Pix4dmapper 3.2 user manual*. Pix4D SA. Available at: <https://s3.amazonaws.com/mics.pix4d.com/manual_pdf/Pix4Ddesktop_Manual_3.2_May_2017.pdf>. Accessed on: August, 2018.

Pringle J.K., Clark J.D., Westerman A.R., Stanbrook D.A., Gardiner A.R., Morgan B.E. 2001. Virtual outcrops: 3-D reservoir analogues. *Journal of the Virtual Explorer*, **4**(9). https://doi.org/10.3809/jvirtex.2001.00036

Pringle J.K., Crawford D.C., Clark J.D., Gardiner A., Westerman A.R., Morgan B.E.F., Green S. 1999. A novel technique integrating digital photogrammetry with geological and geophysical data to acquire 3D architectures at Alport Castles, Derbyshire, UK. *In*: BSRG Annual Conference, Edinburgh. *Annals*...

Riccomini C. 1995. *Tectonismo gerador e deformador dos depósitos sedimentares pós-gondvânicos da porção centro-oriental do Estado de São Paulo e áreas vizinhas*. PhD Thesis. Instituto de Geociências, Universidade de São Paulo, São Paulo. https://doi.org/10.11606/T.44.2013.tde-03062013-103524

Riccomini C., Chamani M.A.C., Agena S.S., Fambrini G.L., Fairchild T.R., Coimbra A.M. 1992. Earthquake-induced liquefaction features in the Corumbataí Formation (Permian, Paraná Basin, Brazil) and the dynamics of Gondwana. *Anais da Academia Brasileira de Ciências*, **64**:210.

Riccomini C., Sallun Filho W., Ferreira N., Coimbra A. 1996. Estruturas de liquefação em arenitos eólicos da Formação Botucatu (Ki) na Serra de Itaqueri, SP. *In*: Congresso Brasileiro de Geologia. *Annals*... p. 151–153.

Riquelme A., Cano M., Tomás R., Abellán A. 2017. Identification of Rock Slope Discontinuity Sets from Laser Scanner and Photogrammetric Point Clouds: A Comparative Analysis. *Procedia Engineering*, **191**:838-845. https://doi.org/10.1016/j.proeng.2017.05.251

Riquelme A.J., Tomás R., Abellán A. 2016. Characterization of rock slopes through slope mass rating using 3D point clouds. *International Journal of Rock Mechanics and Mining Sciences*, **84**:165-176. https://doi.org/10.1016/j.ijrmms.2015.12.008

Rupnik E., Daakir M., Deseilligny M.P. 2017. MicMac - a free, open-source solution for photogrammetry. *Open Geospatial Data, Software and Standards*, **2**:14. https://doi.org/10.1186/s40965-017-0027-2

Schönberger J.L., Frahm J.M. 2016. Structure-from-Motion Revisited. *In*: Conference on Computer Vision and Pattern Recognition (CVPR). *Annals*... https://doi.org/10.1109/CVPR.2016.445

Schönberger J.L., Zheng E., Frahm J.M., Pollefeys M. 2016. Pixelwise View Selection for Unstructured Multi-View Stereo. *In*: European Conference on Computer Vision (ECCV). *Annals*... p. 501-518. https://doi.org/10.1007/978-3-319-46487-9_31

Silva R., Veronez M., Tognoli F.M., Souza M., Inocêncio L. 2014. Accuracy Analysis of Digital Outcrop Models Obtained from Terrestrial Laser Scanner (TLS). *International Journal of Advanced Remote Sensing and GIS*, **3**:508–515. Available at: <http://technical.cloud-journals.com/index.php/IJARSG/article/view/Tech-149>. Accessed on: August, 2018.

Slama C.C. 1980. *Manual of Photogrammetry*. Technical Report. Falls Church, VA, American Society of Photogrammetry.

Snavely N., Seitz S.M., Szeliski R. 2006. Photo tourism: exploring photo collections in 3D. *ACM Transactions on Graphics*, **25**(3):835-846. https://doi.org/10.1145/1179352.1141964

Sturzenegger M., Stead D. 2009. Close-range terrestrial digital photogrammetry and terrestrial laser scanning for discontinuity characterization on rock cuts. *Engineering Geology*, **106**(3-4):163-182. https://doi.org/10.1016/j.enggeo.2009.03.004

Tavani S., Corradetti A., Billi A. 2016. High precision analysis of an embryonic extensional fault-related fold using 3D orthorectified virtual outcrops: The viewpoint importance in structural geology. *Journal of Structural Geology*, **86**:200-210. https://doi.org/10.1016/j.jsg.2016.03.009

Tavani S., Granado P., Corradetti A., Girundo M., Iannace A., Arbués P., Munõz J., Mazzoli S. 2014. Building a virtual outcrop, extracting geological information from it, and sharing the results in Google Earth via OpenPlot and Photoscan: An example from the Khaviz Anticline (Iran). *Computers and Geosciences*, **63**:44-53. https://doi.org/10.1016/j.cageo.2013.10.013

Tohver E., Cawood P.A., Riccomini C., Lana C., Trindade R.I.F. 2013. Shaking a methane fizz: Seismicity from the Araguainha impact event and the Permian-Triassic global carbon isotope record. *Palaeogeography, Palaeoclimatology, Palaeoecology*, **387**:66-75. http://dx.doi.org/10.1016/j.palaeo.2013.07.010

Tohver E., Schmieder M., Lana C., Mendes P.S.T., Jourdan F., Warren L., Riccomini C. 2018. End-Permian impactogenic earthquake and tsunami deposits in the intracratonic Paraná Basin of Brazil. *GSA Bulletin*, **130**(7-8):1099-1120. https://doi.org/10.1130/B31626.1

Turner D., Lucieer A., Watson C. 2012. An automated technique for generating georectified mosaics from ultra-high resolution Unmanned Aerial Vehicle (UAV) imagery, based on Structure from Motion (SFM) point clouds. *Remote Sensing*, **4**(5):1392-1410. https://doi.org/10.3390/rs4051392

Turra B.B. 2009. *Diques clásticos da Formação Corumbataí, Bacia do Paraná, no contexto da tectônica permotriássica do Gondwana Ocidental*. MS Dissertation. Instituto de Geociências, Universidade de São Paulo, São Paulo. https://doi.org/10.11606/D.44.2009.tde-06072009-111626

Vasuki Y., Holden E.J., Kovesi P., Micklethwaite S. 2014. Semi-automatic mapping of geological Structures using UAV-based photogrammetric data: An image analysis approach. *Computers and Geosciences*, **69**:22-32. http://dx.doi.org/10.1016/j.cageo.2014.04.012

Verma A.K., Bourke M.C. 2018. A Structure from Motion photogrammetry-based method to generate sub-millimetre resolution Digital Elevation Models for investigating rock breakdown features. *Earth Surface Dynamics Discussions*, 1-34. https://doi.org/10.5194/esurf-2018-53

Viana C.D., Endlein A., da Cruz Campanha G.A., Grohmann C.H. 2016. Algorithms for extraction of structural attitudes from 3D outcrop models. *Computers and Geosciences*, **90**(Part A):112-122. https://doi.org/10.1016/j.cageo.2016.02.017

Westoby M., Brasington J., Glasser N., Hambrey M., Reynolds J. 2012. 'Structure-from-Motion' photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, **179**:300-314. https://doi.org/10.1016/j.geomorph.2012.08.021

Wu C. 2013. Towards linear-time incremental structure from motion. *In*: 3D Vision-3DV 2013, 2013 International Conference on, IEEE. *Annals*... p. 127-134. https://doi.org/10.1109/3DV.2013.25

Wu C., Agarwal S., Curless B., Seitz S.M. 2011. Multicore bundle adjustment. *In*: Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference. *Annals*... p. 3057-3064. https://doi.org/10.1109/CVPR.2011.5995552

Zachariah D.F., Terry L.P. 2018. An orientation based correction method for SfM-MVS point clouds. Implications for field geology. *Journal of Structural Geology*, **113**:76-89. https://doi.org/10.1016/j.jsg.2018.05.014

Zahm C., Lambert J., Kerans C. 2016. Use of Unmanned Aerial Vehicles (UAVs) to create Digital Outcrop Models: an example from the Cretaceous Cow Creek Formation, Central Texas. *Gulf Coast Association of Geological Societies Journal*, **5**:180-188. Available at: <http://archives.datapages.com/data/gcags-journal/data/005/005001/pdfs/180.htm>. Accessed on: August, 2018.

Zitová B., Flusser J. 2003. Image registration methods: a survey. *Image and Vision Computing*, **21**(11):977-1000. https://doi.org/10.1016/S0262-8856(03)00137-9

© 2018 Sociedade Brasileira de Geologia
This is an open access article distributed under the terms of the Creative Commons license.

Anexo C. Resumos expandidos apresentados ao XIX Simpósio Brasileiro de Sensoriamento Remoto 2019

Resumos expandidos apresentados ao XIX Simpósio Brasileiro de Sensoriamento Remoto 2019, realizado de 14 a 17 de Abril de 2019, na cidade de Santos - SP.

Anexo C.1. *Comparing Terrestrial Laser Scanner and UAV-based photogrammetry to generate a landslide DEM*

COMPARING TERRESTRIAL LASER SCANNER AND UAV-BASED PHOTOGRAMMETRY TO GENERATE A LANDSLIDE DEM

Guilherme P. B. Garcia[1], Elton B. Gomes[2], Camila D. Viana[3] and Carlos H. Grohmann[4]

[1] Institute of Geosciences (IGc) - USP, São Paulo, 05508-080, Brazil, guilherme.pereira.garcia@usp.br, [2] IGc-USP, elton.gomes@usp.br; [3] IGc-USP, camila.viana@usp.br; [4] Institute of Energy and Environment (IEE) - USP, São Paulo, 05508-010, Brazil, guano@usp.br. All authors: Spatial Analysis And Modelling Lab (SPAMLab) – IEE-USP

ABSTRACT

Gravitational mass movements like landslides are natural destructive processes that can cause enormous losses. Although crucial, identification and monitoring of such areas is time consuming and costly. New technologies such as laser scanning, unmanned aerial vehicles (UAV) and Structure-from-Motion – Multi-View Stereo (SfM-MVS) photogrammetry provides an alternative to conventional mapping methods. A hill with a landslide located in the city of Cunha - SP was surveyed by terrestrial laser scanner (TLS) and UAV-based SfM-MVS. The cloud-to cloud distance was calculated. SfM-MVS point cloud covers a larger area and point distribution is more homogeneous while TLS points have an uneven distribution. Small distances were predominant in the vicinity of the landslide and greater differences only occurred on the scene edges. We conclude that both TLS and UAV SfM-MVS are suitable for landslide investigation according to terrain conditions and other visible limitation factors.

Key words – *Laser scanning, Photogrammetry, Landslides, TLS, DEM.*

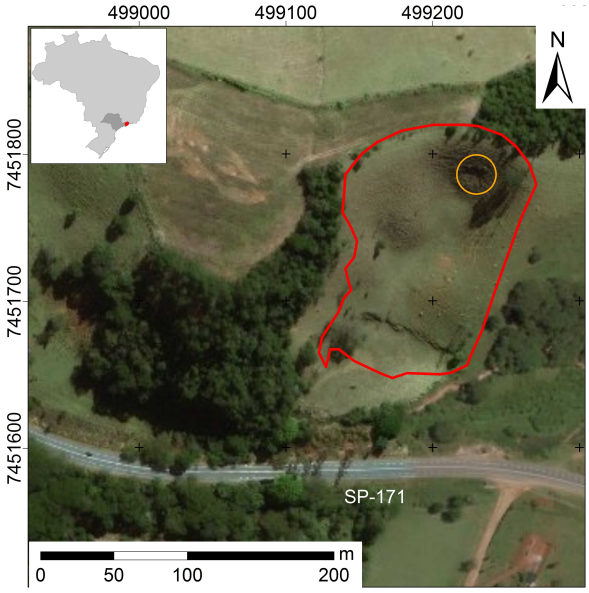

Figure 1: Location map of the Cunha City (left) and of the study area (right). The red line represents the survey boundary and the orange line the area affected by the landslide. Satellite imagery ©2017 Digital Globe, powered by Google. UTM coordinates, zone 23 (South), WGS84.

1. INTRODUCTION

Hill slopes, mainly unvegetated ones, undergo several erosive processes that can compromise their stability. The occurrence of gravitational mass movements in these slopes is usually triggered by natural phenomena such as rains and earthquakes, which when near to highways or inhabited areas can cause enormous economic losses, environmental harm and deaths [1]. Therefore, identification and monitoring of such areas are of high importance for governmental purposes.

Both terrestrial (TLS) and aerial (ALS) laser scanning applied to landslides mapping offers many advantages over traditional methods such as fieldwork, topographic map digitization and aerial photography [2–5]. It allows generation of three-dimensional topographic models, being a more precise method and with little human interference in data acquisition [6]. Rapid data processing with repeated scans and high precision enhances morphometric changes in topography which may indicate sliding process. The combination of Unmanned Aerial Vehicles (UAVs) and Structure-from-Motion–Multi-view Stereo (SfM-MVS) photogrammetry is becoming an increasingly effective tool to gather outcrop data, particularly in the small- to intermediate-scale range and in areas of difficult access [7]. Photogrammetry was pioneer in the development of new methods for topographical surveying and processing, using digital cameras for data collection and softwares for 3D modelling [8].

Both TLS and UAV SfM-MVS methods have been used for landslide monitoring, mapping and 3D surface reconstruction [9–13]. This methods shows great advantages over conventional, costly and time consuming methods but also have their own cons which can compromise the entire project.

In this work we compare point clouds generated by TLS and UAV SfM-MVS for the same area and evaluate which one is more accurate, thus providing better results and allowing more consistent surface interpretation.

2. MATERIAL AND METHODS

2.1. Study area

The surveyed area is located in Cunha City (São Paulo State, southeastern Brazil), at the roadside of km 40 of the Paulo Virgínio Highway (SP-171), and has approximately 15.000 m^2 in area (Fig. 1). The landslide is 14,5 m long and 10 m wide, totaling an area of 145 m^2. The volume displaced from the hill is of 77 m^3 and the main scarp is almost 2 m high. The area presents sparse vegetation, mainly constituted by grass, and soil are partially exposed.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

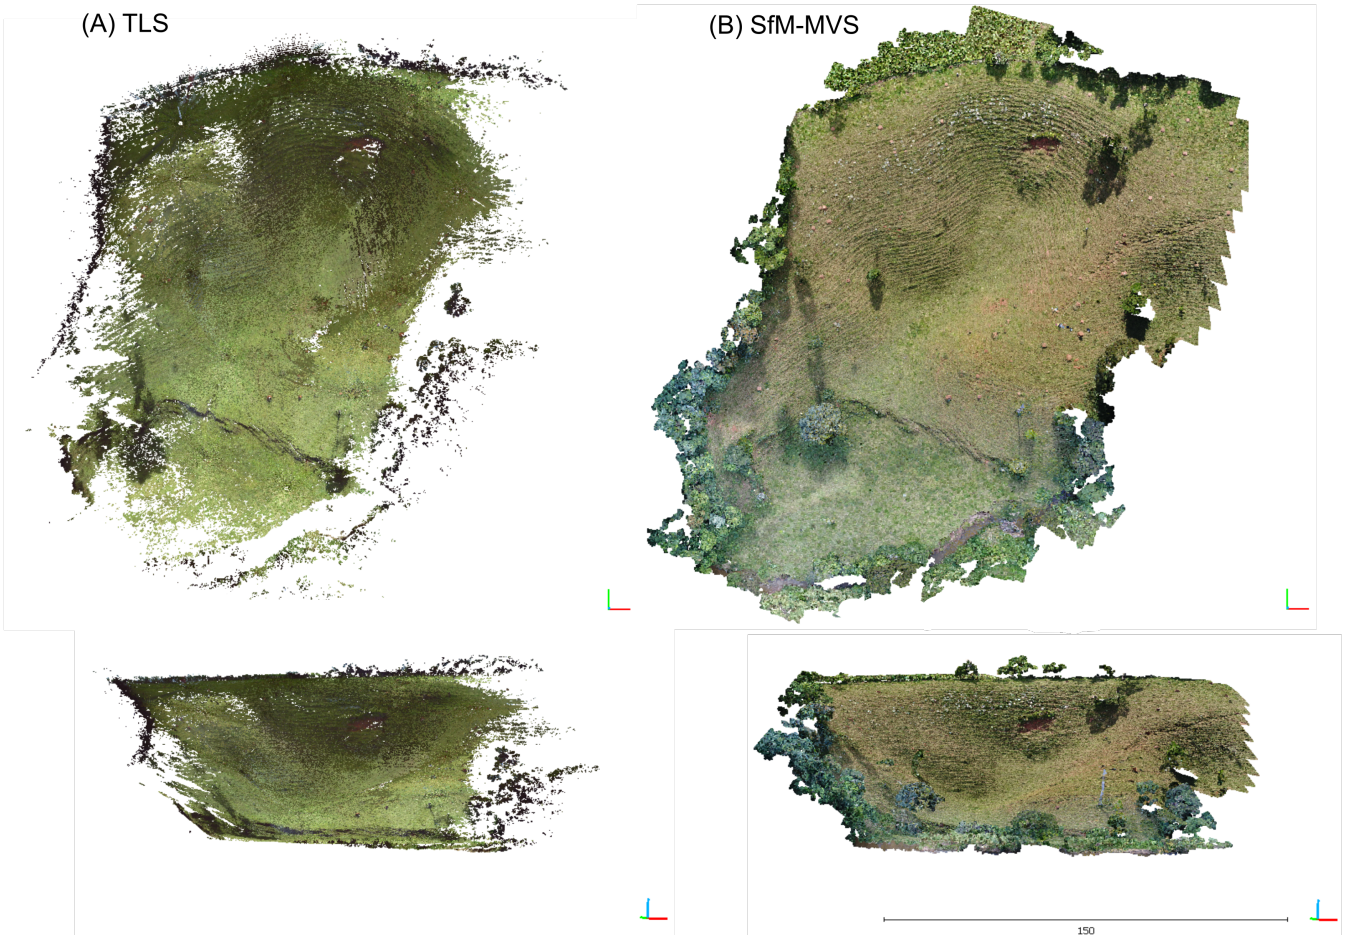

Figure 2: TLS (A) and SfM-MVS (B) point clouds.

2.2. Terrestrial Laser Scanner

A 360° survey was performed from 11 stations allocated around the slide area to generate the TLS point cloud, using a FARO Focus^S 150 Light Detecting and Ranging (LiDAR) equipment. For georeferencing, 8 printed targets were evenly distributed around the landslide and surveyed by irradiation using a total station (TS). Coordinates were collected in field by a Spectra Precision 60 (SP60) equipment and geodetic GNSS post-processing in SPoffice software was used to obtain precise coordinates.

2.3. UAV-based photogrammetry

The image acquisition was made using a DJI Phantom 4 Pro UAV. The onboard digital camera has an 1" CMOS 20MP sensor, with FOV of 84° and 8.8 mm focal distance (24 mm at 35 mm equivalent). The UAV autonomous mission was programed with the MapPilot App [14] which allows the flight height to be set as a constant value above a reference DEM (SRTM), resulting in more consistent pixel size values across the imaged area, even in situations of high relief.

Two missions were flown to cover the entire hillside, both at 40 m above the terrain and with lateral and frontal overlap of 80% between photos. For georeferencing, the same targets and coordinates used for the TLS point cloud were applied.

3. RESULTS AND DISCUSSION

TLS raw data is a point cloud with 128,513,743 points (Fig. 2A). FARO SCENE and CloudCompare [15] were used for processing and georeferencig the point cloud. All the markers were automatically recognized by FARO SCENE.

The SfM-MVS point cloud (Fig. 2B) was generated with Agisoft Photoscan [16] using 315 images. The complete SfM-MVS workflow, using the 'high quality' setting of Photoscan, produced a dense cloud with 93,245,315 points. Only 7 markers were identified in the image set, as their vertical positioning - specially the one at a tree trunk that was covered by its crown on the images - makes location difficult.

Visually inspecting both point clouds some contrast is clearly noticed. TLS point cloud, despite having a larger number of points, does not reflect the entire area equally. The point distribution is noticeably denser in areas near the scans positions, gradually losing density with increasing distance due the equipment technical features. Voids are common features in TLS point cloud, mainly further from the slide area where points occur sparsely distribute and no information has been captured by the sensor. Even the landslide area has some voids itself which would require some other scans from different viewpoints to fill them.

SfM-MVS point cloud has a more uniform appearance, as points are homogeneously distributed and there are no significant voids. The slope is entirely comprised within the

Galoá { Este trabalho foi publicado utilizando o Galoá proceedings

point cloud and the landslide can be clearly identified. This point cloud has approximately 35 million points less than TLS point cloud but covers a larger area.

The difference between the two clouds was computed using the "Cloud-to-Cloud distance" tool in CloudCompare [15] with a threshold of 1 m (Fig. 3). Short distances occur in almost the entire slope and larges distances are predominant in the borders. TLS do not acquired points so far from the scan positions, concentrating them within the slope, while UAV captured a wider area and SfM-MVS generated a homogeneous point cloud. The greater point clouds distances occur at the borders of the surveyed area, probably beyond TLS scan range or due the presence of ground obstacles blocking the laser beam path. However, points within the slope are very similar even though TLS point cloud being denser than SfM-MVS.

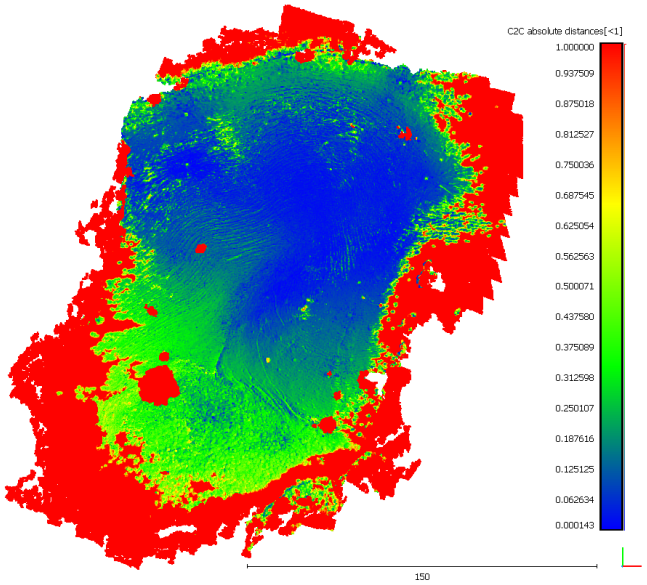

Figure 3: Cloud-to-Cloud distance with 1 m threshold using the TLS as the reference cloud.

Small differences could be related to georeferencing problems as the UAV does not image vertical targets precisely, like TLS does from the ground position. Fig. 4 shows an example of how the UAV imaged vertical markers. This marker was placed over a termite mound and was in a near vertical position, hindering the correct positioning of its center. Some markers were not visible, affecting the distribution of ground control information and thus affecting georeferencing.

Absence of vegetation also contributes to this smalls differences. UAV images are usually in visible spectral range (RGB) so it has no penetration among leaves. Densely vegetated areas blocks markers from UAV field-of-view (FOV) which increases georeferencing errors and point cloud differences.

Thus, both TLS and SfM-MVS point clouds are suitable for 3D surface modelling in this case. Point clouds differences are minimal in the target area, despite the 35 million points variation between them. Great differences occur only outside the study area and has less influence in modelling process. Absence of vegetation allows digital models generation from both point clouds without significant information loss.

Figure 4: UAV image of a printed target.

4. CONCLUSIONS

Laser scanning and UAV SfM-MVS are ultimate tools in evolving surface representation and topographic data acquisition. In the past decades this techniques were used for many applications including landslides mapping and other surface processes monitoring. Both techniques presents pros and cons, but mostly easy handling, high precision and rapid acquisition are great advantages over conventional methods. Knowledge of which technique is more suitable for a specific application is essential for any project, so comparison between TLS and SfM-MVS point clouds are relevant in the choosing process.

A hill slope with a minor landslide within (14,5 m long and 10 m wide), mainly covered by grass and with partially exposed soil was scanned by a FARO TLS and photographed by an UAV. Vegetation absence is critical for comparing both methods once UAV imaging cannot penetrate through the leaves. Final TLS point cloud contains 128,513,743 points while UAV SfM-MVS generates a point cloud with 93,245,315 points, a difference of about 35 million points. "Cloud-to-Cloud distance" tool in CloudCompare was used for comparing both point clouds; it computes the (euclidean) distance between points highlighting their positioning differences. Despite the 35 million points difference in total points, the two point clouds are very similar in the top and center slope areas but present great differences away from these areas. TLS technical limitations and laser beam path obstruction can explain the major differences in the borders of the scene, while georeferencing problems probably causes small differences within the slope. UAV images may have some problems identifying markers in vertical positions, such as in tree trunks or termite mounds, and this can lead to these minor errors in the point clouds.

For this specific terrain conditions, no vegetation cover and few view obstacles, both point clouds are suitable for DEM generation and other surface modelling to identify

Galoá { Este trabalho foi publicado utilizando o Galoá proceedings

landslides. TLS majority total points and concentration in target area should provide more detailed DEMs than UAV SfM-MVS, but for local and intermediate scales both methods can be applied with minimal information loss. Choose which method best fit a project depends mainly on personal preferences, budget, mapping scale and study area particulars. Other studies comparing TLS and UAV SfM-MVS in different environments should provide distinct results, and also comparison between ALS and UAV SfM-MVS must yield great results.

ACKNOWLEDGEMENTS

This project is supported by FAPESP (grant #2016/06628-0). C.D.V. and G.P.B.G. are PhD students at IGc-USP (RMH); E.B.S. is an undergraduate student at IGc-USP. C.H.Grohmann is a CNPq research fellow (grant #307647/2015-3). SPAMLab: <https://spamlab.github.io>.

5. REFERENCES

[1] GUERRA, A. J. T.; GONÇALVES, L. F. H.; LOPES, P. B. M. Evolução histórico-geográfica da ocupação desordenada e movimentos de massa no município de petrópolis, nas últimas décadas. *Revista Brasileira de Geomorfologia*, v. 8, n. 1, 2007.

[2] GUZZETTI, F. et al. Landslide hazard evaluation: a review of current techniques and their application in a multi-scale study, Central Italy. *Geomorphology*, Elsevier, v. 31, n. 1-4, p. 181–216, dec 1999. ISSN 0169-555X. Avaliable at: <https://www.sciencedirect.com/science/article/pii/S0169555X99000781?via{\\%}3Di>.

[3] BURNS, W. J.; MADIN, I. P. Protocol for Inventory Mapping of Landslide Deposits from Light Detection and Ranging (lidar) Imagery. p. 1–36, 2009.

[4] EECKHAUT, M. V. D. et al. The effectiveness of hillshade maps and expert knowledge in mapping old deep-seated landslides. *Geomorphology*, v. 67, n. 3-4, p. 351–363, 2005. ISSN 0169555X.

[5] BOOTH, A. M.; ROERING, J. J.; PERRON, J. T. Automated landslide mapping using spectral analysis and high-resolution topographic data: Puget Sound lowlands, Washington, and Portland Hills, Oregon. *Geomorphology*, Elsevier B.V., v. 109, n. 3-4, p. 132–147, 2009. ISSN 0169555X. Avaliable at: <http://dx.doi.org/10.1016/j.geomorph.2009.02.027>.

[6] ROWLANDS, K.; JONES, L. D.; WHITWORTH, M. Landslide laser scanning: a new look at an old problem. *Quarterly Journal of Engineering Geology and Hydrogeology*, GeoScienceWorld, v. 36, n. 2, p. 155–157, 2003.

[7] CHESLEY, J. T. et al. Using unmanned aerial vehicles and structure-from-motion photogrammetry to characterize sedimentary outcrops: An example from the Morrison Formation, Utah, USA. *Sedimentary Geology*, Elsevier B.V., v. 354, p. 1–8, 2017. ISSN 00370738. Avaliable at: <http://dx.doi.org/10.1016/j.sedgeo.2017.03.013>.

[8] CHANDLER, J. Effective application of automated digital photogrammetry for geomorphological research. *Earth Surface Processes and Landforms*, v. 24, n. 1, p. 51–63, 1999. ISSN 01979337.

[9] GLENN, N. F. et al. Analysis of LiDAR-derived topographic information for characterizing and differentiating landslide morphology and activity. *Geomorphology*, v. 73, n. 1-2, p. 131–148, 2006. ISSN 0169555X.

[10] BURNS, W. J. et al. Analysis of elevation changes detected from multi-temporal LiDAR surveys in forested landslide terrain in western Oregon. *Environmental and Engineering Geoscience*, v. 16, n. 4, p. 315–341, 2010. ISSN 10787275.

[11] EECKHAUT, M. V. D. et al. Regional mapping and characterisation of old landslides in hilly regions using LiDAR-based imagery in Southern Flanders. *Quaternary Research*, University of Washington, v. 75, n. 3, p. 721–733, 2011. ISSN 00335894. Avaliable at: <http://dx.doi.org/10.1016/j.yqres.2011.02.006>.

[12] GIORDAN, D. et al. UAV: Low-cost remote sensing for high-resolution investigation of landslides. *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, p. 5344–5347, 2015. Avaliable at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7327042>.

[13] GUPTA, S. K.; SHUKLA, D. P. Application of drone for landslide mapping, dimension estimation and its 3D reconstruction. *Journal of the Indian Society of Remote Sensing*, Springer India, v. 1, 2018. ISSN 0255-660X. Avaliable at: <http://link.springer.com/10.1007/s12524-017-0727-1>.

[14] Drones Made Easy. *Map Pilot for DJI*. 2017. Avaliable at: <http://www.dronesmadeeasy.com/Articles.asp?ID=254>.

[15] GIRARDEAU-MONTAUT, D. *CloudCompare (version 2.9.1 Omnia)*. 2018. Avaliable at: <https://www.danielgm.net/cc/>.

[16] AGISOFT. *Agisoft PhotoScan User Manual Professional Edition v. 1.4*. 2018. Avaliable at: <http://www.agisoft.com/pdf/photoscan-pro_1_4_en.pdf>.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

Anexo C.2. *Semi-automatic UAV-based SFM survey of vertical surfaces*

SEMI-AUTOMATIC UAV-BASED SFM SURVEY OF VERTICAL SURFACES

Carlos H. Grohmann[1], *Camila D. Viana*[2], *Guilherme P.B. Garcia*[3], *Rafael W. Albuquerque*[4], *Francesco Barale*[5], *Fernanda A. Ferretti*[6]

[1] Institute of Energy and Environment (IEE) - University of São Paulo (USP), São Paulo, 05508-010, Brazil, guano@usp.br; [2] Institute of Geosciences (IGc) - USP, São Paulo, 05508-080, Brazil, camila.viana@usp.br; [3]IGc-USP, guilherme.pereira.garcia@usp.br; [4]IEE-USP, rafael.albuquerque@usp.br; [5]IGc-USP, francesco.barale@usp.br; [6]IGc-USP, fernanda.ferretti@usp.br. All authors: Spatial Analysis And Modelling Lab (SPAMLab) – IEE-USP

ABSTRACT

UAV flight control applications designed for mapping, inspection and 3D model generation do not provide tools for autonomous flight and image acquisition of vertical surfaces, such as quarry walls or large cliffs, leaving the user to a manual flight operation. In this work we describe a workflow to program autonomous UAV missions designed to acquire images of vertical surfaces, with the desired parameters of distance to target and overlap, using the Litchi App. The study area is a inactive basalt quarry, where 540 images of a ∼25x200 m wall were taken in about an hour, following a layout of six flight lines, ensuring an 80% overlap between photographs.

Key words – *Structure from Motion, Photogrammetry, Litchi, Structural Geology, Quarry.*

1. INTRODUCTION

UAVs can be programed to fly autonomous missions for orthophoto and DEM generation with Structure from Motion–Multi View Stereo (SfM-MVS) [1], where the aircraft usually follows a square grid path while acquiring images at predefined distance or time intervals. The user can chose from a wide number of applications for flight control, including free or commercial, installed on a computer (desktop/laptop) or mobile device (phone/tablet), and with different sets of features, such as allowing the UAV to fly at a constant height over the terrain instead of the same height from the take off point regardless of variations in topography.

Despite the options offered by flight control applications, which include grid flight, double (crossed) grid, flight parallel to linear features (roads, power lines) or orbiting flight around vertical structures (towers), there is no option for autonomous flight and image acquisition of vertical surfaces, such as quarry walls, outcrops or large cliffs. If the subject of analysis is a vertical surface, the user is left with option of terrestrial photogrammetry [2, 3] or manual UAV flight [4], which will depend on a skilled pilot, will increase operation time and might not assure that the images will be taken from a constant distance from the target or that image overlap and orientation [5] will meet the requirements for a successful 3D reconstruction.

In this work we describe a workflow to program autonomous UAV missions designed to acquire images of vertical surfaces with the desired parameters of distance to target and overlap, using the Litchi App.

The intention is to simulate the grid pattern used for terrain mapping, but placing the grid in a vertical plane. This can be achieved by creating an individual mission running parallel to the vertical surface, with waypoints spaced according to the desired lateral image overlap. This mission is then repeated at different heights, proportional to the vertical overlap.

2. MATERIAL AND METHODS

2.1. Study Area

Situated at the outskirts of Campinas City (São Paulo State, southeastern Brazil), the Jardim Garcia quarry is composed of mafic intrusive rocks from Serra Geral Formation (Cretaceous, Paraná Basin). It is deactivated and used as a recreational area for activities such as rock climbing and aeromodeling.

This work focused on the west side of the quarry, a ∼25 m high and ∼200 m long SSE-NNW rock wall (Fig. 1). For georeferencing the final 3D model, climbing anchors were surveyed by irradiation from a total station located in an open traverse. The traverse coordinates were obtained by geodetic GNSS post-processing.

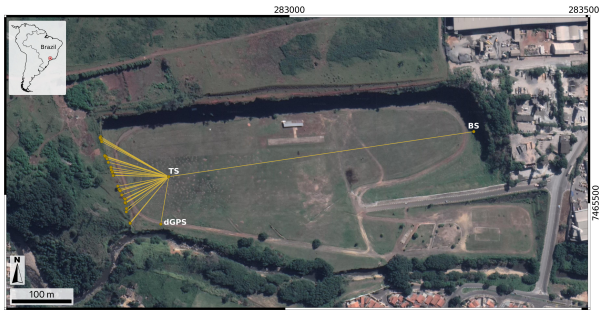

Figure 1: Situation map of Jardim Garcia Quarry with surveyed traverse and control points. TS: Total Station; BS: Backsight; dGPS: GPS base station. Satellite imagery ©2018 Digital Globe, powered by Google. UTM coordinates, zone 23 (South), WGS84.

2.2. Autonomous flight programming

The Litchi App (<https://flylitchi.com>) was used to program the autonomous flight of the UAV. Litchi is an Android/iOS application for UAV control aimed towards photography and video capture. Among its many features, it allows the user to fly on a path defined by waypoints, and to execute up to 15 different 'actions' at each waypoint, such as take a photograph, rotate the aircraft, tilt the camera gimbal and others. Although other applications have similar features, Litchi has a 'Mission Hub' (<https://flylitchi.com/

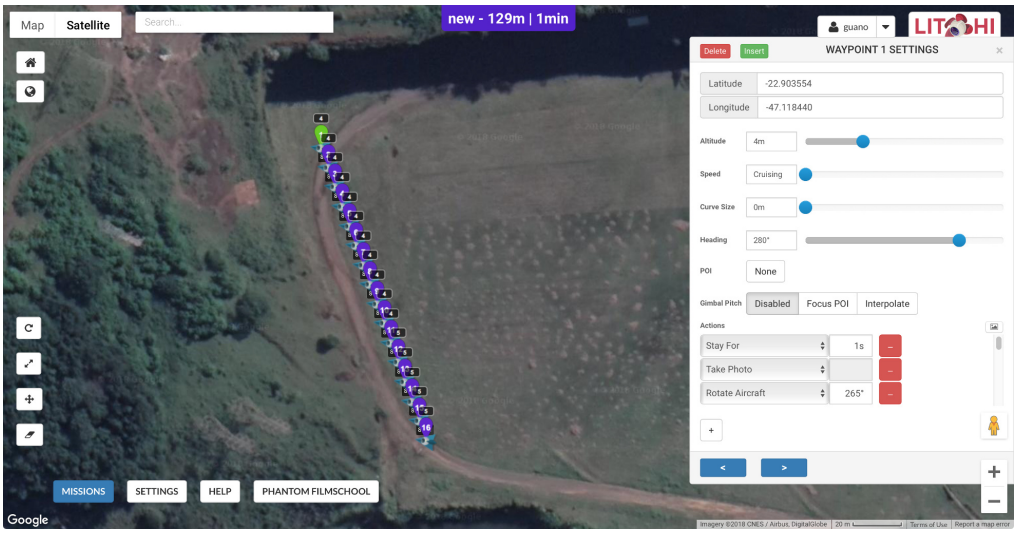

Figure 2: Litchi Mission Hub with imported flight path. The menu is used to define flight parameters and waypoint actions.

hub>) where missions can be created using a desktop or laptop computer, enabling the possibility of using multiple tools (e.g., GIS, GoogleEarth) to plan missions in a quick and easy way.

A DJI Phantom 4 Pro UAV was used for image acquisition. The aircraft digital camera has an 1" CMOS 20MP sensor, with FOV of 84° and 8.8 mm focal distance (24 mm at 35 mm equivalent). Images can be saved as JPEG or RAW, with 5472×3648 px (3:2 ratio). In this project we set the distance to the wall as 20 m and image overlap at 80% vertical and lateral. This resulted in an image footprint of 30×20 m, a pixel size of ∼0.5 cm, and distance between photos of 6 m horizontally and 4 m vertically. To avoid doming effects observed in datasets acquired with cameras positioned only at a perpendicular orientation about the target [5], we planned to acquire images at three orientations: N265° (perpendicular), N250° and N280°. Additionally, after these images were obtained, the camera gimbal was tilted -15° (downwards from the horizontal position) and the images reacquired, in a total of 6 images per waypoint.

The workflow described here requires the use Litchi Mission Hub (via browser), Google Earth (or GIS), an ASCII text editor and Litchi for mobile devices (for actual flight). In brief, the steps are:

1. Create first flight line in Google Earth and save as KML;
2. Import KML into Mission HUb and edit actions for first waypoint;
3. Export mission as CSV and open in text editor;
4. In text editor, adjust flight height and duplicate actions for all waypoints;
5. Save one mission for each required flight height as CSV;
6. Import CSV into Mission Hub and save into user account;
7. Fly each mission via Litchi mobile App.

The first step is to create the flight path in Google Earth or in a GIS software. Create a polyline parallel to the surface of interest, with nodes spaced according to the necessary lateral overlap (each node will be a waypoint in Mission Hub) and export it as a KML file.

Next, import the KML file into Mission Hub and edit manually the parameters only for the first waypoint (Fig. 2). Define flight height above the take-off point, set 'curve size' to zero and 'heading' to the azimuth of the first photo. Edit the actions of the UAV for this waypoint. In this project, we defined the following actions:

1. Hover for 1s (to stabilize the UAV);
2. Take photo (aircraft is oriented at initial 'heading' setting of N280°);
3. Rotate aircraft to N265°;
4. Take photo;
5. Rotate aircraft to N250°;
6. Take photo;
7. Tilt camera gimbal -15°;
8. Take photo;
9. Rotate aircraft to N265°;
10. Take photo;
11. Rotate aircraft to N280°;
12. Take photo;
13. Hover for 1s;
14. Tilt camera gimbal back to 0°.

Once the parameters and actions for the first waypoint are set, export the mission as a CSV file and open it in an ASCII text editor. The file has a long header with self-explanatory labels, followed by the waypoints and their actions.

```
latitude,longitude,altitude(m),heading(deg),curvesize(m),rotationdir,gimbalmode,gimbalpitchangle,
actiontype1,actionparam1,actiontype2,actionparam2,actiontype3,actionparam3,actiontype4,actionparam4,actiontype5,actionparam5,
actiontype6,actionparam6,actiontype7,actionparam7,actiontype8,actionparam8,actiontype9,actionparam9,actiontype10,actionparam10,
actiontype11,actionparam11,actiontype12,actionparam12,actiontype13,actionparam13,actiontype14,actionparam14,actiontype15,actionparam15,
altitudemode,speed(m/s),poi_latitude,poi_longitude,poi_altitude(m),poi_altitudemode
-22.9035544946994,-47.1184402458146,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9036275426808,-47.1184118144023,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9037005906621,-47.1183833829901,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9037736386434,-47.1183549515778,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9038466866247,-47.1183265201655,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9039197346061,-47.1182980887533,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9039927825874,-47.1182696573410,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9040658305687,-47.1182412259287,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9041388785500,-47.1182127945164,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9042119265314,-47.1181843631042,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9042849745127,-47.1181559316919,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9043580224940,-47.1181275002796,5,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9044310704753,-47.1180990688674,5,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9045041184566,-47.1180706374551,5,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9045771664380,-47.1180422060428,5,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9046502144193,-47.1180137746306,5,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
```

Figure 3: Contents of CSV file defining a Litchi 'waypoint' mission.

In the example CSV file shown in Fig. 3, the values of the `curvesize(m)` field were edited and rounded to zero, or else Litchi will not perform the defined actions at each waypoint but instead will fly through them as if in a video mission. Each action has a numerical code and an associated parameter, such as:

- `actiontype1`: `0` (stay hovering)
- `actionparam1`: `1000` (miliseconds)
- `actiontype2`: `1` (take photo)
- `actionparam2`: `0` (no associated parameter)
- `actiontype3`: `4` (rotate aircraft)
- `actionparam3`: `265` (azimuth)
- `actiontype7`: `5` (rotate gimbal)
- `actionparam7`: `-15` (angle)

From here it is easy to copy/paste the actions of the first waypoint to all the others. Adjust the flight height as needed. In this case, the ground was gently sloping so the last point was about one meter below the first one; the height of the waypoints were adjusted so the last points are one meter above the take-off point (Fig. 3).

Save one CSV file for each flight height, according to the vertical overlap defined beforehand. Import all files into Mission Hub and check for any errors. Once the missions are imported into the user's account, they can be opened in the mobile App for flight control. It is always safer to check all missions at the office, while connected to the Internet, which will also allow Litchi to download and cache the base map images, for better visualization during field work.

3. RESULTS AND DISCUSSION

In our fieldwork each flight line (with 16 waypoints) was flown in about 8 minutes. Total operation time, including returning the UAV to the initial position, uploading the new mission and replacing the battery (each battery was used in two missions) was around 1:15".

The 3D model of the quarry wall (Fig. 5) was generated with Agisoft Photoscan [6] using 534 images. Photos containing features such as sky and vegetation were masked to reduce processing time. The SfM step of the reconstruction identified 129,806 tie points between the images; using the 'high quality' setting of Photoscan, the MVS step produced a dense cloud with 39,599,660 points which was interpolated to a 3D mesh with 7,919,932 faces.

The layout of the flight lines and waypoints resulted in an image overlap greater than nine photos for almost all the wall area (Fig. 4). Small deviations from a perfect grid are expected due the precision of the onboard GPS used for navigation.

4. CONCLUSIONS

This work presented a workflow, based on the Litchi App, to program autonomous flight missions designed for acquiring images of a vertical surface in a layout similar to the grid pattern commonly used for terrain mapping.

The intent is to avoid manual UAV flight, decreasing operation time, and assuring not only the safety of users and assets, but also that images will be taken from a constant distance from the target and that overlap and camera orientation will meet the requirements for the 3D reconstruction.

The workflow is flexible and can be adapted to a variety of target configurations and user-defined parameters. Flight missions can be saved and shared, ensuring not only repeatability, but also reproducibility of data collection.

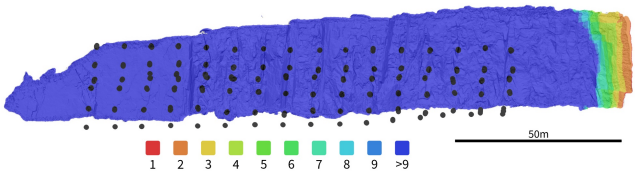

Figure 4: Image overlap map of the quarry wall, with camera positions (black dots). Note the regular layout of flight lines.

Figure 5: 3D model of the quarry wall. Perspective view.

ACKNOWLEDGMENTS

This project is supported by FAPESP (grant #2016/06628-0). C.D.V. and G.P.B.G. are PhD students at IGc-USP (RMH); R.W.A. is a PhD student at IEE-USP (PROCAM); F.B. and F.A.F. are undergraduate students at IGc-USP. C.H.Grohmann is a CNPq research fellow (grant #307647/2015-3). This study was financed in part by CAPES Brasil - Finance Code 001. SPAMLab: <https://spamlab.github.io>.

5. REFERENCES

[1] WESTOBY, M. J. et al. 'Structure-from-Motion' photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, v. 179, p. 300–314, 2012. ISSN 0169-555X. Avaliable at: <http://www.sciencedirect.com/science/article/pii/S0169555X12004217>.

[2] HANEBERG, W. C. Using close range terrestrial digital photogrammetry for 3-D rock slope modeling and discontinuity mapping in the United States. *Bulletin of Engineering Geology and the Environment*, v. 67, n. 4, p. 457–469, maio 2008. ISSN 1435-9529. Avaliable at: <http://link.springer.com/10.1007/s10064-008-0157-y>.

[3] STURZENEGGER, M.; STEAD, D. Close-range terrestrial digital photogrammetry and terrestrial laser scanning for discontinuity characterization on rock cuts. *Engineering Geology*, Elsevier B.V., v. 106, n. 3-4, p. 163–182, jun. 2009. ISSN 00137952. Avaliable at: <http://linkinghub.elsevier.com/retrieve/pii/S0013795209000556>.

[4] CAWOOD, A. J. et al. LiDAR, UAV or compass-clinometer? Accuracy, coverage and the effects on structural models. *Journal of Structural Geology*, p. –, 2017. ISSN 0191-8141. Avaliable at: <http://www.sciencedirect.com/science/article/pii/S0191814117300822>.

[5] JAMES, M. R.; ROBSON, S. Mitigating systematic error in topographic models derived from UAV and ground-based image networks. *Earth Surface Processes and Landforms*, v. 39, n. 10, p. 1413–1420, 2014. ISSN 1096-9837. ESP-14-0032.R2. Avaliable at: <http://dx.doi.org/10.1002/esp.3609>.

[6] AGISOFT. *Agisoft PhotoScan User Manual Professional Edition v. 1.4*. 2018. Avaliable at: <http://www.agisoft.com/pdf/photoscan-pro_1_4_en.pdf>.

Anexo D. Coautoria em artigo completo apresentado ao *14th International Congress on Rock Mechanics and Rock Engineering - ISRM 2019*

Artigo apresentado ao *14th International Congress on Rock Mechanics and Rock Engineering - ISRM 2019*, realizado de 13 a 18 de Setembro de 2019, na cidade de Foz do Iguaçu - PR.

Anexo D.1. *Slope stability assessment based on a Digital Outcrop Model: a case-study at Jardim Garcia quarry*

Rock Mechanics for Natural Resources and Infrastructure Development –
Fontoura, Rocca & Pavón Mendoza (Eds)
© 2020 ISRM, ISBN 978-0-367-42284-4

Slope stability assessment based on a digital outcrop model: A case-study at Jardim Garcia quarry

C.D. Viana & G.P.B. Garcia
Institute of Geosciences, University of São Paulo, São Paulo, Brazil

C.H. Grohmann & R.W. Albuquerque
Institute of Energy and Environment, University of São Paulo, São Paulo, Brazil

J.P. Monticelli, P.P. Cacciari & M.M. Futai
Polytechnic School, University of São Paulo, São Paulo, Brazil

ABSTRACT: In this work a 3D digital model generated with SfM-MVS is used to investigate rock slope stability. The test site is a deactivated quarry used as recreational area for climbers. The model was divided in three sectors. Sector 1 has the least steep slope and structures are parallel to slope face. Sectors 2 and 3 have steeper slope angles and are prone to wedges. The work has demonstrated that the application of a 3D model generated with SfM-MVS workflow for rock slope stability analysis is feasible and can find future application in climbing sites.

1 INTRODUCTION

The climbing sport will be joining in the Olympics of 2020 (Tokyo-Japan). The announcement has promoted climbing organizations to a new level in Brazil (*O Globo, 21/01/2018*). It is expected that global visualization will influence the increasing of climb practitioners around the world, which usually after training in an indoor wall, the climber looks for an outdoor wall, i.e. natural rock masses or "artificial" rock masses, quarries.

Natural rock masses present different geological risks and interesting grades to the climbing practice, despite the necessity of travelling and find accommodation, which increases the cost and is time-consuming (Panizza and Mennella, 2007; Motta et al. 2009). The quarries have a considerable potential for climbing sport and outdoor activities because of their location near to urban centers, easy access by roads and parking spots. However, the "artificial" rock masses, beyond the geological-geotechnical properties, have fissured and damage zones produced by drilling and blasting operations, which deserve even more attention in the rehabilitation for use with another purpose.

The decommissioning process must assure the site would return under suitable conditions for the socio-environmental security of the local community (Abrão & Oliveira, 2018), as for example, the famous Opera de Arame in Curitiba city (PR), Brazil, which was used to creation of an amphitheater that became a touristic site. On the other hand, quarries reused for sports, such as climbing, are undervalued and underutilized by the society, and those who use them often neglect their geological-geotechnical conditions. For example, the process of cleaning up the climbing routes, removing small and apparently loose blocks (key-blocks) can destabilize a whole rock mass increasing the risk.

The Jardim Garcia quarry is composed of mafic intrusive rocks from the Serra Geral Formation, Paraná Basin. Together with the Dib and São Roque comprise some of the deactivated quarries used to climbing close to Campinas and São Paulo metropolitan regions, Brazil, (Figure 1a). Among the quarries, the west wall of Jardim Garcia area was chosen due to recent removal of

blocks by climbers and to be a potential zone of falling of blocks (Figure 1b-c). It is a 23 m high and 195 m long SSE-NNW rock wall with 38 mapped climbing routes (or craigs).

In this sense, a detailed geological-geotechnical assessment of the old mining fronts is needed to make sporting and commercial activities safer. Besides, the interaction between rock mechanics and rock climbing can bring important engineering concepts as observed in Barton et al. (2018) and from this perspective, the rehabilitation of quarries near to urban centers for outdoor sports naturally become a future alternative to its reuse, increasing the need of adequate geological-geotechnical investigations.

The stability analysis is highly dependent on field survey and discontinuities play a fundamental role. Traditional field surveys are time-consuming and even risky or impossible. In this regard, the use of remotely sensed 3D digital models allows a greater amount of data to be collected in a short period of time. Among the most employed techniques is photogrammetry, which has experienced a large increase in applications with the introduction of Structure from Motion – Multi-View Stereo (SfM-MVS) algorithms, which allow for greater flexibility and is easily reproducible by non-experts.

The main objective of this work was to integrate traditional field survey, rock mass characterization and classification, and photogrammetry using SfM- MVS to evaluate slope stability of a climb wall. This integration aims to digitally obtain, from a 3D model, discontinuity parameters such as orientation, persistence, fracturing, weathering and roughness (waviness). The 3D digital model serves not only for this evaluation but can also be used for future modeling and decision-making regarding changes in the climbing routes or even providing information to the safety of the climbers.

1.1 *Structure from Motion - Multi-View Stereo*

Structure from Motion is a digital remote topography survey technique that has emerged from the combination of photogrammetry and computer vision (Carrivick et al. 2016), in which the digital model is constructed from a redundant number of images. Because of its flexibility and ease of use, SfM-MVS has been used to create three-dimensional models in geosciences in recent years, leading to the emergence of terms such as Digital Outcrop Model (DOM – Pringle et al. 1999) and Virtual Outcrop (Pringle et al. 2001).

The first step to generate a DOM is to acquire data, which is a collection of digital images of the object or scene. Besides good quality images, including good lighting conditions and avoidance of casting shadows, it is important to ensure a large overlap between images for a feature to be reconstructed. Depending on their quality, images can be sorted or processed for color correction and/or clipping before the model construction.

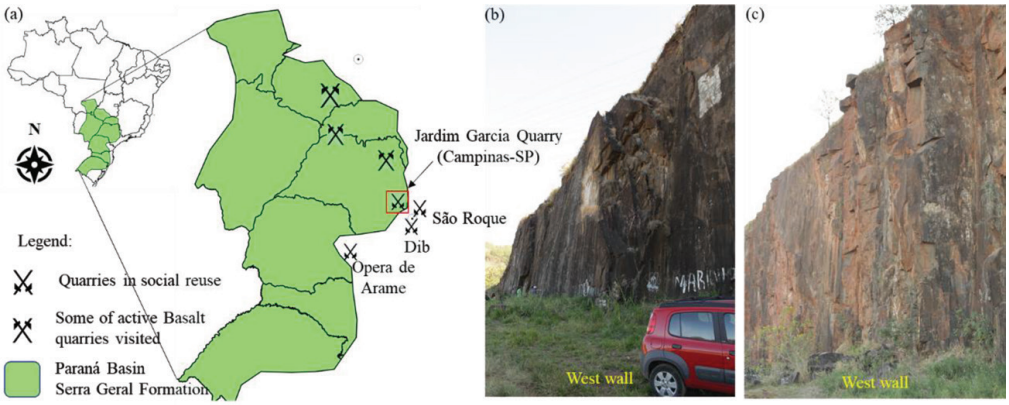

Figure 1. Location site of Jardim Garcia quarry (a) and recent (b) and old (c) traces of block falling in the west wall.

Ground control points (GCP) for georeferencing and other field data are acquired depending on the application. Georeferencing, or just scaling and orientation, can be made by several ways, including the survey of GCP with GPS or with the placement of an oriented scale bar on the scene (Sturzenegger & Stead 2009).

For model generation, the first step is performed by Structure from Motion algorithm, which identifies common points between the images and calculates their position in space, generating a sparse point cloud. For some applications, the resulting cloud of this first step is suitable, but in order to obtain more detailing, the Multi-View Stereo (MVS) algorithm is applied, resulting in a dense point cloud. Finally, this cloud can be transformed into a mesh and a texture can be added to assign real color to the surface, creating the DOM.

There are many software options that can be used to create DOM, both commercial (Agisoft 2018, Pix4D SA 2017) and open source (Rupnik et al. 2017, OpenDroneMap 2014).

2 METHODS

2.1 *Image planning and acquisition*

The slope geometry imposed some difficulties. For the generation using Agisoft Photoscan Professional (Agisoft 2018), image survey was made with a DJI Phantom 4 Pro drone. In order to obtain greater control of scale and image overlap, the flights were planned with the Litchi application (<https://flylitchi.com>). The app was chosen because it allows flight lines to be stacked vertically, different from what is usually done in aerial surveys where the lines are horizontal. The mission was flown 20 m away from the wall, with 6 flight lines spaced 4 m vertically. For each line, 6 images (at 285, 265 and 250 Az with camera horizontal and inclined -15 degrees) were acquired every 8 m, totaling 540 images, of which 534 were selected for 3D model construction (Figure 2). The images1). Images containing features such as sky and vegetation were masked to reduce processing time. For ground control, climbing anchors were surveyed by irradiation from a total station located in a georreferenced polygonal. The polygonal's georreferenced coordinates were obtained by geodetic GNSS post-processing (Figure 3).

2.2 *3D model analysis*

The resulting model was divided into 3 sectors considering field observations and major structures detected on the DOM (Figure 4). For each sector, visible joints were selected using MeshLab and had their attitude and persistence calculated according to the methods of Viana et al. (2016). Results were plotted on stereonets for kinematic analysis. In addition, the recent proposal for rock mass slope classification, Q - Slope (Bar & Barton 2017), was used to classify each sector and integrate the geomechanical classes and failure predictions to the failures modes.

3 RESULTS AND DISCUSSION

The resulting model is a dense cloud with 39.599.660 points and the final mesh comprises 3.996.392 vertices and 7.919.932 faces. DOM analysis showed that slope dip gradually increases towards north from 79 degrees on sector 1 to 83 degrees on sector 3. This is reflected on the increasing difficulty level of climbing routes from south to north as reported by the climbers.

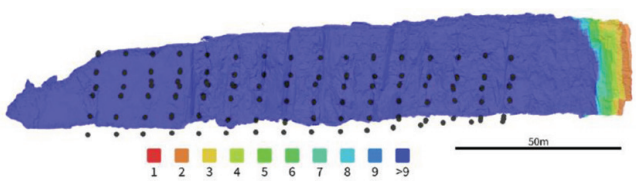

Figure 2. Camera positions (black dots) along lines of flight. Colors represent number of image overlap.

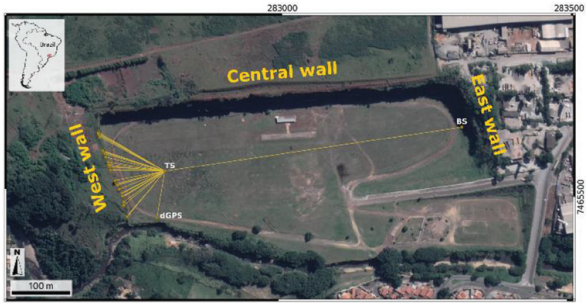

Figure 3. Situation map of Jardim Garcia Quarry with surveyed traverse and control points (b). TS: Total Station; BS: Backsight; dGPS: GPS base station. Satellite imagery 2018 Digital Globe, powered by Google. UTM coordinates, zone 23 (South), WGS84.

Figure 4. 3D model of the quarry wall with defined sectors (1 - blue, 2 - red and 3 - yellow). Orange lines indicate the sector limits.

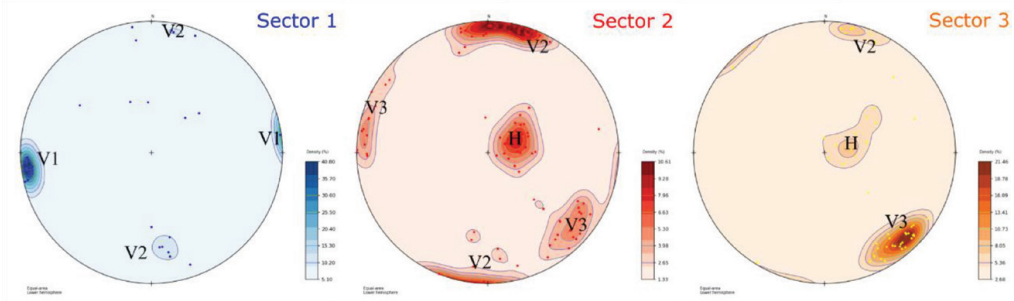

Figure 5. Stereonets of the three sectors (1, 2 and 3) showing the discontinuity mapping: sub-parallel (V) and sub-horizontal sets (H). Equal area, lower hemisphere.

The structures orientations were organized in stereonets and four discontinuity sets were characterized, being three sets sub-vertical and one sub-horizontal (Figure 5). Slope stability analysis demonstrated that wedge failure might occur in sectors one and two, while block toppling failure are prone to happen in all sectors (Figure 6). The sub parallel fractures (V1 and V3) to the slope orientation influence directly the toppling kind of failure in sectors 1, 2 and 3.

The Q_{slope} parameters characterization and the sectors classification of the Jardim Garcia were organized in Table 1. Unfavorable and favorable scenarios were compared based on the variation of the investigated parameters. The block size ratio can be visualized in each sector, bringing important considerations to the rock mass classification. Sector 1 has greater sized blocks in restricted areas of occurrence, comparatively to sector 2 and 3 where smaller blocks were observed along the whole wall. The dominant and less dominant discontinuity sets of each sector were also characterized based on kinematic analysis and field inspections, and the orientation factor were adjusted for them. The geological conditions of the west wall show a competent and relative stable rock mass, and the site environmental condition is markedly by wet and tropical storms. The disturbance by blasting is locally found as well as the loose blocks and the susceptibility to weathering, are inherent of this kind of rock as external factors.

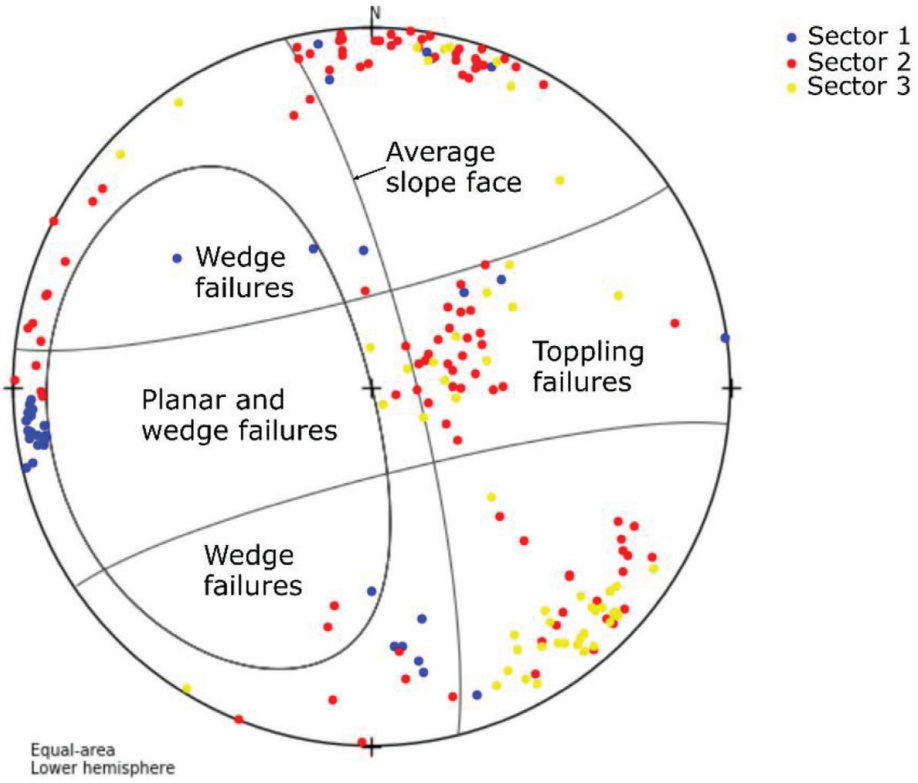

Figure 6. Kinematic analysis of sectors.

The geomechanical classification, the slope angles (β) of each sector and the failure mechanisms identified by field surveys and kinematic analysis were organized in Table 2. In addition, the steepest slope angle suggestion for reinforcement-free site access were calculated with the Q_{slope} values and the slope angles (β) were plotted in the probability chart based on unwanted events (Bar & Barton 2017) (Figure 7).

The sectors present geomechanical classes varying from 1 to 5 for unfavorable conditions and from 10 to 40 for favorable conditions (Table 2). Comparing the classes with slope angles, it can be observed that in the favorable scenario the sectors are stable but bordering semi-stable limits. On

Table 1. Q_{slope} parameters characterization.

Gárcia Querry - West wall			Sectors	1		2		3	
			Scenarios	Unf.	Fav.	Unf.	Fav.	Unf.	Fav.
	Block size		RQD (%)	75	85	55	65	65	75
			Jn	6	6	12	12	9	9
Parameters	**Shear strength (joint set)**	**Dominant**	Jr	3 (V1)	3 (V1)	1,5 (V2)	3 (V2)	1,5 (V2)	3 (V2)
			Ja	1 (V1)	0,75 (V1)	1 (V2)	1 (V2)	1 (V2)	1 (V2)
			O-F	0,75 (V1)	0,75 (V1)	0,9 (V2)	0,9 (V2)	0,9 (V2)	0,9 (V2)
		Secondary	Jr	1,5 (V2)	3 (V2)	1,5 (H)	3 (H)	1,5 (H)	3 (H)
			Ja	1 (V2)	1 (V2)	1 (H)	1 (H)	1 (H)	1 (H)
			O-F	0,9 (V2)	0,9 (V2)	1 (H)	1 (H)	1 (H)	1 (H)
	External factors		Jwic	0,5	0,7	0,5	0,7	0,5	0,7
			SRF	5	2,5	5	2,5	5	2,5

Table 2 Slope stability prediction.

Sectors	1		2		3	
Scenario	Unf.	Fav.	Unf.	Fav.	Unf.	Fav.
Q-slope	4	32	1	12	1,5	19
Slope angle, β (°)	79		80		83	
Probability of slope failure	Quasi-stable	Stable	Unstable	Stable	Unstable	Stable
Modes of failure	Wedge/Toppling failures		Wedge/Toppling failures		Toppling	
Steepest slope angle suggestion (°)	77	-5	65	86	68	90

the other hand, in the unfavorable scenario sectors 2 and 3 are unstable and boundary the failed slopes, while sector 1 is in a semi-stable condition (Figure 7).

According to Bar & Barton (2017), the steepest slope for these sectors could have values ranging from 65 to 75° for unfavorable conditions and from 85 ° to -5 ° for favorable. All the sectors present wedges and blocks ready to fall or vestiges of falls/removal by climbers (Figures 2b-c and 8), which can be interpreted that the parameters bordering the unfavorable conditions raised along the rock mass are better suited to express their geomechanical behavior.

Correcting the angle of the slope is certainly not an option, since it would disfigure the use for climbing, rappel among other outdoor sports. Jardim Garcia quarry were gradually reintegrated into society by groups of climbers and other sports activities, which carried out the cleaning, maintenance and viability of access. However, the rock mass stability is maintained by the climbers who identify the loose rock blocks, remove or cement them with resin or grouts. This process without a geological-geotechnical approach can increase the risk by removing key-blocks or even not stop-

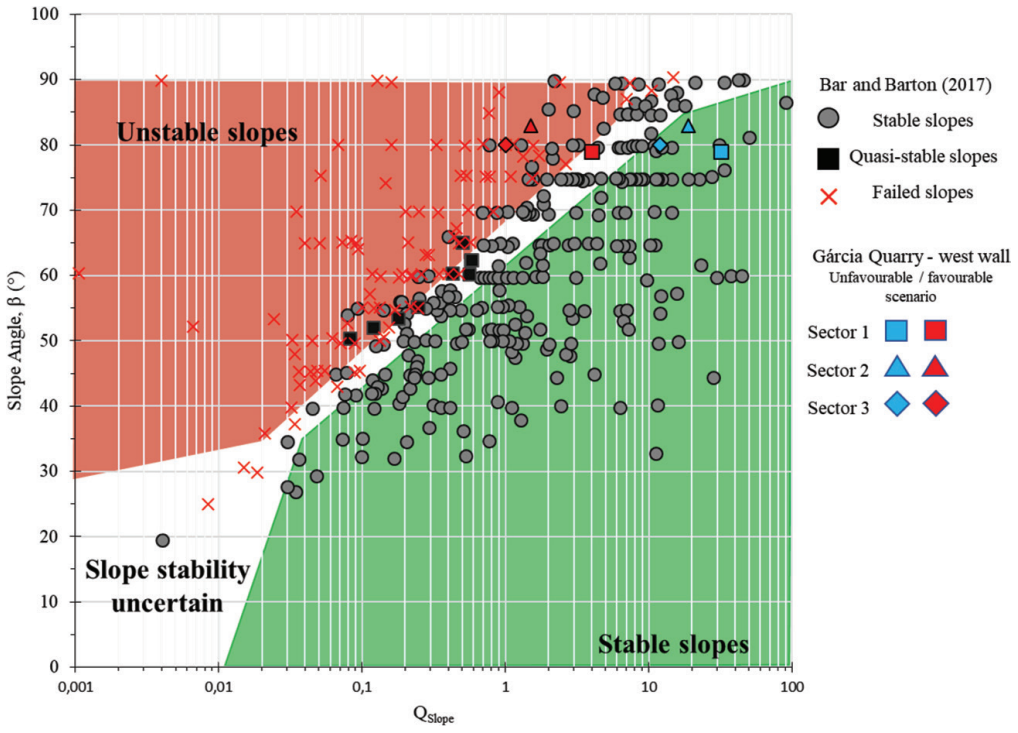

Figure 7. Q_{slope} probability of failure based on unwanted events (failed or quasi-stable slopes) and the Jardim Garcia sectors classifications.

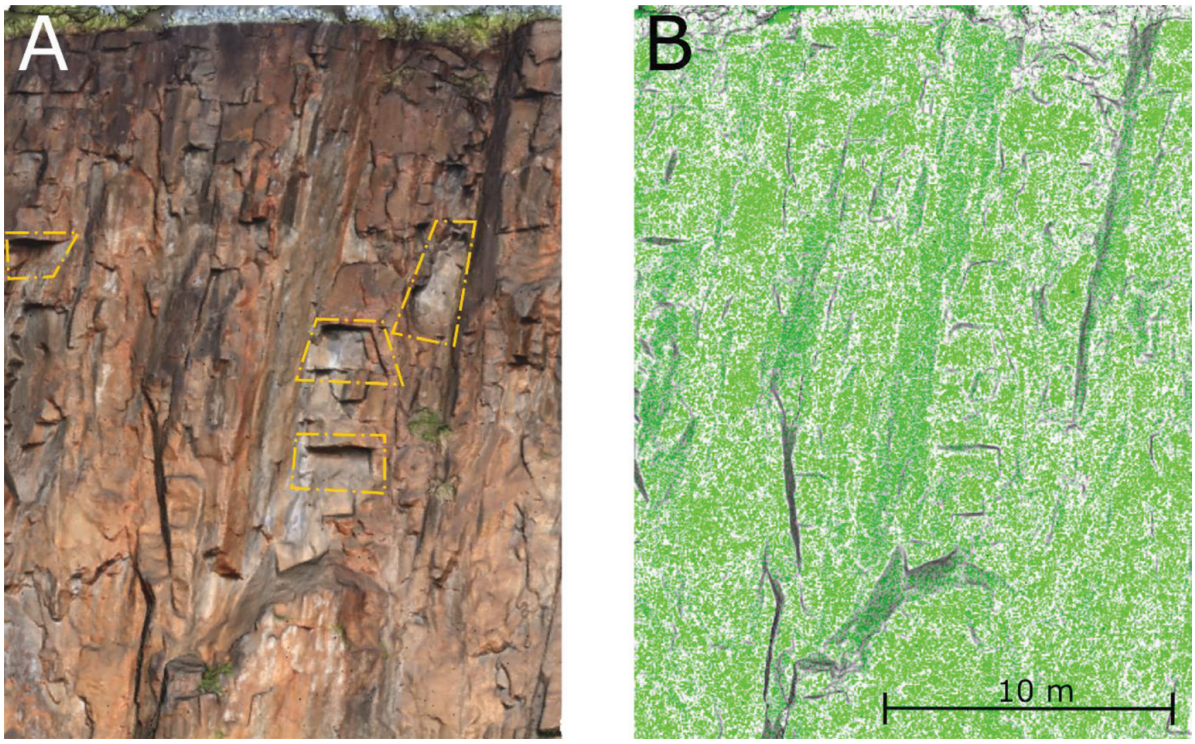

Figure 8. Detail of 3D model of Sector 2: textured mesh (A) and shaded point cloud (B). The removed or the fallen rock blocks are shown with the yellow dashed boxes.

ping as was investigated with kinematic analysis. Besides, the resin can lose their properties with the exposition to weathering and the climbing activities. The use of anchors would be the most appropriate in this case, maintaining the integrity of the craigs and at the same time promoting the safety of the users. Such a measure could be transferred to the mining companies at the time of decommissioning with the intention of promoting the recreational use of the quarry.

4 CONCLUSIONS

The application of DOM on rock slope stability analysis is of great value as it allows a more dynamic visualization of structures and the collection of a large number of structural data.

The kinematic analyses integrated with the Q_{slope} classification raised some geological-geotechnical information, that undoubted will guide the actions to be taken to promote the safety of climbing routes. The model applied in this work is flexible and low cost, being easily reproducible and allowing the decommissioning of quarries to be done in a way that promotes their reintegration into society in the form of a space for safe sports and leisure practice. It is clear that the use of 3D models should be associated to field inspection, which allows the professional to have complementary information for the analysis, but its application provides an additional tool in the geological-geotechnical evaluation.

ACKNOWLEDGEMENTS

This research was supported by FAPESP (grant #2016/06628-0) and CNPq (grant #423481/2018-5). C.H.G. is a CNPq research fellow (grants #307647/2015-3 and # 304413/2018-6).

REFERENCES

Abrão, P.C. & Oliveira, S.L. 2018. Mineração. In A.M.S. Oliveira & J.J. Monticeli (eds.), *Geologia de Engenharia e Ambiental Volume 3: aplicações*: 71-86. São Paulo.

Agisoft 2018. Agisoft PhotoScan User Manual Professional Edition v. 1.4

Bar, N. & Barton, N.R. 2017. The Q-Slope Method for Rock Slope Engineering. *Rock Mech Rock Eng* 50(12): 3307–3322.

Barton, N.R., Shen, B., Bar, N. 2018. Limited heights of vertical cliffs and mountain walls linked to fracturing in deep tunnels - Q-slope application if jointed slopes. In *Proc. VII Brazilian Symposium on Rock Mechanics – SBMR 2018*, *Salvador*, *28 August to 1 September 2018*.

Carrivick J.F., Smith M. W., Quincey D.J. 2016. *Structure from Motion in the Geosciences*. John Wiley & Sons.

Motta, M., Panizza, V., Pecci, M. 2009. Geomorphological hazard assessment on natural rock wall for free climbing practice. *Memorie Descrittive Della Carta Geologica d'Italia* 87: 109–122.

OpenDroneMap 2014. OpenDroneMap. Retrieved from https://github.com/OpenDroneMap/OpenDrone-Map.

Panizza, V. & Mennella, M. 2007. Assessing geomorphosites used for rock climbing: the example of Monteleone Rocca Doria (Sardinia, Italy). *Geographica Helvetica* 62: 181–191.

Pix4D SA, 2017 Pix4Dmapper 3.2 user manual.

Pringle, J.K., Clark, J.D., Westerman, A.R., Morgan, B.E.F., Gardiner, A.R., Crawford, D.C., Green, S. 1999. A novel technique integrating digital photogrammetry with geological and geophysical data to acquire 3D architectures at Alport Castles, Derbyshire, UK. In *BSRG Annual Conference*.

Pringle, J.K., Clark, J.D., Westerman, A.R., Stanbrook, D.A., Gardiner, A.R., Morgan, B.E.F. 2001. Virtual outcrops: 3-D reservoir analogues. *Journal of the Virtual Explorer* 4: 1-8

Rupnik, E., Daakir, M., Pierrot Deseilligny, M. 2017. MicMac: a free, open-source solution for photogrammetry. *Open Geospatial Data, Software and Standards* 2: 9.

Sturzenegger, M. & Stead, D. 2009. Close-range terrestrial digital photogrammetry and terrestrial laser scanning for discontinuity characterization on rock cuts. *Engineering Geology* 106(3–4): 163–182.

Viana, C.D., Endlein, A., Campanha, G.A.C., Grohmann, C.H. 2016. Algorithms for extraction of structural attitudes from 3D outcrop models. *Computers and Geosciences* 90: 112–122.

Anexo E. Coautoria em artigo completo apresentado ao 35º Congresso Brasileiro de Espeleologia - SBE 2019

Artigo apresentado ao *35th Congresso Brasileiro de Espeleologia - SBE 2019*, realizado de 19 a 22 de Julho de 2019, na cidade de Bonito - MS.

Anexo E.1. Mapeamento e modelagem 3D do setor turístico da Caverna do Diabo (SP) com *laser scanner*: resultados preliminares

35º Bonito - MS | ANAIS do 35° Congresso Brasileiro de Espeleologia
19 - 22 de julho de 2019 - ISSN 2178-2113 (online)

O artigo a seguir é parte integrando dos Anais do 35º Congresso Brasileiro de Espeleologia disponível gratuitamente em www.cavernas.org.br.

Sugerimos a seguinte citação para este artigo:

GROHMANN, C.H. et al. Mapeamento e modelagem 3D do setor turístico da Caverna do Diabo (SP) com laser scanner: resultados preliminares. In: ZAMPAULO, R. A. (org.) CONGRESSO BRASILEIRO DE ESPELEOLOGIA, 35, 2019. Bonito. *Anais*... Campinas: SBE, 2019. p.201-206. Disponível em: <http://www.cavernas.org.br/anais35cbe/35cbe_201-206.pdf>. Acesso em: *data do acesso*.

Esta é uma publicação da Sociedade Brasileira de Espeleologia.
Consulte outras obras disponíveis em www.cavernas.org.br

MAPEAMENTO E MODELAGEM 3D DO SETOR TURÍSTICO DA CAVERNA DO DIABO (SP) COM LASER SCANNER: RESULTADOS PRELIMINARES

3D MAPPING AND MODELLING OF THE TOURISTIC SECTOR OF DEVIL'S CAVE (CAVERNA DO DIABO, SP): PRELIMINARY RESULTS

Carlos H. GROHMANN (1); Gabriel ZACHARIAS (2); Guilherme P.B. GARCIA (2); Francesco BARALE (2); Flavio Vaz de ALMEIDA (3); Ives Simões ARNONE (4)

(1) Instituto de Energia e Ambiente, USP.
(2) Instituto de Geociências, USP.
(3) Escola Politécnica, USP.
(4) Parque Estadual Caverna do Diabo, Fundação para a Conservação e a Produção Florestal do Estado de São Paulo.

Contatos: guano@usp.br; gabriel.sugiura@usp.br; guilherme.pereira.garcia@usp.br; francesco.barale@usp.br; flaviovaz@usp.br; bioives@gmail.com.

Resumo

Neste trabalho apresenta-se um primeiro mapeamento 3D com Laser Scanner (*Terrestrial Laser Scanner* - TLS) do setor turístico da Caverna do Diabo. Foram realizadas 36 varreduras do TLS, unidas em uma nuvem de pontos com 1,15 bilhão de pontos. Para as análises, essa nuvem foi simplificada para 17,2 milhões de pontos. O volume calculado da caverna (74.500 m^3) não mostrou variação significativa em nuvens com 1.000.000, 500.000, 250.000 e 50.000 pontos. Os dados gerados mostram diferenças importantes quando comparados com os mapas do PROCAD, o que reflete tanto as técnicas utilizadas na época como a subjetividade inerente ao levantamento topográfico espeleológico.

Palavras-Chave: topografia*;* espeleometria; passeio virtual; acessibilidade.

Abstract

A first 3D survey with Terrestrial Laser Scanner (TLS) of the touristic sector of Devil's Cave *(Caverna do Diabo)* is presented. 36 TLS scans were fused into a 1.15 billion-points cloud. This cloud had to be simplified to 17.2 million points for analyses. Volume calculated from the 3D model (74,500m^3) does not change much for clouds with 1,000,000, 500,000, 250,000 or 50,000 points. The data shows expressive differences from PROCAD maps, a reflex of the techniques used at the time as well as of the inherent subjectivity of the speleological topographic survey process.

Keywords*: cave mapping; speleometrics; virtual tour;accessibility.*

1. INTRODUÇÃO

A Caverna do Diabo, ou Gruta da Tapagem, é uma das cavernas mais conhecidas do Brasil e a única caverna de São Paulo com infraestrutura para turismo de larga escala, com iluminação elétrica fixa, escadarias e passarelas (Silvério, 2014).

Localiza-se no Parque Estadual da Caverna do Diabo (PECD), que integra o Mosaico de Unidades de Conservação do Jacupiranga, juntamente com outras 13 UCs, sendo gerenciada pela Fundação para a Conservação e a Produção Florestal, ou Fundação Florestal, ligada à Secretaria de Infraestrutura e Meio Ambiente do Estado de São Paulo- SIMA/SP (Figura 1).

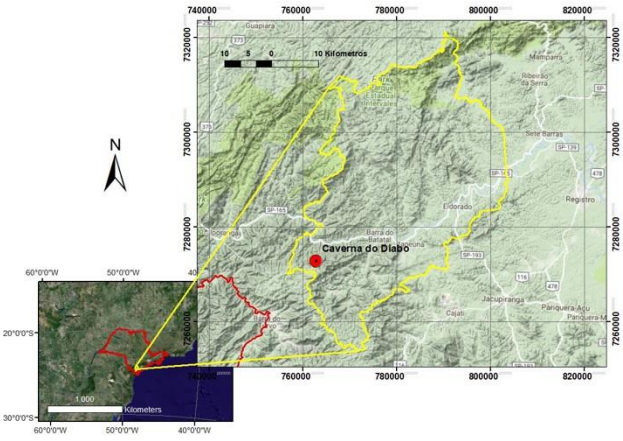

Figura 1: Localização da Caverna do Diabo.

Explorada desde o início do século XX, teve seu primeiro mapeamento realizado em 1964, liderado por Michel Le Bret (Valle, 2001) e na década de 1990 o Projeto Caverna do Diabo (PROCAD) da Sociedade Brasileira de Espeleologia (SBE) culminou na produção de um mapa completo da caverna e diversos estudos relacionados. Entretanto, o último trabalho de mapeamento do PROCAD foi realizado em 1998 (Figueiredo et al., 2007).

Outros trabalhos que visavam o aprimoramento do mapeamento espeleológico da caverna foram feitos por Person (2013) e Silvério (2014) com uso de equipamentos mais precisos que os utilizados durante o PROCAD, como Estação Total. Estudos voltados à geologia, hidrogeologia e geomorfologia (Polistchuck 2011, Cordeiro 2013, Sallun Filho et al. 2015) vêm sendo desenvolvidos e contribuem para o conjunto do conhecimento sobre o sistema cárstico do local.

O objetivo principal deste trabalho foi a produção de um modelo tridimensional do setor turístico da Caverna do Diabo a partir de dados levantados por Laser Scanner Terrestre. O georreferenciamento do modelo 3D permite contribuições cartográficas e comparações com trabalhos anteriores.

2. METODOLOGIA

Equipamentos de Laser Scanner Terrestre (ou *Terrestrial Laser Scanner* - TLS) basicamente se utilizam de espelhos giratórios para realizar a deflexão de pulsos de laser que combinam dados de distância com dados de ângulos horizontais e verticais para produzir coordenadas 3D (*x, y, z*) (Buckley et al., 2008).

Neste trabalho foram utilizados dois modelos de TLS simultaneamente: FARO *focus* 3Dx130 e FARO *focus* S350. Cada varredura desses equipamentos gera uma nuvem de pontos com abrangência de 360º horizontal e 270º vertical (de maneira que apenas a área ocupada pelo tripé do equipamento não é coletada) com alcance efetivo de aproximadamente 50 à 60 metros, dependendo das condições da topografia local.

Os equipamentos TLS são instalados sobre tripés em cada ponto de varredura enquanto esferas brancas, são instaladas nas proximidades do durante o processo. O escaneamento destas esferas padronizadas serve para a posterior interligação entre as nuvens de pontos durante o pós-processamento. Desta forma, necessita-se que ao menos três esferas fixas estejam inclusas em duas nuvens de pontos consecutivas. Foram realizadas 36 varreduras de TLS seguindo o circuito pelas passarelas de concreto, desde a entrada da caverna, até o Salão da Catedral.

Para o georreferenciamento da nuvem de pontos completa, foi necessário determinar as coordenadas das esferas dos trechos inicial e final da nuvem de pontos. As coordenadas foram obtidas por topografia clássica com Estação Total em uma poligonal levantada a partir de duas estações de GPS geodésico instaladas nas áreas do restaurante e do estacionamento do PECD.

O processamento de uma nuvem de pontos tão densa como a gerada a partir de um trabalho como este é um dos principais desafios a serem enfrentados (Gallay et al. 2015). Dentro desse conceito, incluem-se a junção de cada varredura em um projeto único, o georreferenciamento deste projeto a partir dos dados obtidos por DGPS e topografia e a produção de superfícies 3D que sejam condizentes com a realidade e possam ser usadas para modelagens matemáticas.

O processamento inicial dos dados foi realizado no software *FARO Scene* 7.0, onde se deu uma das etapas mais trabalhosas, que consiste em estabelecer uma relação geométrica entre os dados de cada varredura realizada (operação chamada de registro). Para essa tarefa, foi necessária a importação de cada varredura, seguindo a sequência de coleta de dados em campo, para que os dados pudessem ter sua relação geométrica mais facilmente estabelecida, devido a presença de ao menos três esferas em comum entre as varreduras. A partir do registro entre as varreduras, obteve-se a nuvem de pontos completa, com 1,15 bilhão de pontos.

Por se tratar de um ambiente extremamente úmido, as gotículas de água presentes no ar e o espelho d'água podem interferir na medição de alguns pontos pela reflexão do feixe de laser. Turistas em circulação na caverna durante as varreduras, e mesmo a própria equipe, são captados pelo TLS, e precisam ser removidos da nuvem de pontos para etapas posteriores de análise.

Após a etapa de limpeza manual da nuvem de pontos, foi necessário realizar uma subamostragem (ou decimação), pois o elevado número de pontos no espaço tridimensional dificulta o processamento mesmo em softwares dedicados, como *Meshlab* e *Cloud Compare*. A amostragem foi configurada para uma distância entre pontos de 5 cm, o que resultou em uma nuvem com 17,2 milhões de pontos.

Uma segunda nuvem de pontos foi gerada contendo apenas um grande espeleotema localizado no início do setor turístico. Os dados foram decimados com distância entre pontos de 5 mm, resultando em uma nuvem com 10,1 milhões de pontos.

As nuvens decimadas foram processadas no software *Meshlab* (Cignoni et al., 2008). Entre análises realizadas estão o cálculo de volume e massa do espeleotema e uma avaliação da variação do volume calculado da caverna a partir de nuvens de pontos ainda mais simplificadas.

Para os cálculos do volume da caverna, a nuvem de pontos foi progressivamente simplificada com a ferramenta *Point Cloud Simplification.* Malhas (*meshs*) tridimensionais foram então geradas com a ferramenta *Poisson Surface Reconstruction.*

3. RESULTADOS

O principal resultado deste trabalho é a nuvem de 1,15 bilhões de pontos coletados por TLS ao longo do trecho turístico da Caverna do Diabo (Figura 2). A partir desse conjunto dados, diversas análises e produtos podem ser gerados, como comparação/atualização cartográfica, "passeios" virtuais, análises espeleométricas etc.

Uma comparação com os produtos cartográficos existentes para a caverna ilustra bem as limitações dos métodos tradicionais de mapeamento espeleológico, onde a geometria dos elementos mapeados depende não apenas dos equipamentos e métodos utilizados (bases fixas *vs* bases flutuantes, por exemplo), mas principalmente da experiência e subjetividade do "croquista".

A Figura 2 mostra uma imagem em planta da nuvem de pontos produzida neste trabalho, e a Figura 3 traz uma comparação visual entre o mapa da Caverna do Diabo produzido pelo PROCAD, por Silvério (2014) e a nuvem de pontos produzida neste trabalho.

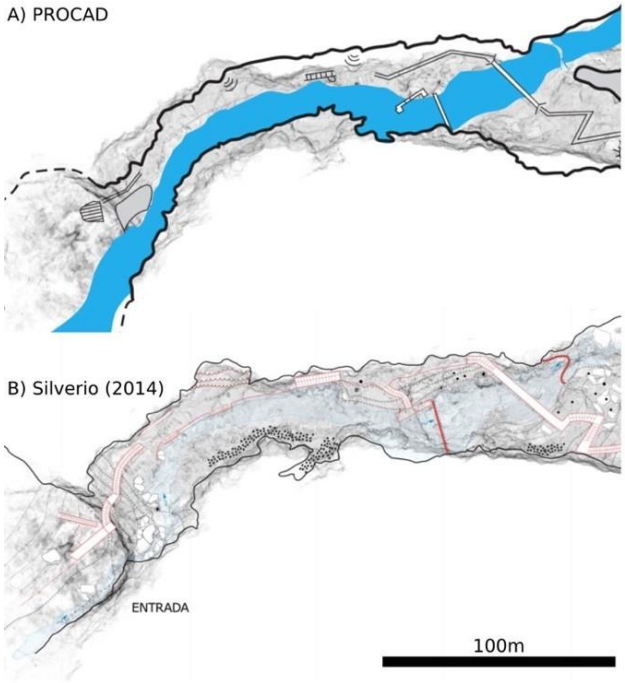

Figura 2: Comparação entre os dados produzidos com TLS e os mapas do PROCAD e Silverio (2014).

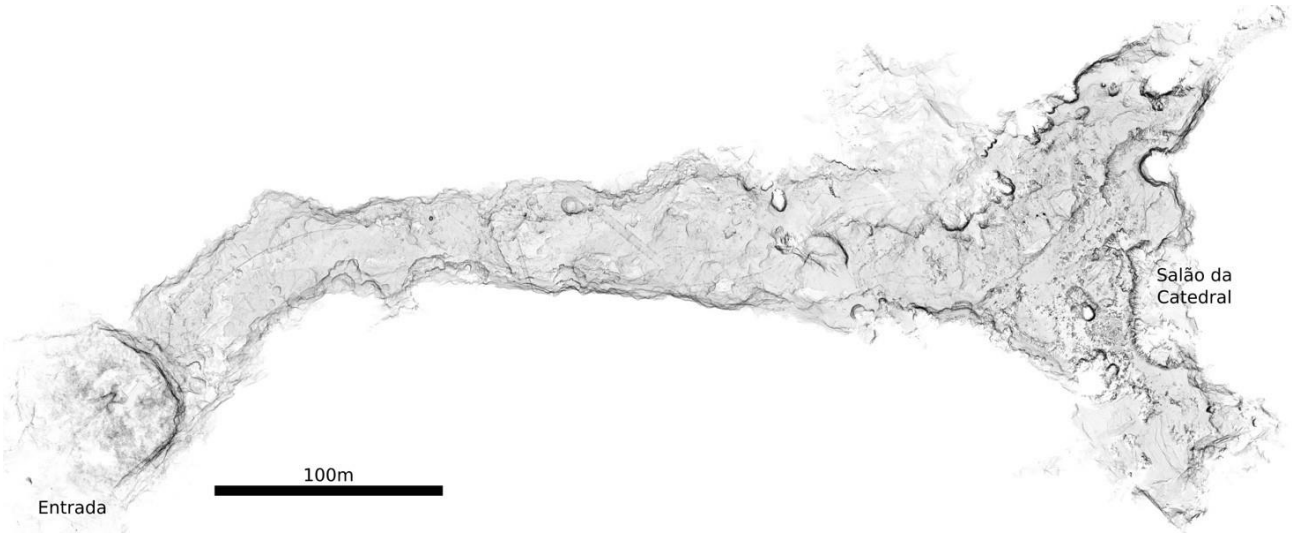

Figura 3: Vista em planta da nuvem de pontos produzida neste trabalho.

Enquanto que há diferenças marcantes com o mapa do PROCAD, os limites dos condutos definidos pelo TLS são muito similares aos do mapa de Silvério (2014), que utilizou dados levantados com DGPS e Estação Total por Person (2013).

O espeleotema selecionado para cálculo de volume e massa (Figura 4) tem dimensões de aproximadamente 9 x 3 m, com área superficial de 125 m^2, volume de 50 m^3 e massa de 135.500 kg (considerando a densidade da calcita de 2,71 g/cm^3).

Figura 4: Modelo 3D do espeleotema selecionado para cálculo de volume e massa.

O volume da caverna pode ser calculado a partir de uma malha "estanque" (*watertight*), fechada em todas as extremidades. O resultado do cálculo corresponde ao "volume de ar" dentro do modelo, sem considerar o volume dos espeleotemas ou passarelas, pontes etc.

Com o elevado número de pontos das nuvens, os arquivos se tornam grandes e o processamento mais demorado ou mesmo impraticável dependendo da configuração do computador utilizado.

A nuvem com 17,2 milhões de pontos foi progressivamente simplificada no *Meshlab* e o volume foi calculado em cada passo. A Tabela 1 traz os resultados da análise.

Tabela 1: Comparação entre os valores de volume calculados a partir de nuvens de pontos progressivamente simplificadas.

Número Pontos	Tam. Arquivo nuvem (*.xyz*)	Tam. Arquivo malha (*.ply*)	Volume (m^3)	Área Sup. (m^2)
17,2 x10^6	1.106,1 MB	799,3 MB	74.519	42.355
1,0 x10^6	71,2 MB	147,9 MB	75.145	40.792
500.000	27,3 MB	39,6 MB	73.318	35.295
250.000	13,8 MB	23,0 MB	73.438	32.500
50.000	3,1 MB	4,7 MB	74.055	27.295

Enquanto que o tamanho dos arquivos diminui drasticamente com o número de pontos, o volume calculado não sofre mudança significativa. Dessa forma, de acordo com o objetivo da pesquisa, pode-se trabalhar com arquivos menores e obter resultados significativos.

É preciso levar em consideração, entretanto, que a qualidade da reconstrução 3D (e de valores derivados) depende fortemente da distribuição dos pontos levantados pelo TLS. O ambiente cavernícola é, por sua natureza, um espaço composto de formas irregulares e com inúmeros anteparos (como blocos de rocha e espeleotemas) para o laser, o que irá resultar em áreas de "sombra", sem dados no produto final.

Nessas áreas, a reconstrução da malha pelo método de Poisson irá produzir formas arredondadas que irão influenciar nos cálculos de volume. No caso de não ser possível completar os dados com novos levantamentos, tais artefatos podem ser suavizados manualmente em softwares de modelagem 3D. A Figura 5 traz um exemplo de superfície suave gerada na reconstrução 3D, na área da entrada da caverna.

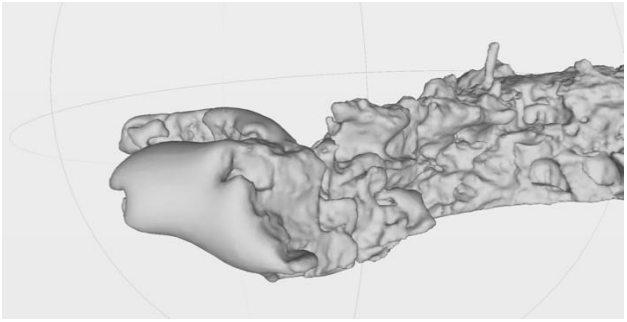

Figura 5: Superfície suave produzida em área sem dados na nuvem de pontos.

4. CONCLUSÕES

O levantamento por TLS em cavernas brasileiras com fins científicos e turísticos ainda é incipiente. Enquanto que empresas de mineração realizem levantamentos para fins de licenciamento ambiental, os dados não são disponibilizados para o público.

Neste trabalho foi realizado um primeiro mapeamento 3D com Laser Scanner do setor turístico da Caverna do Diabo (Figuras 6 e 7), uma das mais importantes cavernas turísticas do Brasil.

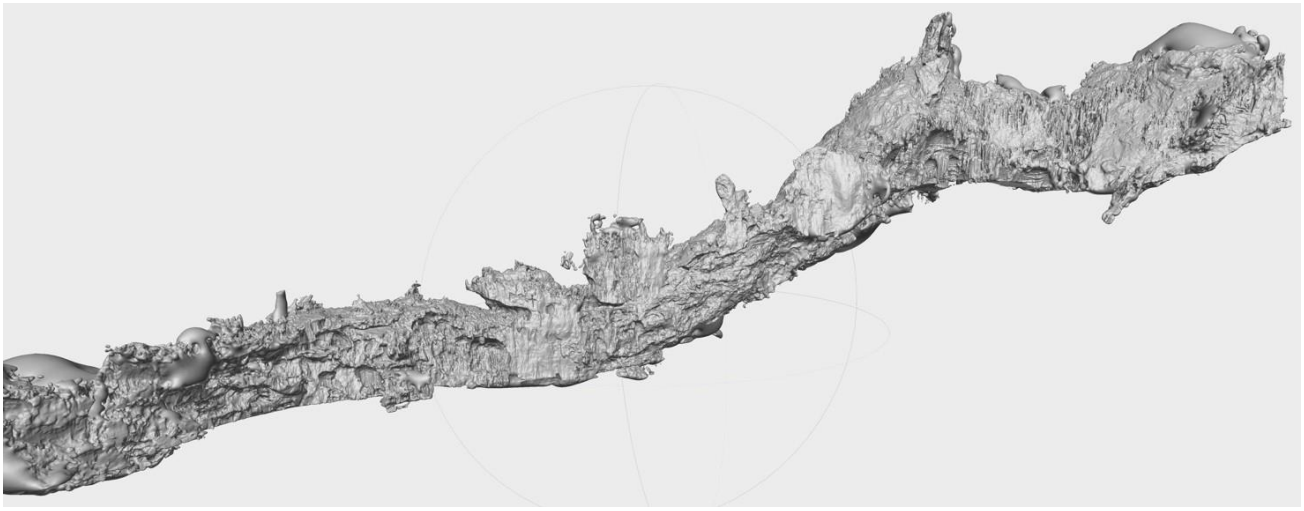

Figura 6: Modelo 3D do setor turístico da Caverna do Diabo.

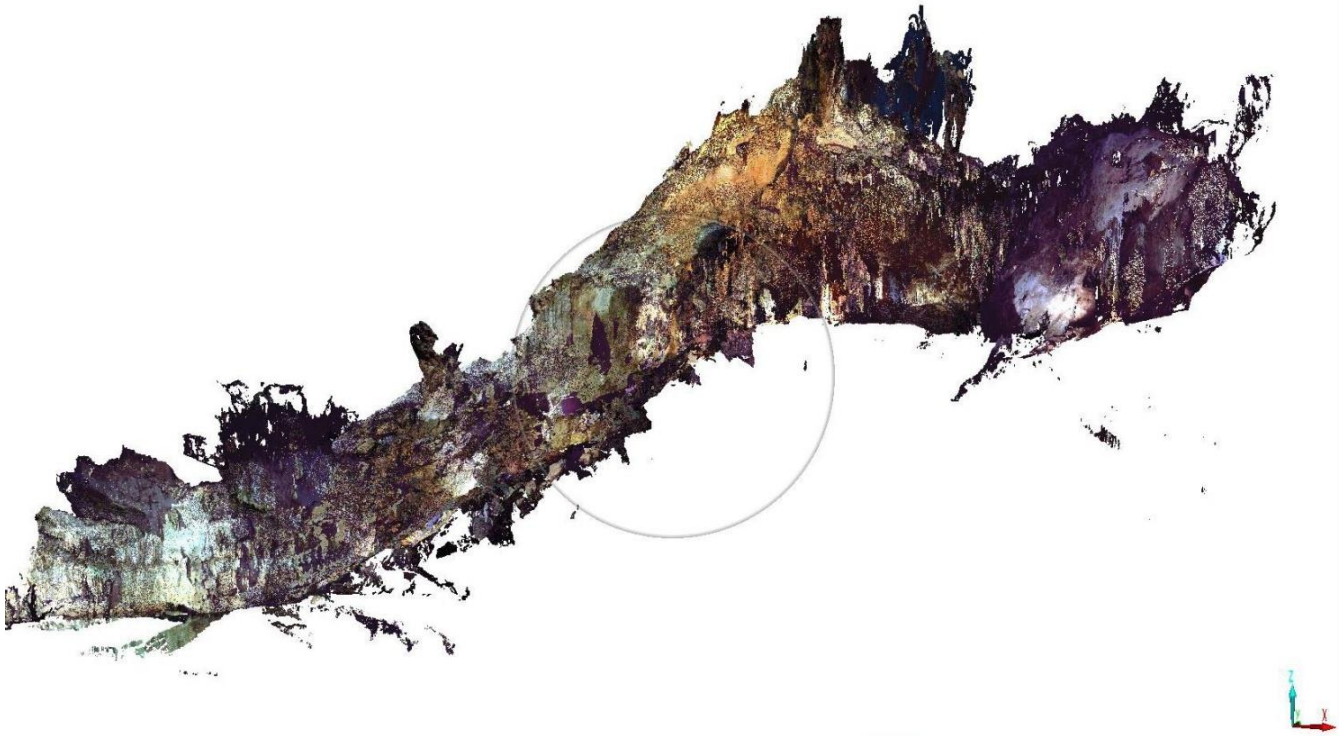

Figura 7: Nuvem de pontos do setor turístico da Caverna do Diabo.

Os dados foram levantados com propósito de documentação, pesquisa e acesso público sobre essa importante feição cárstica.

A continuidade da pesquisa prevê a realização de novos levantamentos, tanto para a complementação das áreas de sombra, quanto para a expansão do setor mapeado em 3D. Os dados deverão ser utilizados para gerar passeios virtuais e modelos físicos da caverna, ferramentas importantes e inovadoras em Educação e Conscientização Ambiental.

A cooperação científica na utilização dos dados e produção de material derivado é bem-vinda. Mais informações sobre o projeto, bem como acesso à modelos 3D interativos (simplificados) e vídeos de divulgação podem ser encontrados no site do Laboratório de Análise e Modelagem Espacial do Instituto de Energia e Ambiente da Universidade de São Paulo (SPAMLab): https://spamlab.github.io.

5. AGRADECIMENTOS

Este projeto é desenvolvido com apoio FAPESP (proc. #2016/06628-0) em parceria com a FARO Brasil. C.H.Grohmann é bolsista de Produtividade CNPq (proc. #304413/2018-6).

REFERÊNCIAS

BUCKLEY S.J., HOWELL J.A., ENGE H.D., KURZ T.H. **Terrestrial laser scanning in geology: data aquisition, processing and accuracy considerations.** Journal of the Geological Society, v.165, 625- 638, 2008.

CIGNONI, P., CALLIERI, M., CORSINI, M., DELLEPIANE, M., GANOVELLI, F., RANZUGLIA, G., **Meshlab: an open-source mesh processing tool**. Eurographics Italian chapter conference. 2008.

CORDEIRO, B.M. **Planalto carbonático do André Lopes (SP): Geomorfologia cárstica e geoespeleologiada Gruta da Tapagem (Caverna do Diabo).** Dissertação de Mestrado, Instituto de Geociências, Universidade de São Paulo, São Paulo, 2013.

FIGUEIREDO, L.A.V., ZAMPAULO, R.A., GERIBELLO, F.K., PEDRO, E.G., DELL ANTONIO, R., LOBO, H.A.S. **Projeto Caverna do Diabo (PROCAD): aspectos históricos (1990-2007) e resultados das expedições da terceira fase.** Anais do XXIX Congresso Brasileiro de Espeleologia, SBE, Ouro Preto. p.113-119, 2007.

GALLAY M., KANUK J., HOCHMUTH Z., MENEELY J.D., HOFIERKA J., SEDLAK V., **Large-scale and high-resolution 3-D cave mapping by terrestrial laser scanning: a case study of the Domica Cave, Slovakia**. International Journal of Speleology, 44, 277-291, 2015.

VALLE, M.A. Gruta da Tapagem (Caverna do Diabo). *in* AULER, A; RUBBIOLI, E.L.; BRANDI, R. **As Grandes Cavernas do Brasil**. Belo Horizonte: GBPE, p.136-137, 2001.

PERSON, A.L. **Mapeamento espeleológico de detalhe do setor turístico da gruta da Tapagem (Caverna do Diabo) - SP**. Monografia de trabalho de formatura, Instituto de Geociências, Universidade de São Paulo, São Paulo, 2013.

POLISTCHUCK, A., **Caracterização morfométrica da região cárstica da Serra André Lopes, Vale do Ribeira, SP**. Monografia de trabalho de formatura, Instituto de Geociências, Universidade de São Paulo, São Paulo, 2011.

SALLUN FILHO W., CORDEIRO B.M., KARMANN I., **Structural and hydrological controls on the development of a river cave in marble (Tapagem Cave - SE Brazil).** International Journal of Speleology, 44, 75-90, 2015.

SILVÉRIO M.O., **Atuação da arquitetura no uso público de cavernas. Conceitos, métodos e estratégias para ocupação. Caverna do Diabo, SP. São Paulo**. Dissertação de Mestrado, Faculdade de Arquitetura e Urbanismo, Universidade de São Paulo, São Paulo, 2014.

Anexo F. Coautoria em artigo completo publicado no periódico *Computers and Geosciences*

Anexo F.1. *Dune migration and volume change from airborne LiDAR, terrestrial LiDAR and Structure from Motion-Multi View Stereo*

Computers & Geosciences 143 (2020) 104569

Contents lists available at ScienceDirect

Computers and Geosciences

journal homepage: www.elsevier.com/locate/cageo

Research paper

Dune migration and volume change from airborne LiDAR, terrestrial LiDAR and Structure from Motion-Multi View Stereo

Carlos H. Grohmann [a,c,*], Guilherme P.B. Garcia [b,c], Alynne Almeida Affonso [a,c], Rafael Walter Albuquerque [a,c]

[a] Institute of Energy and Environment, University of São Paulo (IEE-USP), São Paulo, 05508-010, Brazil
[b] Institute of Geosciences, University of São Paulo (IGc-USP), São Paulo, 05508-080, Brazil
[c] Spatial Analysis and Modelling Lab (SPAMLab, IEE-USP), Brazil

ARTICLE INFO

Keywords:
Geomorphometry
Photogrammetry
Digital elevation model
Point cloud
RPA

ABSTRACT

Sand dunes are commonly regarded as a challenge to traditional photogrammetry due their homogeneous texture and spectral response. In this work we present an evaluation of Structure from Motion-Multi View Stereo (SfM-MVS) to obtain high-resolution elevation data of coastal sand dunes based on images acquired by Remotely Piloted Aircraft (RPA). A Digital Elevation Model (DEM) of a dunefield in Southern Brazil was generated from 810 photos captured by an RPA at 100 m above the takeoff point in February 2019. Image matching was successful in all areas of the survey due the presence of superficial features (footprints and sandboard tracks) and visibility of the sedimentary stratification, highlighted by heavy minerals. Altimetric accuracy of the SfM-MVS DEM was validated by comparison with Terrestrial LiDAR (TLS) data collected during the same fieldwork campaign of the RPA flights. The SfM-MVS DEM was then compared to an Airborne LiDAR (ALS) DEM from October 2010. While the SfM-MVS and TLS DEMs are very similar, without any major difference in elevation or in the reconstruction of topographic features, the SfM-MVS DEM presents a small scale surface roughness not visible in the TLS DEM. The Feature Preserving DEM Smoothing (FPD) algorithm was applied to the SfM-MVS DEM with good results in terms of surface smoothing, but without any significant changes in descriptive statistics and error metrics, with an RMSE of 0.08 m and MAE of 0.06 m for both the original and the FPD-filtered DEM. Displacement of dune crest lines from the ALS and SfM-MVS DEMs resulted in a migration rate of ≈5 m/year between 2010 and 2019, in good agreement with rates derived from satellite images and historical aerial photographs of the same area. Sand volume change in the same period showed a decrease of only 0.2%, which can be related to the installation of sand fences to promote dune stabilization and sand removal from the front of the dune field to keep a road open to vehicles. ALS can cover large areas in little time but its high cost still remains a barrier to wider usage, especially by researchers in developing countries. TLS has an intermediate cost but demands more fieldwork and more processing time. In our case we needed three days for the TLS survey and around three weeks to produce a DEM of ≈80 400m^2. On the other hand, we were able to cover ≈740 900m^2 with six flight missions in under three hours, with ≈13 h processing time in a medium-range workstation. This makes SfM-MVS a low-cost solution with fast and reliable results for 3D modelling and continuous monitoring of coastal dunes.

1. Introduction

Aeolian dune fields occur in diverse depositional settings, on Earth and on other planetary bodies such as Mars, Venus, Saturn's moon Titan and Pluto (Fryberger and Dean, 1979; Short, 1988; Wang et al., 2002; Livingstone et al., 2007; Hayward et al., 2007; Radebaugh et al., 2008; Bourke et al., 2010; Martinho et al., 2010; Kreslavsly and Bondarenko, 2017; Hayes, 2018; Telfer et al., 2018). To better understand these dynamic environments, repeated topographic surveys of the landscape are needed (Conlin et al., 2018). As the sand supply of dune fields is sensitive to patterns of wind and rainfall, changes in dune field volume and morphology can be related to climate change (Gaylord et al., 2001; Clemmensen et al., 2007; Sawakuchi et al., 2008; Tsoar et al., 2009;

* Corresponding author.
E-mail addresses: guano@usp.br (C.H. Grohmann), guilherme.pereira.garcia@usp.br (G.P.B. Garcia), alynne.affonso@usp.br (A.A. Affonso), rafael.albuquerque@usp.br (R.W. Albuquerque).
URLs: http://www.iee.usp.br, https://spamlab.github.io (C.H. Grohmann).

https://doi.org/10.1016/j.cageo.2020.104569
Received 27 March 2020; Received in revised form 16 July 2020; Accepted 3 August 2020
Available online 7 August 2020
0098-3004/© 2020 Elsevier Ltd. All rights reserved.

Singhvi et al., 2010; Levin, 2011; Grohmann and Sawakuchi, 2013; Hoover et al., 2018).

Migration rates of aeolian dunes have been determined with aerial photographs (e.g., Finkel, 1961), orbital imagery (Shrestha et al., 2005; Potts et al., 2008; Hugenholtz and Barchyn, 2010; Dong, 2015; Mendes and Giannini, 2015; Mendes et al., 2015; Bhadra et al., 2019) or Digital Elevation Models (DEMs[1]) (e.g., Mitasova et al., 2005b).

With the growth of Geomorphometry as the practice of terrain modelling and ground-surface quantification (Pike, 1995; Pike et al., 2009; Hengl and Reuter, 2008), DEMs have became essential tools in landform analysis, as they allow speed, precision and reproducibility to calculation of geomorphometric parameters (Grohmann, 2004).

DEMs of aeolian dunes can be constructed by several methods such as traditional field techniques (levelling, Total Station) (Łabuz, 2016), interpolation of contour lines (Judge et al., 2000; Mitasova et al., 2005b), Differential or Real-time kinematic (RTK) GPS points (Mitasova et al., 2005b; Pardo-Pascual et al., 2005), LiDAR (Light Detection and Ranging) surveys, either airborne (ALS – Airborne Laser Scanner) (Mitasova et al., 2004, 2005a,b; Vianna and Calliari, 2015; Baughman et al., 2018), terrestrial (TLS – Terrestrial Laser Scanner) (Montreuil et al., 2013; Feagin et al., 2014; Fabbri et al., 2017; Sankey et al., 2018b; Bañón et al., 2019; Kasprak et al., 2019; Lee et al., 2019) or mounted on Remotely Piloted Aircrafts (RPAs) (Solazzo et al., 2018; Garcin et al., 2019), and Structure from Motion-Multi View Stereo (SfM-MVS) using images collected by handheld cameras, mounted on poles, kites or RPAs (Mancini et al., 2013; Gonçalves and Henriques, 2015; Conlin et al., 2018; Duffy et al., 2018; Forlani et al., 2018; Seymour et al., 2018; Solazzo et al., 2018; Guisado-Pintado et al., 2019; Laporte-Fauret et al., 2019; Kasprak et al., 2019; Lee et al., 2019; O'Dea et al., 2019; Pagán et al., 2019; Taddia et al., 2019). A literature review on RPA-based topographic surveys of coastal areas is presented by Casella et al. (2020).

In this work we present an evaluation of SfM-MVS to obtain high-resolution elevation data of coastal sand dunes. Altimetric accuracy of the SfM-MVS DEM was validated by comparison with TLS data collected during the same fieldwork campaign of the RPA flights (February 2019). The SfM-MVS DEM was then compared to an ALS DEM from October 2010. The results show almost no change in total volume and a migration rate of ≈5 m/year, compatible with those derived from aerial and orbital imagery.

While 3D modelling of aeolian sand dunes can be a challenge to traditional photogrammetry due to their homogeneous texture and spectral response, the use of SfM-MVS is recommended and the factors that contributed to a successful reconstruction are discussed.

1.1. Study area

The study area, located in Santa Catarina State, southern Brazil (Fig. 1A-B), comprises barrier–lagoon depositional systems with associated dune fields (Angulo et al., 2006; Giannini et al., 2007) which evolved during the Late Holocene as a result of wind strength intensification and sand supply increase in southern Brazilian coast (Mendes and Giannini, 2015; Mendes et al., 2015). The Garopaba (or Siriú) dune field is composed of unvegetated and vegetated aeolian dunes. The unvegetated dunes are represented by mostly barchanoid chains, while the vegetated ones include parabolic dunes, blowouts and foredunes (Martinho et al., 2006; Hesp et al., 2007).

There are significant differences of wind field along the southern Brazilian coast; while the dominant and prevailing direction is from the S at Joaquina (located ≈45 km north of Garopaba in Santa Catarina Island), it is from the NE at Farol de Santa Marta, ≈70 km south of the study area (Dillenburg et al., 2006; Hesp et al., 2007; Truccolo, 2011; Mendes and Giannini, 2015). At Garopaba, winds from the North are responsible for dune migration (Mendes and Giannini, 2015; Mendes et al., 2015).

[1] In this work we use Digital Elevation Model (DEM) in a loose sense to refer to any 3D representation of the land surface, not making a distinction between Digital Terrain Model (DTM) representing the true (bare) ground surface, or Digital Surface Model (DSM) representing a surface that does not necessarily coincide with the ground and may depict man-made structures or vegetation canopy.

Table 1
Overview of datasets used in this study. See text for details and Supplemental Material for maps of point density.

Data	DEM Area (m^2)	# points	points/m^2
ALS (full)	4 434 722	11 574 555	2.6
ALS (SfM area, 1st returns)	740 922	2 380 005	3.2
SfM-MVS (full)	740 922	344 769 434	465.3
SfM-MVS (thin 125th pt)	740 922	2 378 399	3.2
SfM-MVS (TLS area)	80 413	28 158 102	350.1
SfM-MVS (10 cm grid)	80 413	8 079 569	100.5
TLS (full)	80 413	1 187 708 492	14 770.1
TLS (2 cm filter)	80 413	170 141 709	2 115.8
TLS (10 cm grid)	80 413	7 039 501	87.5

2. Methods

This section presents the datasets, methods and tools used in this study. A flowchart of the analysis steps is in the Supplemental Material. Table 1 shows, for each kind of data used in this paper (ALS, SfM-MVS, TLS), area of the interpolated DEM, number of points and density of points within that area.

2.1. Airborne LiDAR

Airborne LiDAR (ALS) data were collected on October 2010 by Geoid Laser Mapping Co. using an Optech ALTM 3100 sensor with a saw-tooth scanning pattern, density of about one point per 0.5 m^2, measured from an altitude of ≈1200 m (≈4000 ft). Raw LiDAR data (with up to four laser pulses) were processed by Geoid and delivered with vertical accuracy of 0.15 m (1σ) and horizontal accuracy of 0.5 m (1σ).

ALS data (LiDAR 1st returns) were imported into GRASS-GIS (Neteler et al., 2012) as vector points and interpolated with bilinear splines (Brovelli and Cannata, 2004; Brovelli et al., 2004) to create a DEM with 0.5 m spatial resolution (Fig. 1C).

2.2. Fieldwork and ground control points

Fieldwork for TLS and SfM-MVS surveys was conducted on February 2019. Six targets were deployed within the dune field area (Fig. 2B) and their coordinates were determined by Differential Global Positioning System (DGPS), to serve as Ground Control Points (GCPs) for georeferencing the SfM-MVS outputs and the TLS point cloud (Harwin et al., 2015).

Each target measured ≈80 × 60 cm in a black and white chequered pattern and was clearly visible in the photos (Fig. 2C). A Spectra Precision SP60 DGPS was used in a base-rover static configuration and raw data was post-processed in Survey Office[2] 4.10 software, using the Imbituba Station of the Brazilian GPS Network as reference. The processing reports are available in the Supplemental Material.

[2] https://spectrageospatial.com/survey-office.

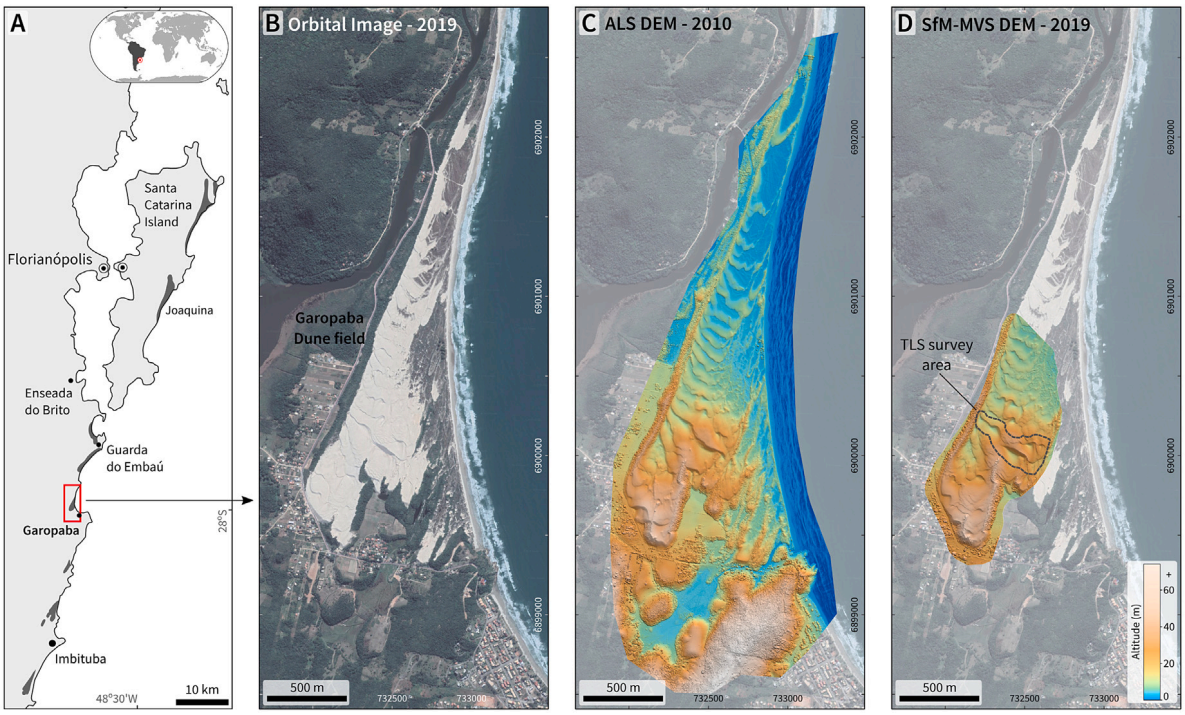

Fig. 1. (A) Location of study area in southern Brazil; (B) Satellite image of the Garopaba dune field (image date: 07-30-2017); (C) Digital Surface Model produced by ALS (2010); (D) DEM produced by SfM-MVS (2019), with TLS survey area shown. Elevation colour scale is the same for C and D. Shaded relief illumination: N25°, 30° above horizon. Dune field satellite imagery ©2019 Maxar Technologies, powered by Google. Coordinate system for B/C/D and following figures: UTM zone 22 southern hemisphere, WGS84 datum.

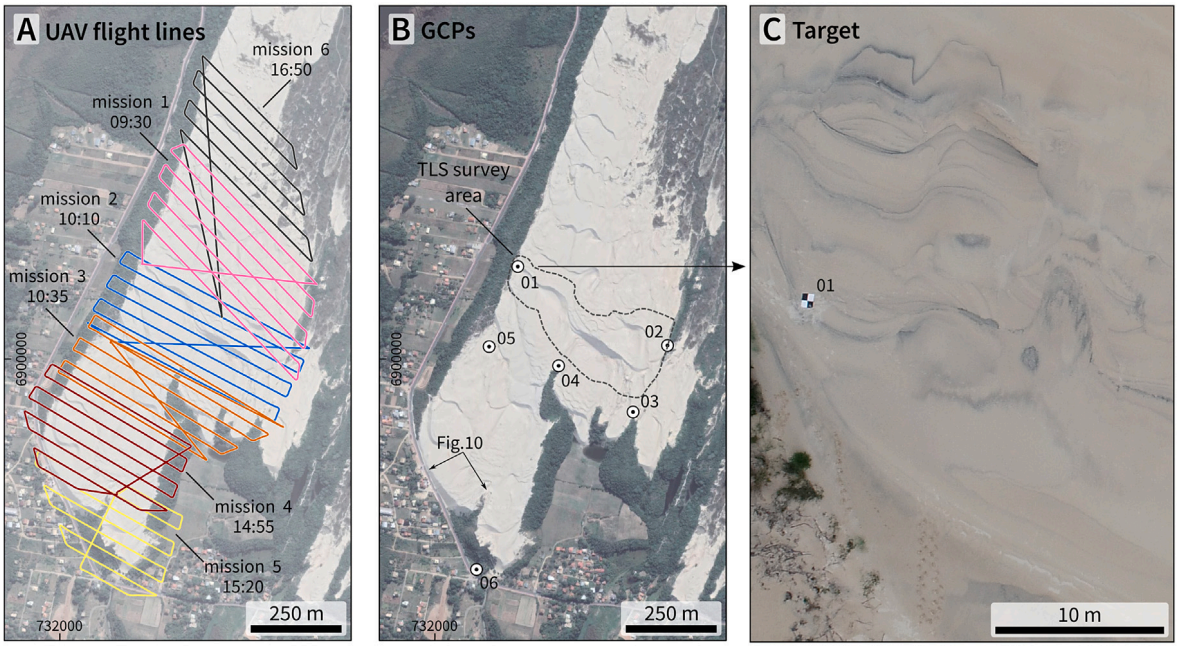

Fig. 2. (A) Flight missions executed over the dune field; (B) Ground Control Points used to georeference the SfM-MVS outputs and TLS data; (C) Target (GCP 01), sedimentary structures and superficial features seen in the RPA photo.

2.3. Terrestrial LiDAR

Terrestrial LiDAR (TLS) data were collected with a FARO™ Laser Scanner Focus^{3D} S120, a geodetic laser scanner with distance measurement based on phase shift of infrared light (905 nm), maximum range of 120 m, and ranging error of ±2 mm at 10 m distance at 90% reflectivity (FARO Technologies Inc., 2013). The scanner was set at resolution of "1/5" and quality of "3x", resulting in a point spacing of 7.67 mm at a distance of 10 m, scan time of two minutes and 28.4 million points per scan (this model does not acquire images). Five spherical targets provided with the equipment were arranged on the ground at ≈10 m from the TLS and re-positioned in a 'leapfrog' scheme during the survey, so that each consecutive scan was able to capture at least two spheres from the previous one. In three days of field work, 110 scans were collected, covering an area of ≈80 400 m^2 (Fig. 1D).

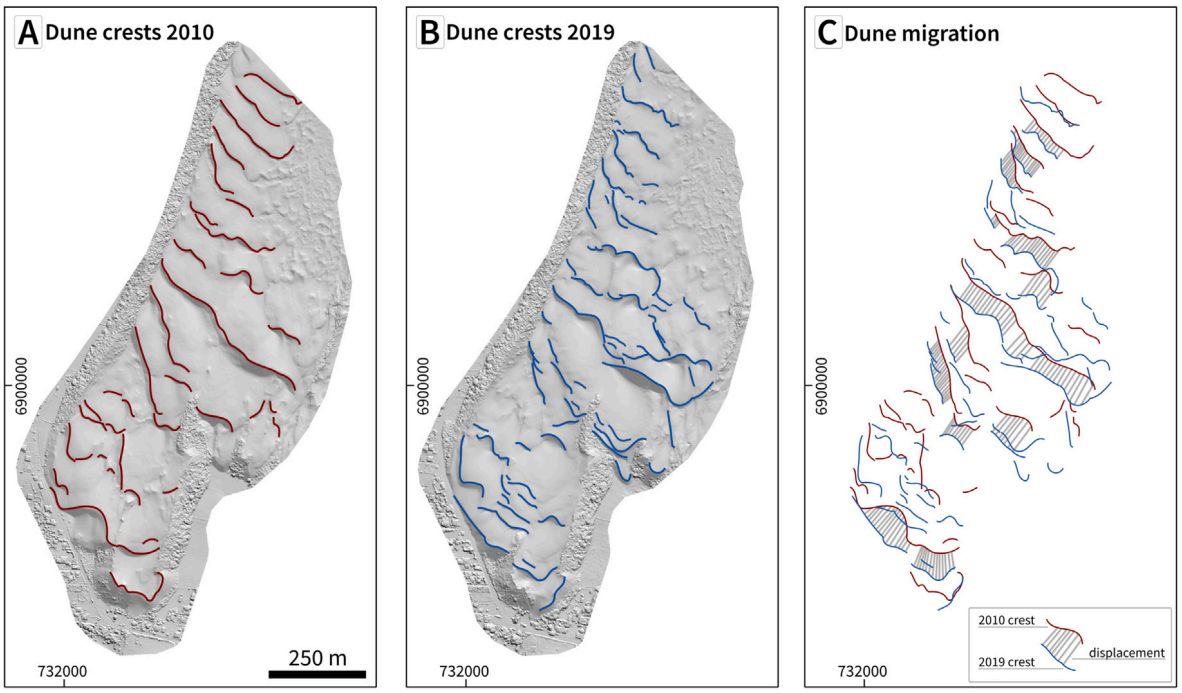

Fig. 3. Determination of dune migration between 2010 and 2019 surveys. (A) dune crests of 2010, over shaded relief image of ALS DEM; (B) dune crests of 2019, over shaded relief image of SfM-MVS DEM; (C) displacement lines (grey) connecting crest lines.

TLS data were processed in FARO Scene 7.1.[3] Each scan was registered to its adjacent ones manually using the spherical targets as references. Georeferencing of the point cloud was based on two DGPS points located at the extremities of the surveyed area (Fig. 2B). Referencing with only two points was possible because this TLS model has an integrated dual axis compensator to automatically level the captured scan data, so the control points were used for an affine transformation (translation/scale/rotation) in 2D space.

To overcome the heterogeneous distribution of data common to terrestrial LiDAR, with a very high density of points near the scanner, the full point cloud was subsampled in FARO Scene with a minimum distance filter of 2 cm between points. To eliminate duplicate points and compensate for small differences in the alignment of individual scans, this point cloud was gridded to a raster in GRASS-GIS using the mean elevation value of LiDAR points within 10 cm cells (`r.in.xyz` module). To fill empty (null) cells, the raster was converted to vector and a DEM with 10 cm spatial resolution was created by interpolation with bilinear splines (Fig. 4A).

2.4. SfM-MVS

Images for the SfM-MVS reconstruction were acquired by a DJI Phantom 4 Pro RPA. The aircraft digital camera has an 1″ CMOS 20 MP sensor, global shutter, 84° FOV and 8.8 mm focal distance (24 mm at 35 mm equivalent). Images can be saved as JPEG or RAW, 5472 × 3648 px (3:2 ratio). Flight missions were planned and executed using the MapPilot app[4] with height above takeoff point of 100 m (image footprint 150 × 100 m, pixel size ≈2.7 cm) and 75% overlap along and across-track.

Six missions were flown, covering an area of ≈869 000 m^2 with 810 images. The camera angle was set to −80° (i.e., 10° from nadir). Fig. 2A shows flight paths and starting time for each mission (UTC-3). Weather conditions during fieldwork were of dark skies with light rains scattered throughout the day.

The SfM-MVS workflow (e.g., Westoby et al., 2012; Viana et al., 2018; James et al., 2019) was processed in Agisoft Metashape Pro version 1.5.1.[5] In the SfM step, images were aligned with 'High' accuracy. To avoid doming effects in the reconstructed surface (e.g., James and Robson, 2014), camera alignment optimization was performed considering a marker accuracy of 0.005 m, following Agisoft's recommendations.[6] The MVS reconstruction was set to 'High' quality and 'aggressive' depth filtering. The processing report is available in the Supplemental Material.

For the altimetric comparison with TLS data, the full SfM-MVS point cloud was imported into GRASS-GIS in the same manner of the TLS data: gridded by the mean elevation in 10 cm cells, converted to vector and interpolated with bilinear splines to a DEM with 10 cm resolution (Fig. 4B).

For the dune migration and volume analysis, the full SfM-MVS point cloud was subsampled (thinned) with LAStools (Isenburg, 2019) by extracting every 125th point, imported into GRASS-GIS as vector points and interpolated with bilinear splines to a DEM with 0.5 m resolution (Fig. 1D). The thinning value was determined after experimentation, and the goal was to obtain a similar number of points, within the interpolation area, for the ALS and SfM point clouds (Table 1).

2.4.1. Accuracy of SfM-MVS DEM

The vertical accuracy of a DEM can be computed from the differences between the dataset being analysed and co-located values from an independent source of higher accuracy (Willmott and Matsuura, 2005; Wechsler, 2007; Hebeler and Purves, 2009; Reuter et al., 2009; Baade and Schmullius, 2016). To evaluate the accuracy of the SfM-MVS reconstruction, the TLS DEM was considered as the reference.

Mean Absolute Error (MAE) and Root Mean Square Error (RMSE) are metrics that been widely used in the Geosciences to measure the accuracy of DEMs (e.g., Nikolakopoulos et al., 2006; Willmott and Matsuura, 2006; Smith and Vericat, 2015; Gesch et al., 2016; Satge

[3] https://knowledge.faro.com/Software/FARO_SCENE/SCENE.
[4] https://support.dronesmadeeasy.com.
[5] https://www.agisoft.com.
[6] https://www.agisoft.com/index.php?id=31.

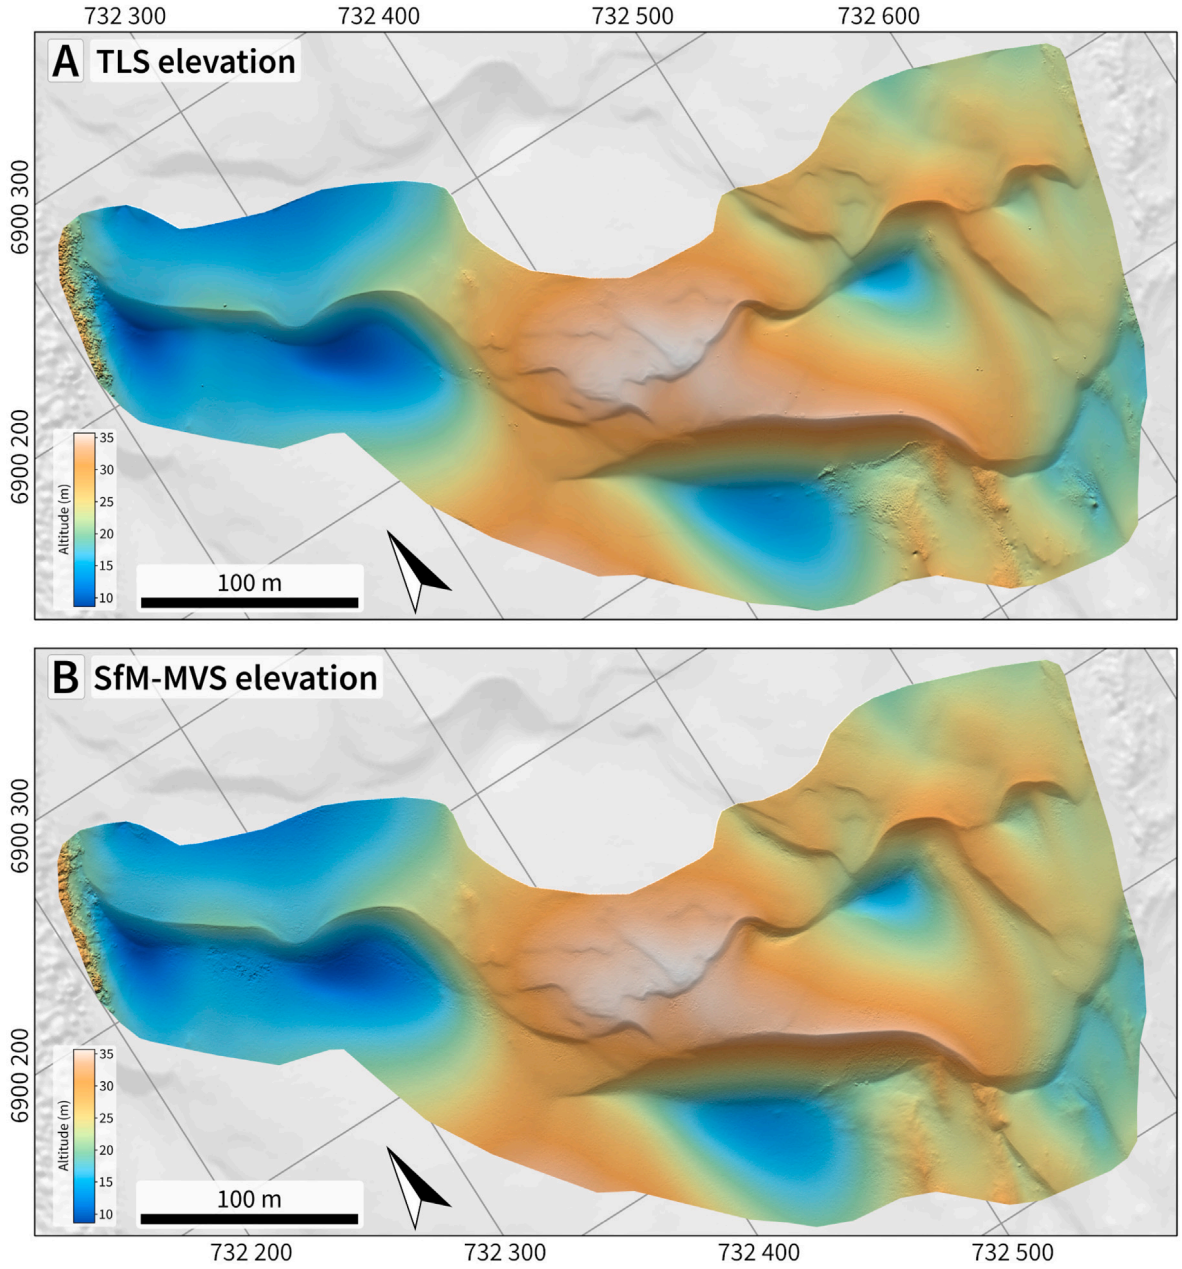

Fig. 4. (A) TLS DEM; (B) SfM-MVS DEM. Elevation colour scale is the same for A and B. Shaded relief illumination: N25°, 30° above horizon.

et al., 2016; Grohmann and Sawakuchi, 2013; Grohmann, 2018). MAE (Eq. (1)) and RMSE (Eq. (2)) were calculated from all pixels within a mask designed to avoid areas with vegetation or without TLS data.

$$MAE = \frac{1}{n}\sum_{i=1}^{i=n}(|z_{TLS} - z_{SfM}|) \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{i=n}\left[(z_{TLS} - z_{SfM})^2\right]} \quad (2)$$

2.4.2. Surface roughness and DEM smoothing

Surface roughness characterizes elevation variations over a particular scale (Grohmann et al., 2010; Berti et al., 2013; Grohmann and Hargitai, 2014; Smith, 2014). In this paper surface roughness was calculated as the standard deviation of slope in a moving-window filter, as it provide good results in identifying terrain features and is not sensitive to spurious data (Grohmann et al., 2010).

Low-pass filters are usually applied to DEMs to remove or reduce roughness (Reuter et al., 2009; Gallant, 2011; Lindsay et al., 2019), but sharp edges such as dune crests will be modified as well (Barash, 2002; Grohmann and Riccomini, 2009). To retain the sharpness of breaks-of-slope in the filtered DEM edge-preserving (or de-noise) procedures (e.g., Sun et al., 2007; Stevenson et al., 2010; Lindsay et al., 2019) must be employed.

The effect of de-noising the SfM-MVS DEM was evaluated by applying the Feature Preserving DEM Smoothing (FPD) algorithm (Lindsay et al., 2019), with different parameter settings, to a sub-area of the DEM (Fig. 5) and evaluating the change of RMSE from the TLS DEM and of Circular Variance of Aspect (CVA – Lindsay et al., 2019) for each set of parameters. CVA measures the variability of aspect, or surface shape complexity, within a neighbourhood; its value is 0.0 in smooth areas approaching 1.0 in areas of complex topography (i.e., high surface roughness). The three parameters to be set in the FPD method are the filter kernel size (k), the normal difference threshold angle (t), and the number of elevation-update iterations (i) (for a detailed explanation of the algorithm and parameters' definitions, see Lindsay et al., 2019).

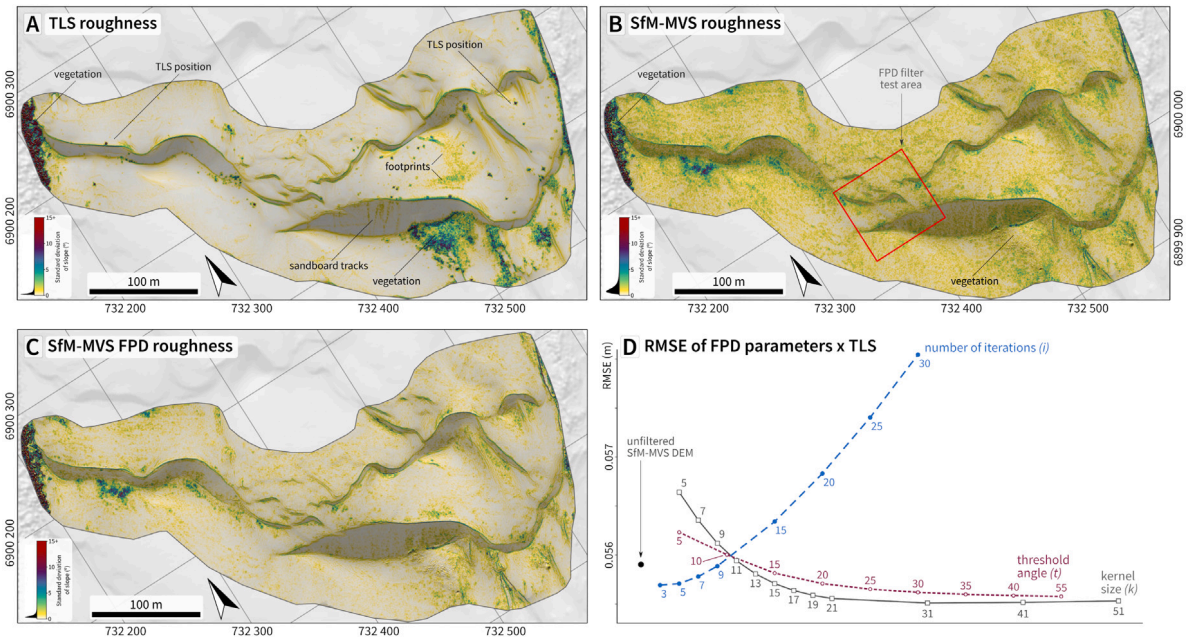

Fig. 5. Surface roughness maps, calculated as the standard deviation of slope in a 5 × 5 window: (A) TLS; (B) SfM-MVS; (C) SfM-MVS after FPD filter (k = 17, t = 20°, i = 5); (D) RMSE plot of each FPD DEM with TLS DEM according to FPD parameters. Roughness colour scale is the same for A, B and C.

The tests were done by changing one parameter while keeping the other two fixed, and then calculating CVA for each DEM with filter sizes of 3 × 3 up to 41 × 41 pixels.

In the first experiment, t ranged from 5° to 45° (in 5° increments) with k = 15 and i = 5. Next, k changed from 5 × 5 up to 51 × 51 with t = 20° and i = 5. Last, i varied between 3 and 30 iterations with k = 15 and t = 20°.

After the sub-area tests, k, t and i values were selected and FPD was applied to the entire SfM-MVS DEM. Error metrics (RMSE, MAE) of the original and smoothed SfM-MVS DEM were calculated considering the TLS DEM as reference.

2.5. Dune migration and sand volume

Dune migration can be evaluated from multi-temporal data such as aerial photographs (Finkel, 1961; Stafford and Langfelder, 1971; Mendes and Giannini, 2015; Baughman et al., 2018), satellite images (Hoover et al., 2018; Dong, 2015; Yang et al., 2019) or LiDAR DEMs (Mitasova et al., 2004, 2005a,b; Baughman et al., 2018). Dune migration between the 2010 (ALS) and 2019 (SfM-MVS) surveys was determined as the displacement of dune crest lines.

For each survey, surface roughness of the DEM was calculated as the standard deviation of slope (Grohmann et al., 2010) in a 5 × 5 pixels neighbourhood (2.5 × 2.5 m); crest lines were drawn in QGIS version 3.8 (QGIS Development Team, 2019) following the high-roughness crests (see Supplemental Material); lines connecting the crests were draw approximately parallel to the S-SW migration direction (Hesp et al., 2007; Mendes and Giannini, 2015) (Fig. 3) and saved in shapefile format. Azimuth and length of each displacement line were calculated with Python version 3.7.4 (Python Software Foundation, 2019) using the `ogr` module of the GDAL library (GDAL Development Team, 2019) to access vector geometries. Mean azimuth was calculated according to Fisher (1993).

Sand volume was calculated with the GRASS-GIS `r.volume` module (Hinthorne, 1988). This module calculates volume by summing cell values within a given area and then multiplying by the area occupied by those cells. An elevation of 0 m (zero) was used as a reference base level.

2.6. Data analysis

In order to streamline the process and ensure reproducibility (Barnes, 2010), data analysis was performed in GRASS-GIS version 7.6 (Neteler et al., 2012; GRASS Development Team, 2019) through Jupyter notebooks (Kluyver et al., 2016; Rule et al., 2018) using the Pygrass library (Zambelli et al., 2013) to access GRASS' datasets. The FPD algorithm is implemented in the open-source geospatial analysis platform WhiteboxTools (Lindsay, 2017). Statistical analyses were performed with the Python libraries Rasterio, Scipy, Numpy, Pandas, Seaborn and Matplotlib (Oliphant, 2006; Hunter, 2007; McKinney, 2011; Gillies et al., 2013; The SciPy community, 2013; Waskom et al., 2016).

3. Results

3.1. TLS and SfM-MVS

The SfM-MVS survey resulted in data with 2.77 cm resolution (1.1 px reprojection error) and RMSE of 0.7 cm in longitude and 0.4 cm in latitude, and 0.5 cm in elevation for the residuals of control points (see Supplemental Material). The TLS point clouds were combined into a single dataset with a registration error of 4.9 mm.

The DEMs produced from the TLS and SfM-MVS data are presented in Fig. 4. The surfaces are very similar, without any major difference in elevation or in the reconstruction of topographic features. Upon a closer inspection, the SfM-MVS DEM presents a small scale surface roughness not visible in the TLS DEM. To visually evaluate this difference, surface roughness of the DEMs was calculated as the standard deviation of slope in a 5 × 5 pixels neighbourhood (0.5 × 0.5 m).

The TLS DEM has a smooth surface, with higher roughness values on vegetated areas and over some of the places where the TLS equipment was positioned (Fig. 5A). These spots can be related to a small mismatch between adjacent scans, where in one there is no data (under the scanner), so the gridding procedure cannot compensate the difference and the result is a small circular patch of the terrain slightly above or below its surroundings. Dune crests are well marked by above-average roughness. Footprints and track marks are also visible, with lower roughness values.

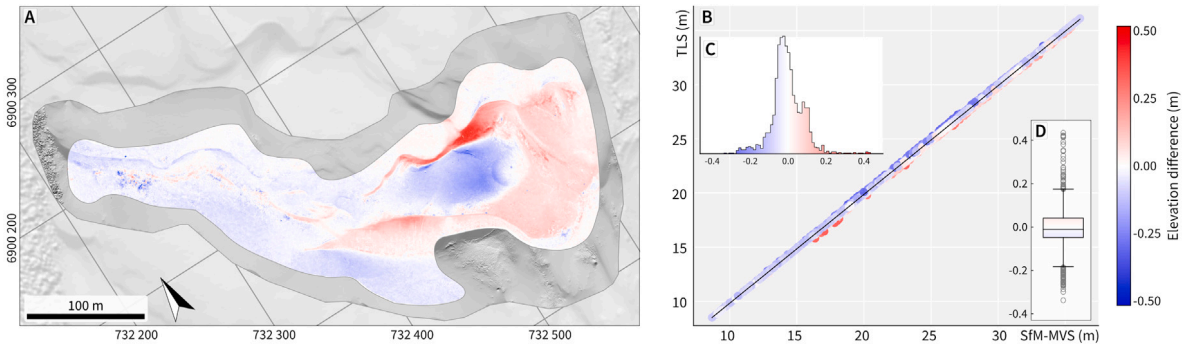

Fig. 6. Differences between TLS and SfM-MVS: (A) Map of difference values (all pixels); (B) Scatterplot; (C) Histogram (bins = 60); (D) Boxplot. Data for B,C,D from a set of 2000 random pixels.

The SfM-MVS DEM shows a widespread distribution of low and average roughness values (Fig. 5B). While the dune crests can be identified, track marks are no longer visible and the patch of vegetation near the sandboard tracks cannot be discriminated based on its roughness. A set of footprints seen in the central-eastern portion of the TLS roughness map is not visible in the SfM-MVS roughness because the SfM-MVS survey was carried out before the TLS survey could cover that area. We see this roughness as a noise inherent to the SfM process due to small errors in geolocation as well as to the consumer-grade quality of the photographic camera (Mosbrucker et al., 2016).

Applying the FPD algorithm to a sub-area of the SfM-MVS DEM shows the RMSE between the smoothed DEM and the TLS DEM decreasing with larger FPD kernel sizes and higher angular threshold values, but increasing with the number of interactions (Fig. 5C). Considering these results, we applied FPD to the SfM-MVS DEM with $k = 17 \times 17$ $t = 20°$ and $i = 5$ (Fig. 5D). An evaluation of Circular Variance of Aspect for each parameter leads to similar conclusions, and is presented in the Supplemental Material.

The vertical accuracy of the SfM-MVS DEM, calculated for all pixels within the mask shown in Fig. 6A resulted in RMSE of 0.08 m and MAE of 0.06 m for both the original and the FPD-filtered DEM.

Descriptive statistics of the TLS and SfM-MVS DEMs are very similar (Table 2). Considering all pixels of the DEMs, elevation differences range from −1.5 m to +0.5 m, with mean of 0.0 m and standard deviation of 0.08 m; with a random sample of 2000 pixels, elevation differences range from −0.3 m to +0.5 m, with mean of 0.0 m and standard deviation of 0.08 m. The negative differences below −0.5 m can be disregarded as they represent a small fraction of the total (312 pixels out of $\approx 4.8 \times 10^6$ pixels).

A scatterplot of elevations (2000 pixels, TLS × SfM-MVS, Fig. 6B) shows minimal dispersion of points, with an R^2 of 0.999 (see Supplemental Material). The histogram of differences (Fig. 6C) has a bimodal distribution, with ≈55% of the values below zero, indicating that, in general, the SfM-MVS DEM has higher elevations than the TLS DEM, and the boxplot of differences (Fig. 6D) shows 106 points classified as outliers (values beyond ±0.17 m).

3.2. ALS and SfM-MVS

Besides a good correlation to the TLS DEM, the full SfM-MVS DEM (Fig. 7B) shows a good fit with elements of the landscape that did not experienced significant change between the surveys, such as the road bordering the dune field to west and southwest (in grey in Fig. 7C, indicating no elevation difference).

Comparison of the 2010 ALS and 2019 SfM-MVS DEMs was carried out based on: (1) descriptive statistics of the DEMs; (2) differences between the DEMs; (3) sand volume within an area and (4) displacement of dune crests.

Differences between the DEMs were calculated by subtracting the elevations of the ALS DcrestEM from the SfM-MVS DEM. Positive values represent areas where the SfM surface has higher elevations than the ALS one, and vice-versa.

The ALS and SfM-MVS DEMs (0.5 m resolution) and the differences between the two surfaces, are presented in Fig. 7. In the studied area, dunes are mainly barchanoids with lee side towards south west. Elevation reaches its highest (≈58 m) in the southern portion, likely due the influence of an underlying palaeotopography (Giannini et al., 2007).

Descriptive statistics are presented in Table 3 and histograms of elevation values in Fig. 8. The DEM of differences between 2019 and 2010 DEMs is in Fig. 7C; positive values are in red and negative values in blue. Topographic profiles (location in Fig. 7B) are in Fig. 9.

The DEMs have similar values of maximum, standard deviation, skewness, kurtosis and quantiles. The SfM-MVS DEM shows slightly higher mean and minimum values. Elevation differences between the DEMs range from −16.95 m to +23.15 m, with mean and median of ≈0.0 ms. Some notable differences are indicated as #1,#2 and #3 in Fig. 7C: #1 marks the highest positive difference (where the SfM-MVS surface is above the ALS), related to the migration of a large 'central dune' with accumulation of sand towards a vegetated ridge in #2; #3 shows the migration of the dune field over the road. In this place, the town hall needs to remove the sand periodically to keep the road open.

The polygon for volume calculation encloses only unvegetated areas in both surveys (see Fig. 7A). Using the ALS and SfM DEMs with 0.5 m resolution, the calculated sand volumes were 9 035 115.45 m^3 for 2010 and 9 010 844.95 m^3 for 2019 (a decrease of 24 270.50 m^3 or 0.2%).

Dune crest displacement lines drawn over the DEMs (see Fig. 3) yielded a mean azimuth of 215.5° and mean length of ≈44.5 m (mean: 44.3 m, median: 44.7 m, see Supplemental Material for statistical analysis of azimuth and length).

A mean length of 44.5 m in 9 years corresponds to a dune migration rate of ≈5 m/year. We consider these rates to be in agreement with rates of 6–7 m/year from Mendes and Giannini (2015) and Mendes et al. (2015), which were derived from interpretation of historical aerial photographs and satellite images with coarser spatial resolution.

Topographic profiles (Fig. 9) illustrate dune movement from 2010 to 2019, with migration of the lee side and relatively less change over the stoss side of large compound dunes.

4. Discussions and conclusions

In this work we presented an evaluation of SfM-MVS in high-resolution topographic modelling of coastal sand dunes.

Although sand dunes are commonly regarded as a challenge to traditional photogrammetry due their homogeneous texture and spectral response, yielding poor results in image matching (Baltsavias, 1999), recent literature on close-range photogrammetry/SfM-MVS of coastal areas report good results in surface reconstruction (Gonçalves and

Table 2
Descriptive statistics of the TLS, SfM-MVS DEMs and of differences. Elevation units in metres (m).

	min	max	mean	median	std.dev.	skewness	kurtosis	25%quant.	75%quant.
All pixels									
TLS	8.490	36.172	23.937	24.753	6.519	−0.277	−0.750	18.708	28.712
SfM-MVS	8.440	36.153	23.938	24.774	6.531	−0.283	−0.754	18.691	28.713
SfM-MVS FPD	8.445	36.152	23.938	24.774	6.532	−0.283	−0.754	18.691	28.713
Diff. SfM TLS	−1.506	0.519	0.001	−0.008	0.085	0.701	4.801	−0.045	0.046
Diff. FPD TLS	−1.510	0.509	0.001	−0.008	0.085	0.703	4.849	−0.045	0.046
2000 pixels									
TLS	8.526	36.023	24.015	24.840	6.455	−0.277	−0.725	18.863	28.639
SfM-MVS	8.483	35.990	24.010	24.830	6.468	−0.281	−0.730	18.822	28.654
SfM-MVS FPD	8.477	35.989	24.010	24.826	6.468	−0.281	−0.729	18.824	28.654
Diff. SfM TLS	−0.338	0.434	−0.004	−0.012	0.084	0.344	3.172	−0.048	0.041
Diff. FPD TLS	−0.344	0.429	−0.004	−0.012	0.084	0.344	3.186	−0.048	0.042

Table 3
Descriptive statistics of the ALS, SfM-MVS DEMs and of differences between the two surfaces.

	min	max	mean	median	std.dev.	skewness	kurtosis	25%quant.	75%quant.
ALS	2.69	58.88	21.34	20.65	11.59	0.51	−0.41	11.64	28.77
SfM-MVS	2.89	58.63	21.64	20.67	11.66	0.45	−0.57	11.63	29.40
Diff.	−16.95	23.15	0.31	0.39	3.48	0.16	2.77	−1.26	1.80

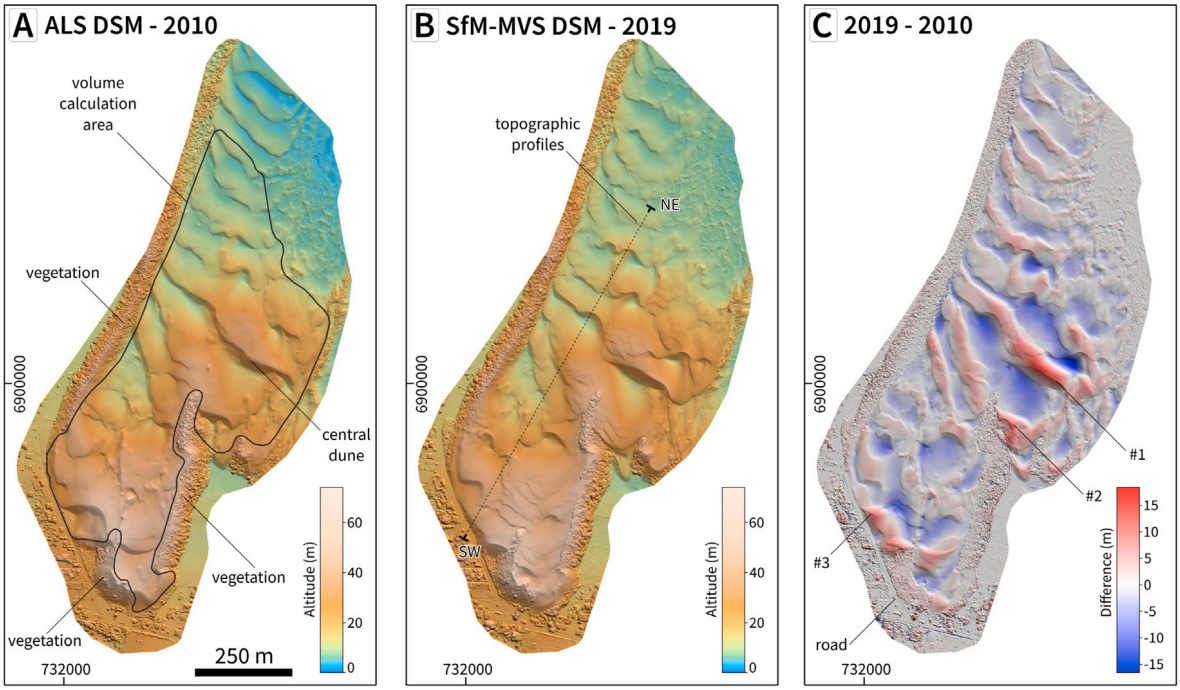

Fig. 7. (A) ALS DEM (2010), with volume calculation area polygon; (B) SfM-MVS DEM (2019), with topographic profiles location; (C) DEM of differences (2019–2010). Numbers in C are discussed in the text. (For interpretation of the references to colour in this figure legend, the reader is referred to the web version of this article.)

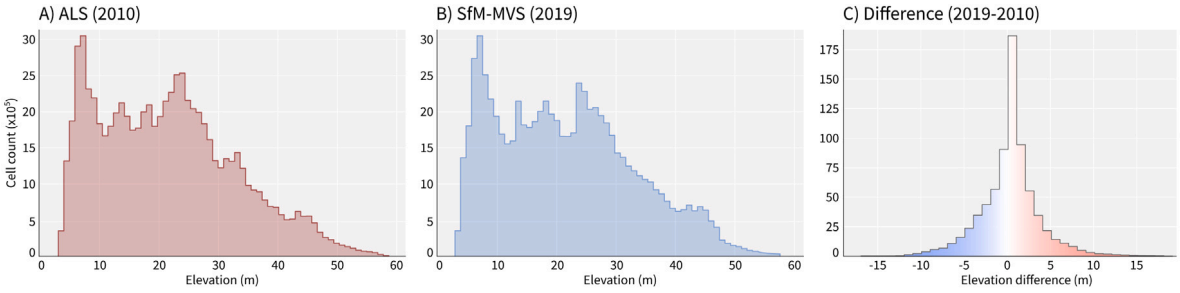

Fig. 8. Histograms: (A) ALS DEM (bins = 60); SfM-MVS DEM (bins = 60); (C) DEM of differences (bins = 40).

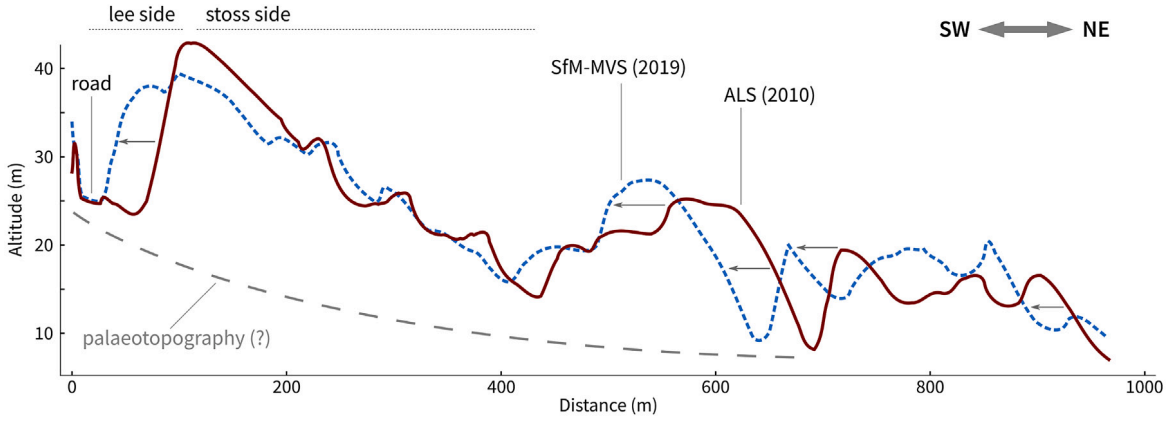

Fig. 9. Topographic profiles across the dune field (location in Fig. 7B.).

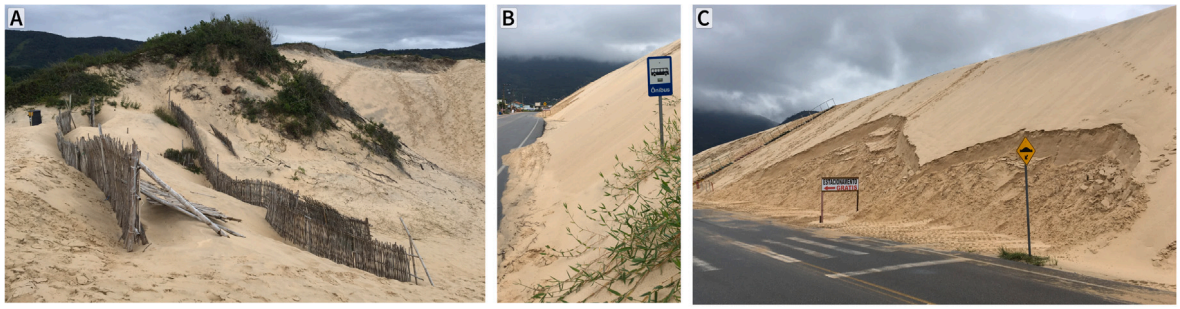

Fig. 10. (A) Sand fences installed to promote dune stabilization; (B, C) Front of the dune field showing migration over road and signs. Location of photos on Fig. 2B.

Henriques, 2015; Gonçalves et al., 2018; Duffy et al., 2018; Laporte-Fauret et al., 2019; van Puijenbroek et al., 2017; Guisado-Pintado et al., 2019; Pitman et al., 2019).

In this research, image matching was successful in all areas of the survey due the presence of superficial features (footprints and sandboard tracks) and visibility of the sedimentary stratification, highlighted by heavy minerals (Fig. 2C).

One factor that positively influenced the RPA survey was the weather. A cloudy sky provided a diffuse illumination, without 'hard' shadows, and the scattered light rain ensured that the sand was humid, without the presence of a layer of loose sand over the dunes, which would mask the stratifications and other features in the photos (Guisado-Pintado et al., 2019).

We believe that the lack of texture in aerial photographs and satellite images is more related to ground resolution (i.e., pixel size) than the spectral or morphological characteristics of aeolian dunes, as a pixel area of one square metre can be enough to 'average-out' small textural features and prevent good image matching. This is an issue to be seen in the context of the everlasting matter of scale in remote sensing and geomorphometry: pixel size *vs.* spatial structure (size) of landforms (e.g., Woodcock and Strahler, 1987; Wood, 1996; Gallant and Hutchinson, 1997; Goodchild and Quattrochi, 1997; Marceau and Hay, 1999; Hengl, 2006; Kamal et al., 2014). Large continental dunes, for instance, have been successfully modelled with 30 m-resolution images from Landsat and ASTER (Levin et al., 2004; Bullard et al., 2011).

To validate the use of an SfM-MVS DEM, a TLS DEM was used as reference for altimetric accuracy. The comparison resulted in RMSE of 0.08 m and MAE of 0.06 m. The TLS DEM has a smooth appearance, with well-marked dune crests and vegetated areas, while the SfM-MVS DEM shows a small-scale roughness that hinders visual identification of small features such as footprints.

Although it does not influence the comparison with ALS data, this roughness can be an issue if the objective of the research is the classification of landforms based on geomorphometric parameters, such as the identification of dune crests based on surface curvature (Mitasova et al., 2005b; Hardin et al., 2014). The FPD de-noise algorithm (Lindsay et al., 2019) was applied to the SfM-MVS DEM with good results in terms of surface smoothing, without any significant changes in descriptive statistics and error metrics.

Dune crests interpreted from the ALS DEM were compared to crests from the SfM-MVS DEM and resulted in a migration rate of ≈5 m/year, in good agreement with rates derived from satellite images and historical aerial photographs of the same area (Mendes and Giannini, 2015; Mendes et al., 2015).

Volumes calculated from the ALS and SfM-MVS DEMs show a difference of 0.2% between 2010 and 2019. Such small variation is within reported uncertainties for SfM-MVS reconstructions (Draeyer and Strecha, 2014; Rhodes, 2017; Gupta and Shukla, 2018) and may be related to the installation of sand fences to promote dune stabilization and the constant removal of sand from the road in front of the dune field (Fig. 10). Future studies can explore the spatial distribution of differences in the DEMs to evaluate the sedimentary budget (*influx–efflux*) of the dune field (Sankey et al., 2018a,b; Kasprak et al., 2019).

When comparing these different approaches to aeolian dune surface modelling (ALS, TLS and SfM-MVS) we must consider not only the accuracy of final products (DEMs), but also the time required to acquire the data and process it to a GIS-ready format.

ALS might be acquired in little time, but it is by far the most expensive, imposing a serious constrain on repeated surveys, especially for researchers in developing countries or without access to state-funded coastal monitoring programs.

TLS has an intermediate cost of acquisition (since the equipment can be rented and operated by the research team) but it demands more fieldwork and more processing time. In our case we needed three days for the TLS survey and around three weeks of full-time work to produce a DEM of ≈80 400 m^2.

SfM-MVS has gained attention recently for being a low-cost solution with fast and reliable results (James et al., 2019). We were able to cover

≈740 900 m^2 with six RPA missions in under three hours. Processing time in a medium-range workstation (i.e., i7 processor, 64 GB RAM, dedicated GPU) was ≈13 h. This makes it an excellent method for 3D modelling and continuous monitoring of coastal dunes.

One strength of the ALS over TLS and SfM-MVS is the possibility of removing the vegetation based on the laser returns or waveform (Brovelli and Cannata, 2004; Evans and Hudak, 2007; Khosravipour et al., 2016), although new methods are being developed for single-return point clouds (Guarnieri et al., 2009; Coveney et al., 2010; Coveney and Stewart Fotheringham, 2011; Montreuil et al., 2013; Pijl et al., 2020) that have been used in coastal environments with good results (Guisado-Pintado et al., 2019).

Another aspect to be considered is the weather. Dry and hot conditions will favour the presence of white sand patches, which can affect image matching and the 3D reconstruction. While clear sunny days might be seen by many as ideal conditions for fieldwork, flying the RPA with cloudy skies and after a light rain can be worthwhile due the scattered light and visibility of the dune's superficial features.

Computer code availability

Jupyter notebooks and associated data files (shapefiles and csv files) are available on GitHub (https://github.com/CarlosGrohmann/scripts_papers/tree/master/garopaba_als_sfm_tls) and Zenodo (https://doi.org/10.5281/zenodo.3476779). The notebooks are based on Python 3.6 and depend on the following libraries: numpy, scipy.stats, matplotlib, pandas, seaborn, rasterio, xarray, statsmodels, osgeo.ogr, pygrass and whiteboxtools.

Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Data availability

The point cloud datasets used in this study are available via the OpenTopography Facility[7] (Crosby et al., 2011; Krishnan et al., 2011). The following datasets were used: OpenTopography ID OT.032013.32722.1 (ALS – Grohmann, 2010; Grohmann and Sawakuchi, 2013), OTDS.072019.32722.1 (SfM – Grohmann, 2019), OTDS.102019.32722.1 (TLS – Grohmann et al., 2019).

Acknowledgements

This study was supported by the Sao Paulo Research Foundation (FAPESP), Brazil grants #2009/17675-5 and #2016/06628-0 and by Brazil's National Council of Scientific and Technological Development, CNPq grants #423481/2018-5 and #304413/2018-6 to C.H.G. This study was financed in part by CAPES Brasil - Finance Code 001 through PhD scholarships to G.P.B.G, A.A.A. and R.W.A. This work acknowledges the services provided by the OpenTopography Facility with support from the National Science Foundation, USA under NSF Award Numbers 1557484, 1557319, and 1557330. The authors are grateful to Clauson Lacerda and Rodrigo Correa (FARO Technologies Brasil), for their continuous support with terrestrial LiDAR data processing. John Lindsay (Un.Guelph) for discussions on FPD algorithm. Acknowledgements are extended to the Editor-in-Chief, the Associate Editor, and the anonymous reviewers for their criticism and suggestions, which helped to improve this paper.

[7] http://opentopo.sdsc.edu

Appendix A. Supplementary data

Supplementary material related to this article can be found online at https://doi.org/10.1016/j.cageo.2020.104569.

References

Angulo, R., Lessa, G., Souza, M., 2006. A critical review of mid-to late-holocene sea-level fluctuations on the eastern Brazilian coastline. Quat. Sci. Rev. 25 (5–6), 486–506.

Baade, J., Schmullius, C., 2016. Tandem-x IDEM precision and accuracy assessment based on a large assembly of differential GNSS measurements in kruger national park, south africa. ISPRS J. Photogramm. Remote Sens. 119, 496–508. http://dx.doi.org/10.1016/j.isprsjprs.2016.05.005.

Baltsavias, E.P., 1999. A comparison between photogrammetry and laser scanning. ISPRS J. Photogramm. Remote Sens. 54 (2–3), 83–94.

Bañón, L., Pagán, J.I., López, I., Banon, C., Aragonés, L., 2019. Validating UAS-based photogrammetry with traditional topographic methods for surveying dune ecosystems in the spanish mediterranean coast. J. Mar. Sci. Eng. 7 (9), http://dx.doi.org/10.3390/jmse7090297.

Barash, D., 2002. Fundamental relationship between bilateral filtering, adaptive smoothing, and the nonlinear diffusion equation. IEEE Trans. Pattern Anal. Mach. Intell. 24 (6), 844–847. http://dx.doi.org/10.1109/TPAMI.2002.1008390.

Barnes, N., 2010. Publish your computer code: it is good enough. Nature 467 (7317), 753. http://dx.doi.org/10.1038/467753a.

Baughman, C.A., Jones, B.M., Bodony, K.L., Mann, D.H., Larsen, C.F., Himelstoss, E., Smith, J., 2018. Remotely sensing the morphometrics and dynamics of a cold region dune field using historical aerial photography and airborne lidar data. Remote Sens. 10 (5), http://dx.doi.org/10.3390/rs10050792.

Berti, M., Corsini, A., Daehne, A., 2013. Comparative analysis of surface roughness algorithms for the identification of active landslides. Geomorphology 182, 1–18. http://dx.doi.org/10.1016/j.geomorph.2012.10.022, URL: http://www.sciencedirect.com/science/article/pii/S0169555X12004862.

Bhadra, B.K., Rehpade, S.B., Meena, H., Srinivasa Rao, S., 2019. Analysis of parabolic dune morphometry and its migration in thar desert area, India, using high-resolution satellite data and temporal DEM. J. Indian Soc. Remote Sens. http://dx.doi.org/10.1007/s12524-019-01050-1.

Bourke, M.C., Lancaster, N., Fenton, L.K., Parteli, E.J., Zimbelman, J.R., Radebaugh, J., 2010. Extraterrestrial dunes: An introduction to the special issue on planetary dune systems. Geomorphology 121 (1–2), 1–14. http://dx.doi.org/10.1016/j.geomorph.2010.04.007, URL: http://www.sciencedirect.com/science/article/pii/S0169555X10001868.

Brovelli, M.A., Cannata, M., 2004. Digital terrain model reconstruction in urban areas from airborne laser scanning data: the method and an example for pavia (northern Italy). Comput. Geosci. 30, 325–331. http://dx.doi.org/10.1016/j.cageo.2003.07.004.

Brovelli, M.A., Cannata, M., Longoni, U.M., 2004. LIDAR Data filtering and DTM interpolation within GRASS. Trans. GIS 8, 155–174. http://dx.doi.org/10.1111/j.1467-9671.2004.00173.x.

Bullard, J.E., White, K., Livingstone, I., 2011. Morphometric analysis of aeolian bedforms in the namib sand sea using ASTER data. Earth Surf. Process. Landforms 36 (11), 1534–1549. http://dx.doi.org/10.1002/esp.2189.

Casella, E., Drechsel, J., Winter, C., Benninghoff, M., Rovere, A., 2020. Accuracy of sand beach topography surveying by drones and photogrammetry. Geo-Mar. Lett. http://dx.doi.org/10.1007/s00367-020-00638-8.

Clemmensen, L.B., Bjørnsen, M., Murray, A., Pedersen, K., 2007. Formation of aeolian dunes on anholt, Denmark since AD 1560: A record of deforestation and increased storminess. Sediment. Geol. 199 (3–4), 171–187. http://dx.doi.org/10.1016/j.sedgeo.2007.01.025, URL: http://www.sciencedirect.com/science/article/pii/S0037073807000486.

Conlin, M., Cohn, N., Ruggiero, P., 2018. A quantitative comparison of low-cost structure from motion (sfm) data collection platforms on beaches and dunes. J. Coast. Res. 34 (6), 1341–1357. http://dx.doi.org/10.2112/JCOASTRES-D-17-00160.1.

Coveney, S., Fotheringham, A.S., Charlton, M., McCarthy, T., 2010. Dual-scale validation of a medium-resolution coastal DEM with terrestrial lidar DSM and GPS. Comput. Geosci. 36 (4), 489–499. http://dx.doi.org/10.1016/j.cageo.2009.10.003.

Coveney, S., Stewart Fotheringham, A., 2011. Terrestrial laser scan error in the presence of dense ground vegetation. Photogramm. Rec. 26 (135), 307–324. http://dx.doi.org/10.1111/j.1477-9730.2011.00647.x.

Crosby, C.J., Arrowsmith, R.J., Nandigam, V., Baru, C., 2011. In: Keller, G.R., Baru, C. (Eds.), Geoinformatics. Cambridge University Press, pp. 251–265. http://dx.doi.org/10.1017/CBO9780511976308.017.

Dillenburg, S., Tomazelli, L., Hesp, P., Barboza, E., Clerot, L., da Silva, D., 2006. Stratigraphy and evolution of a prograded transgressive dunefield barrier in southern Brazil. J. Coast. Res. 132–135, URL: http://www.jstor.org/stable/25741548.

Dong, P., 2015. Automated measurement of sand dune migration using multi-temporal lidar data and GIS. Int. J. Remote Sens. 36 (21), 5426–5447. http://dx.doi.org/10.1080/01431161.2015.1093192, arXiv:https://doi.org/10.1080/01431161.2015.1093192.

Draeyer, B., Strecha, C., 2014. White Paper: How Accurate are UAV Surveying Methods. Pix4D White Paper, URL: https://pdfs.semanticscholar.org/0dd7/1fdcaefbc22e54f2ba7f8bb0fa8af33edb4c.pdf.

Duffy, J.P., Shutler, J.D., Witt, M.J., DeBell, L., Anderson, K., 2018. Tracking fine-scale structural changes in coastal dune morphology using kite aerial photography and uncertainty-assessed structure-from-motion photogrammetry. Remote Sens. 10 (9), http://dx.doi.org/10.3390/rs10091494, URL: https://www.mdpi.com/2072-4292/10/9/1494.

Evans, J.S., Hudak, A.T., 2007. A multiscale curvature algorithm for classifying discrete return lidar in forested environments. IEEE Trans. Geosci. Remote Sens. 45, 1029–1038. http://dx.doi.org/10.1109/TGRS.2006.890412.

Fabbri, S., Giambastiani, B.M., Sistilli, F., Scarelli, F., Gabbianelli, G., 2017. Geomorphological analysis and classification of foredune ridges based on terrestrial laser scanning (TLS) technology. Geomorphology 295, 436–451. http://dx.doi.org/10.1016/j.geomorph.2017.08.003.

FARO Technologies Inc., 2013. User manual for the Focus3D 20/120 and S 20/120. URL: https://knowledge.faro.com/Hardware/3D_Scanners/Focus/User_Manual_for_the_Focus3D_20-120_and_S_20-120?mt-learningpath=focus3d_20-120_downloads (Last access: 01/Jul/2019).

Feagin, R.A., Williams, A.M., Popescu, S., Stukey, J., Washington-Allen, R.A., 2014. The use of terrestrial laser scanning (TLS) in dune ecosystems: The lessons learned. J. Coast. Res. 111–119. http://dx.doi.org/10.2112/JCOASTRES-D-11-00223.1.

Finkel, H.J., 1961. The movement of barchan dunes measured by aerial photogrammetry. Photogramm. Eng. 27, 439–444.

Fisher, N.I., 1993. Statistical Analysis of Circular Data. Cambridge Univ. Press, Cambridge.

Forlani, G., Dall'Asta, E., Diotri, F., Cella, U.M.d., Roncella, R., Santise, M., 2018. Quality assessment of DSMs produced from UAV flights georeferenced with on-board RTK positioning. Remote Sens. 10 (2), http://dx.doi.org/10.3390/rs10020311, URL: https://www.mdpi.com/2072-4292/10/2/311.

Fryberger, S.G., Dean, G., 1979. In: McKee, E.D. (Ed.), A Study of Global Sand Seas. volume Prof. Paper 1052, U.S. Geological Survey, pp. 137–169, chapter Dune forms and wind regime.

Gallant, J., 2011. Adaptive smoothing for noisy DEMs. In: Hengl, T., Evans, I.S., Wilson, J.P., Gould, M. (Eds.), Geomorphometry 2011. Redlands, CA, pp. 37–40.

Gallant, J., Hutchinson, M., 1997. Scale dependence in terrain analysis. Math. Comput. Simulation 43 (3), 313–322.

Garcin, M., Desmazes, F., Nicolae-Lerma, A., Gouguet, L., Metereau, V., 2019. Contribution of lightweight revolving laser scanner, hires UAV lidars and photogrammetry for characterization of coastal aeolian morphologies. http://dx.doi.org/10.13140/RG.2.2.30916.99207, preprint hosted by ResearchGate.

Gaylord, D.R., Foit, F.F., Schatz, J.K., Coleman, A.J., 2001. Smith canyon dune field, washington, U.S.A: relation to glacial outburst floods, the mazama eruption, and holocene paleoclimate. J. Arid Environ. 47 (4), 403–424. http://dx.doi.org/10.1006/jare.2000.0731.

GDAL Development Team, 2019. GDAL - Geospatial Data Abstraction Library, Version 2.4.1. Open Source Geospatial Foundation, Available at http://gdal.osgeo.org (last access 20-July-2019).

Gesch, D.B., Oimoen, M.J., Danielson, J.J., Meyer, D., 2016. Validation of the ASTER global digital elevation model version 3 over the conterminous United States. Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. XLI-B4, 143–148, URL: http://pubs.er.usgs.gov/publication/70175051.

Giannini, P.C.F., Sawakuchi, A.O., Martinho, C.T., Tatumi, S.H., 2007. Eolian depositional episodes controlled by late quaternary relative sea level changes on the imbituba-laguna coast (southern Brazil). Mar. Geol. 237, 143–168.

Gillies, S., et al., 2013. Rasterio: geospatial raster I/O for Python programmers. Mapbox, URL: https://github.com/mapbox/rasterio.

Gonçalves, J., Henriques, R., 2015. Uav photogrammetry for topographic monitoring of coastal areas. ISPRS J. Photogramm. Remote Sens. 104, 101–111. http://dx.doi.org/10.1016/j.isprsjprs.2015.02.009.

Gonçalves, G.R., Pérez, J.A., Duarte, J., 2018. Accuracy and effectiveness of low cost UASs and open source photogrammetric software for foredunes mapping. Int. J. Remote Sens. 39 (15–16), 5059–5077. http://dx.doi.org/10.1080/01431161.2018.1446568, arXiv:https://doi.org/10.1080/01431161.2018.1446568.

Goodchild, M., Quattrochi, D., 1997. In: Quattrochi, D., Goodchild, M. (Eds.), Scale in Remote Sensing and GIS. CRC Press, pp. 1–12.

GRASS Development Team, 2019. Geographic Resources Analysis Support System (GRASS GIS) Software, Version 7.6. Open Source Geospatial Foundation, URL: http://grass.osgeo.org.

Grohmann, C.H., 2004. Morphometric analysis in geographic information systems: applications of free software GRASS and r. Comput. Geosci. 30, 1055–1067. http://dx.doi.org/10.1016/j.cageo.2004.08.002.

Grohmann, C.H., 2010. Coastal Dune Fields of Garopaba and Vila Nova, Santa Catarina State, Brazil. Airborne LiDAR. Data provided by FAPESP grant #2009/17675-5, distributed by OpenTopography, http://dx.doi.org/10.5069/G9DN430Z, OT Collection ID: OT.032013.32722.1.

Grohmann, C.H., 2018. Evaluation of tandem-x DEMs on selected Brazilian sites: Comparison with srtm, ASTER GDEM and ALOS aw3D30. Remote Sens. Environ. 212, 121–133. http://dx.doi.org/10.1016/j.rse.2018.04.043.

Grohmann, C.H., 2019. Garopaba Dune Field, Santa Catarina State, Brazil. SfM-MVS point cloud. Data provided by FAPESP grant #2016/06628-0, distributed by OpenTopography, http://dx.doi.org/10.5069/G9DV1H19, opentopoID: OTDS.072019.32722.1.

Grohmann, C.H., Garcia, G.P.B., Affonso, A.A., Albuquerque, R.W., 2019. Garopaba Dune Field, Santa Catarina State, Brazil. TLS point cloud. Data provided by FAPESP grant #2016/06628-0, distributed by OpenTopography, http://dx.doi.org/10.5069/G9CN7228, opentopoID: OTDS.102019.32722.1.

Grohmann, C.H., Hargitai, H., 2014. Surface roughness. In: Encyclopedia of Planetary Landforms. Springer New York, pp. 1–4. http://dx.doi.org/10.1007/978-1-4614-9213-9_633-1.

Grohmann, C.H., Riccomini, C., 2009. Comparison of roving-window and search-window techniques for characterising landscape morphometry. Comput. Geosci. 35, 2164–2169. http://dx.doi.org/10.1016/j.cageo.2008.12.014.

Grohmann, C.H., Sawakuchi, A.O., 2013. Influence of cell size on volume calculation using digital terrain models: A case of coastal dune fields. Geomorphology 180–181 (1), 130–136. http://dx.doi.org/10.1016/j.geomorph.2012.09.012.

Grohmann, C.H., Smith, M.J., Riccomini, C., 2010. Multiscale analysis of topographic surface roughness in the midland valley, Scotland. IEEE Trans. Geosci. Remote Sens. 49 (4), 1200–1213. http://dx.doi.org/10.1109/TGRS.2010.2053546.

Guarnieri, A., Vettore, A., Pirotti, F., Menenti, M., Marani, M., 2009. Retrieval of small-relief marsh morphology from terrestrial laser scanner, optimal spatial filtering, and laser return intensity. Geomorphology 113 (1), 12–20. http://dx.doi.org/10.1016/j.geomorph.2009.06.005, Understanding earth surface processes from remotely sensed digital terrain models.

Guisado-Pintado, E., Jackson, D., Rogers, D., 2019. 3D mapping efficacy of a drone and terrestrial laser scanner over a temperate beach-dune zone. Geomorphology 328, 157–172. http://dx.doi.org/10.1016/j.geomorph.2018.12.013.

Gupta, S.K., Shukla, D.P., 2018. Application of drone for landslide mapping, dimension estimation and its 3D reconstruction. J. Indian Soc. Remote Sens. 46 (6), 903–914. http://dx.doi.org/10.1007/s12524-017-0727-1.

Hardin, E., Mitasova, H., Tateosian, L., Overton, M., 2014. GIS-based Analysis of Coastal Lidar Time-Series. Springer New York, http://dx.doi.org/10.1007/978-1-4939-1835-5.

Harwin, S., Lucieer, A., Osborn, J., 2015. The impact of the calibration method on the accuracy of point clouds derived using unmanned aerial vehicle multi-view stereopsis. Remote Sens. 7 (9), 11933–11953. http://dx.doi.org/10.3390/rs70911933, URL: https://www.mdpi.com/2072-4292/7/9/11933.

Hayes, A., 2018. Dunes across the solar system. Science 360 (6392), 960–961. http://dx.doi.org/10.1126/science.aat7488, cited By 1.

Hayward, R., Mullins, K., Fenton, L., Hare, T., Titus, T., Bourke, M., Colaprete, A., Christensen, P., 2007. Mars global digital dune database and initial science results. J. Geophys. Res. 112, E11007. http://dx.doi.org/10.1029/2007JE002943.

Hebeler, F., Purves, R.S., 2009. The influence of elevation uncertainty on derivation of topographic indices. Geomorphology 111, 4–16.

Hengl, T., 2006. Finding the right pixel size. Comput. Geosci. 32 (9), 1283–1298.

Hengl, T., Reuter, H.I., 2008. In: Hengl, T., Reuter, H.I. (Eds.), Geomorphometry: Concepts, Software, Applications. In: Developments in Soil Science, vol. 33, Elsevier, Amsterdam, p. 772.

Hesp, P., Abreu de Castilhos, J., Miot da Silva, G., Dillenburg, S., Martinho, C.T., Aguiar, D., Fornari, M., Fornari, M., Antunes, G., 2007. Regional wind fields and dunefield migration, southern Brazil. Earth Surf. Process. Landforms 32 (4), 561–573. http://dx.doi.org/10.1002/esp.1406.

Hinthorne, J., 1988. R.volume GRASS-GIS module. URL: http://grass.osgeo.org/grass64/manuals/html64_user/r.volume.html (accessed 05 December 2011).

Hoover, R.H., Gaylord, D.R., Cooper, C.M., 2018. Dune mobility in the st. anthony dune field, idaho, USA: Effects of meteorological variables and lag time. Geomorphology 309, 29–37. http://dx.doi.org/10.1016/j.geomorph.2018.02.018.

Hugenholtz, C.H., Barchyn, T.E., 2010. Spatial analysis of sand dunes with a new global topographic dataset: new approaches and opportunities. Earth Surf. Process. Landforms 35 (8), 986–992. http://dx.doi.org/10.1002/esp.2013.

Hunter, J.D., 2007. Matplotlib: A 2d graphics environment. Comput. Sci. Eng. 9 (3), 90–95. http://dx.doi.org/10.1109/MCSE.2007.55.

Isenburg, M., 2019. Lastools - efficient lidar processing software (version 190623, unlicensed). obtained from http://rapidlasso.com/LAStools.

James, M.R., Chandler, J.H., Eltner, A., Fraser, C., Miller, P.E., Mills, J.P., Noble, T., Robson, S., Lane, S.N., 2019. Guidelines on the use of structure-from-motion photogrammetry in geomorphic research. Earth Surf. Process. Landforms 44 (10), 2081–2084. http://dx.doi.org/10.1002/esp.4637, arXiv:https://onlinelibrary.wiley.com/doi/pdf/10.1002/esp.4637.

James, M.R., Robson, S., 2014. Mitigating systematic error in topographic models derived from UAV and ground-based image networks. Earth Surf. Process. Landforms 39 (10), 1413–1420. http://dx.doi.org/10.1002/esp.3609, ESP-14-0032.R2.

Judge, E.K., Courtney, M.G., Overton, M.F., 2000. Topographic analysis of dune volume and position, jockey's ridge state park, north carolina. Shore Beach 68 (4), 19–24.

Kamal, M., Phinn, S., Johansen, K., 2014. Characterizing the spatial structure of mangrove features for optimizing image-based mangrove mapping. Remote Sens. 6 (2), 984–1006. http://dx.doi.org/10.3390/rs6020984.

Kasprak, A., Bransky, N.D., Sankey, J.B., Caster, J., Sankey, T.T., 2019. The effects of topographic surveying technique and data resolution on the detection and interpretation of geomorphic change. Geomorphology 333, 1–15. http://dx.doi.org/10.1016/j.geomorph.2019.02.020.

Khosravipour, A., Skidmore, A.K., Isenburg, M., 2016. Generating spike-free digital surface models using lidar raw point clouds: A new approach for forestry applications. Int. J. Appl. Earth Obs. Geoinf. 52, 104–114. http://dx.doi.org/10.1016/j.jag.2016.06.005.

Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B., Bussonnier, M., Frederic, J., Kelley, K., Hamrick, J., Grout, J., Corlay, S., Ivanov, P., Avila, D., Abdalla, S., Willing, C., 2016. In: Loizides, F., Schmidt, B. (Eds.), Positioning and Power in Academic Publishing: Players, Agents and Agendas. IOS Press, pp. 87–90. http://dx.doi.org/10.3233/978-1-61499-649-1-87.

Kreslavsly, M.A., Bondarenko, N.V., 2017. Aeolian sand transport and aeolian deposits on venus: A review. Aeolian Res. 26, 29–46. http://dx.doi.org/10.1016/j.aeolia.2016.06.001, cited By 4.

Krishnan, S., Crosby, C., Nandigam, V., Phan, M., Cowart, C., Baru, C., Arrowsmith, R., 2011. Opentopography: a services oriented architecture for community access to LIDAR topography. In: Proceedings of the 2nd International Conference on Computing for Geospatial Research & Applications. In: COM.Geo '11, ACM, New York, NY, USA, pp. 7:1–7:8. http://dx.doi.org/10.1145/1999320.1999327.

Łabuz, T.A., 2016. A review of field methods to survey coastal dunes—experience based on research from south baltic coast. J. Coast. Conserv. 20 (2), 175–190. http://dx.doi.org/10.1007/s11852-016-0428-x.

Laporte-Fauret, Q., Marieu, V., Castelle, B., Michalet, R., Bujan, S., Rosebery, D., 2019. Low-cost UAV for high-resolution and large-scale coastal dune change monitoring using photogrammetry. J. Mar. Sci. Eng. 7 (3), http://dx.doi.org/10.3390/jmse7030063.

Lee, Y.-K., Eom, J., Do, J.-D., amd Joo-Hyung Ryu, B.-J.K., 2019. Shoreline movement monitoring and geomorphologic changes of beaches using lidar and UAVs images on the coast of the east sea, Korea. J. Coast. Res. 90 (sp1), 409–414–6. http://dx.doi.org/10.2112/SI90-052.1.

Levin, N., 2011. Climate-driven changes in tropical cyclone intensity shape dune activity on earth's largest sand island. Geomorphology 125 (1), 239–252. http://dx.doi.org/10.1016/j.geomorph.2010.09.021, URL: http://www.sciencedirect.com/science/article/pii/S0169555X10004149.

Levin, N., Dor, B.E., Karnieli, A., 2004. Topographic information of sand dunes as extracted from shading effects using landsat images. Remote Sens. Environ. 90 (2), 190–209.

Lindsay, J.B., 2017. Whiteboxtools user manual. Available online: https://jblindsay.github.io/wbt_book/preface.html (accessed on 01 march 2020).

Lindsay, J.B., Francioni, A., Cockburn, J.M.H., 2019. Lidar DEM smoothing and the preservation of drainage features. Remote Sens. 11 (16), http://dx.doi.org/10.3390/rs11161926.

Livingstone, I., Wiggs, G.F., Weaver, C.M., 2007. Geomorphology of desert sand dunes: A review of recent progress. Earth-Sci. Rev. 80 (3–4), 239–257. http://dx.doi.org/10.1016/j.earscirev.2006.09.004, URL: http://www.sciencedirect.com/science/article/pii/S0012825206001449.

Mancini, F., Dubbini, M., Gattelli, M., Stecchi, F., Fabbri, S., Gabbianelli, G., 2013. Using unmanned aerial vehicles (UAV) for high-resolution reconstruction of topography: The structure from motion approach on coastal environments. Remote Sens. 5 (12), 6880–6898. http://dx.doi.org/10.3390/rs5126880.

Marceau, D.J., Hay, G.J., 1999. Remote sensing contributions to the scale issue. Canad. J. Remote Sens. 25 (4), 357–366.

Martinho, C.T., Giannini, P.C.F., Sawakuchi, A.O., Hesp, P.A., 2006. Morphological and depositional facies of transgressive dunefields in the imbituba-jaguaruna region, santa catarina state. J. Coast. Res. SI39, 143–168.

Martinho, C.T., Hesp, P.A., Dillenburg, S.R., 2010. Morphological and temporal variations of transgressive dunefields of the northern and mid-littoral rio grande do sul coast, southern Brazil. Geomorphology 117 (1–2), 14–32. http://dx.doi.org/10.1016/j.geomorph.2009.11.002, URL: http://www.sciencedirect.com/science/article/pii/S0169555X0900467X.

McKinney, W., 2011. Pandas: a foundational python library for data analysis and statistics. In: Python for High Performance and Scientific Computing. pp. 1–9.

Mendes, V.R., Giannini, P.C.F., 2015. Coastal dunefields of south Brazil as a record of climatic changes in the south American monsoon system. Geomorphology 246, 22–34. http://dx.doi.org/10.1016/j.geomorph.2015.05.034.

Mendes, V.R., Giannini, P.C.F., Guedes, C.C.F., DeWitt, R., de Abreu Andrade, H.A., 2015. Central santa catarina coastal dunefields chronology and their relation to relative sea level and climatic changes. Braz. J. Geol. 45, 79–95. http://dx.doi.org/10.1590/2317-4889201530143.

Mitasova, H., Drake, T.G., Bernstein, D., Harmon, R.S., 2004. Quantifying rapid changes in coastal topography using modern mapping techniques and geographic information system. Environ. Eng. Geosci. 10, 1–11. http://dx.doi.org/10.2113/10.1.1.

Mitasova, H., Mitas, L., Harmon, R.S., 2005a. Simultaneous spline approximation and topographic analysis for lidar elevation data in open source GIS. IEEE Geosci. Remote Sens. Lett. 2, 375–379. http://dx.doi.org/10.1109/LGRS.2005.848533.

Mitasova, H., Overton, M., Harman, R.S., 2005b. Geospatial analysis of a coastal sand dune field evolution: Jockey's ridge, north carolina. Geomorphology 72, 204–221. http://dx.doi.org/10.1016/j.geomorph.2005.06.001.

Montreuil, A.-L., Bullard, J., Chandler, J., 2013. Detecting seasonal variations in embryo dune morphology using a terrestrial laser scanner. J. Coast. Res. 65 (SIv2), 1313–1318. http://dx.doi.org/10.2112/SI65-222.1.

Mosbrucker, A.R., Major, J.J., Spicer, K.R., Pitlick, J., 2016. Camera system considerations for geomorphic applications of sfm photogrammetry. Earth Surf. Process. Landforms n/a–n/a. http://dx.doi.org/10.1002/esp.4066, ESP-14-0305.R3.

Neteler, M., Bowman, M.H., Landa, M., Metz, M., 2012. Grass GIS: A multi-purpose open source GIS. Environ. Model. Softw. 31, 124–130. http://dx.doi.org/10.1016/j.envsoft.2011.11.014.

Nikolakopoulos, K.G., Kamaratakis, E.K., Chrysoulakis, N., 2006. SRTM Vs. ASTER elevation products. comparison for two regions in crete, grece. Int. J. Remote Sens. 27, 4819–4838.

O'Dea, A., Brodie, K.L., Hartzell, P., 2019. Continuous coastal monitoring with an automated terrestrial lidar scanner. J. Mar. Sci. Eng. 7 (2), http://dx.doi.org/10.3390/jmse7020037.

Oliphant, T., 2006. Guide to NumPy. Trelgol Publishing, URL: http://www.tramy.us/.

Pagán, J., Bañón, L., López, I., Bañón, C., Aragonés, L., 2019. Monitoring the dune-beach system of guardamar del segura (Spain) using uav, sfm and GIS techniques. Sci. Total Environ. 687, 1034–1045. http://dx.doi.org/10.1016/j.scitotenv.2019.06.186.

Pardo-Pascual, J., García-Asenjo, L., Palomar-Vázquez, J., Garrigues-Talens, P., 2005. New methods and tools to analyze beach-dune system evolution using a real-time kinematic global positioning system and geographic information systems. J. Coast. Res. 34–39, http://www.jstor.org/stable/25737401.

Pijl, A., Bailly, J.-S., Feurer, D., Maaoui, M.A.E., Boussema, M.R., Tarolli, P., 2020. TERRA: Terrain extraction from elevation rasters through repetitive anisotropic filtering. Int. J. Appl. Earth Obs. Geoinf. 84, 101977. http://dx.doi.org/10.1016/j.jag.2019.101977.

Pike, R.J., 1995. Geomophometry – progress, practice, and prospect. Z. Geomorphol. Suppl.-Bd. 101, 221–238.

Pike, R.J., Evans, I.S., Hengl, T., 2009. Chapter 1. geomorphometry: a brief guide. In: Hengl, T., Reuter, H.I. (Eds.), Geomorphometry: Concepts, Software, Applications. In: Developments in Soil Science, vol. 33, Elsevier, Amsterdam, pp. 3–30. http://dx.doi.org/10.1016/S0166-2481(08)00001-9.

Pitman, S.J., Hart, D.E., Katurji, M.H., 2019. Application of UAV techniques to expand beach research possibilities: a case study of coarse clastic beach cusps. Cont. Shelf Res. 184, 44–53. http://dx.doi.org/10.1016/j.csr.2019.07.008.

Potts, L.V., Akyilmaz, O., Braun, A., Shum, C.K., 2008. Multi-resolution dune morphology using shuttle radar topography mission (SRTM) and dune mobility from fuzzy inference systems using SRTM and altimetric data. Int. J. Remote Sens. 29 (10), 2879–2901. http://dx.doi.org/10.1080/01431160701408352.

van Puijenbroek, M.E.B., Nolet, C., de Groot, A.V., Suomalainen, J.M., Riksen, M.J.P.M., Berendse, F., Limpens, J., 2017. Exploring the contributions of vegetation and dune size to early dune development using unmanned aerial vehicle (UAV) imaging. Biogeosciences 14 (23), 5533–5549. http://dx.doi.org/10.5194/bg-14-5533-2017.

Python Software Foundation, 2019. Python programming language, version 3.7.4. Available at http://www.python.org/ (last access 20-Jan-2020).

QGIS Development Team, 2019. QGIS Geographic information system, version 3.8. URL: http://qgis.org Available at http://qgis.org (last access 20-July-2019).

Radebaugh, J., Lorenz, R., Lunine, J., Wall, S., Boubin, G., Reffet, E., Kirk, R., Lopes, R., Stofan, E., Soderblom, L., Allison, M., Janssen, M., Paillou, P., Callahan, P., Spencer, C., the Cassini Radar Team, 2008. Dunes on titan observed by cassini radar. Icarus 194 (2), 690–703. http://dx.doi.org/10.1016/j.icarus.2007.10.015, URL: http://www.sciencedirect.com/science/article/pii/S001910350700512X.

Reuter, H.I., Hengl, T., Gessler, P., Soille, P., 2009. Chapter 4 preparation of DEMs for geomorphometric analysis. In: Hengl, T., Reuter, H.I. (Eds.), Geomorphometry: Concepts, Software, Applications. In: Developments in Soil Science, vol. 33, Elsevier, Amsterdam, pp. 87–120. http://dx.doi.org/10.1016/S0166-2481(08)00004-4.

Rhodes, R.K., 2017. UAS as an Inventory Tool: A Photogrammetric Approach to Volume EstimationRichard Kramer Rhodes. (Master's thesis). University of Arkansas, Fayetteville, URL: https://scholarworks.uark.edu/etd/2424.

Rule, A., Tabard, A., Hollan, J.D., 2018. Exploration and explanation in computational notebooks. In: Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems. In: CHI '18, ACM, New York, NY, USA, pp. 32:1–32:12. http://dx.doi.org/10.1145/3173574.3173606.

Sankey, J.B., Caster, J., Kasprak, A., East, A.E., 2018a. The response of source-bordering aeolian dunefields to sediment-supply changes 2: Controlled floods of the colorado river in grand canyon, arizona, USA. Aeolian Res. 32, 154–169. http://dx.doi.org/10.1016/j.aeolia.2018.02.004.

Sankey, J.B., Kasprak, A., Caster, J., East, A.E., Fairley, H.C., 2018b. The response of source-bordering aeolian dunefields to sediment-supply changes 1: Effects of wind variability and river-valley morphodynamics. Aeolian Res. 32, 228–245. http://dx.doi.org/10.1016/j.aeolia.2018.02.005.

Satge, F., Denezine, M., Pillco, R., Timouk, F., Pinel, S., Molina, J., Garnier, J., Seyler, F., Bonnet, M.-P., 2016. Absolute and relative height-pixel accuracy of SRTM-gl1 over the south American andean plateau. ISPRS J. Photogramm. Remote Sens. 121, 157–166. http://dx.doi.org/10.1016/j.isprsjprs.2016.09.003.

Sawakuchi, A.O., Kalchgruber, R., Giannini, P.C.F., Nascimento Jr, D.R., Guedes, C.C.F., Umisedo, N.K., 2008. The development of blowouts and foredunes in the ilha comprida barrier (southeastern Brazil): the influence of late holocene climate changes on coastal sedimentation. Quat. Sci. Rev. 27, 2076–2090.

Seymour, A., Ridge, J., Rodriguez, A., Newton, E., Dale, J., Johnston, D., 2018. Deploying fixed wing unoccupied aerial systems (UAS) for coastal morphology assessment and management. J. Coast. Res. 34 (3), 704–717. http://dx.doi.org/10.2112/JCOASTRES-D-17-00088.1.

Short, A.D., 1988. Holocene coastal dune formation in southern Australia: A case study. Sediment. Geol. 55 (1–2), 121–142. http://dx.doi.org/10.1016/0037-0738(88)90093-0, URL: http://www.sciencedirect.com/science/article/pii/0037073888900930.

Shrestha, R.L., Carter, W.E., Sartori, M., Luzum, B.J., Slatton, K.C., 2005. Airborne laser swath mapping: Quantifying changes in sandy beaches over time scales of weeks to years. ISPRS J. Photogramm. Remote Sens. 59 (4), 222–232.

Singhvi, A., Williams, M., Rajaguru, S., Misra, V., Chawla, S., Stokes, S., Chauhan, N., Francis, T., Ganjoo, R., Humphreys, G., 2010. A ~200ka record of climatic change and dune activity in the thar desert, India. Quat. Sci. Rev. 29 (23–24), 3095–3105. http://dx.doi.org/10.1016/j.quascirev.2010.08.003, URL: http://www.sciencedirect.com/science/article/pii/S027737911000291X.

Smith, M.W., 2014. Roughness in the earth sciences. Earth-Sci. Rev. 136, 202–225. http://dx.doi.org/10.1016/j.earscirev.2014.05.016, URL: http://www.sciencedirect.com/science/article/pii/S0012825214001081.

Smith, M.W., Vericat, D., 2015. From experimental plots to experimental landscapes: topography, erosion and deposition in sub-humid badlands from structure-from-motion photogrammetry. Earth Surf. Process. Landforms 40 (12), 1656–1671. http://dx.doi.org/10.1002/esp.3747.

Solazzo, D., Sankey, J., Sankey, T., Munson, S., 2018. Mapping and measuring aeolian sand dunes with photogrammetry and lidar from unmanned aerial vehicles (UAV) and multispectral satellite imagery on the paria plateau, az, USA. Geomorphology 319, 174–185. http://dx.doi.org/10.1016/j.geomorph.2018.07.023.

Stafford, D.B., Langfelder, J., 1971. Air photo survey of coastal erosion. Photogramm. Eng. 37 (6), 565–575.

Stevenson, J.A., Sun, X., Mitchell, N.C., 2010. Despeckling SRTM and other topographic data with a denoising algorithm. Geomorphology 114 (3), 238–252. http://dx.doi.org/10.1016/j.geomorph.2009.07.006.

Sun, X., Rosin, P., Martin, R., Langbein, F., 2007. Fast and effective feature-preserving mesh denoising. IEEE Trans. Vis. Comput. Graphics 13 (5), 925–938. http://dx.doi.org/10.1109/TVCG.2007.1065.

Taddia, Y., Corbau, C., Zambello, E., Pellegrinelli, A., 2019. UAVS for structure-from-motion coastal monitoring: A case study to assess the evolution of embryo dunes over a two-year time frame in the po river delta, Italy. Sensors (Switzerland) 19 (7), http://dx.doi.org/10.3390/s19071717.

Telfer, M.W., Parteli, E.J., Radebaugh, J., Beyer, R.A., Bertrand, T., Forget, F., Nimmo, F., Grundy, W.M., Moore, J.M., Stern, S.A., et al., 2018. Dunes on pluto. Science 360 (6392), 992–997. http://dx.doi.org/10.1126/science.aao2975.

The SciPy community, 2013. Scipy reference guide – release 0.13.0. URL: http://docs.scipy.org/doc/scipy/scipy-ref.pdf.

Truccolo, E.C., 2011. Assessment of the wind behavior in the northern coast of santa catarina. Rev. Bras. Meteorol. 26, 451–460. http://dx.doi.org/10.1590/S0102-77862011000300011.

Tsoar, H., Levin, N., Porat, N., Maia, L.P., Herrmann, H.J., Tatumi, S.H., Claudino-Sales, V., 2009. The effect of climate change on the mobility and stability of coastal sand dunes in Ceará State (NE Brazil). Quat. Res. 71 (2), 217–226. http://dx.doi.org/10.1016/j.yqres.2008.12.001, URL: http://www.sciencedirect.com/science/article/pii/S0033589408001464.

Viana, C.D., Grohmann, C.H., Busarello, M., Garcia, G.P.B., 2018. Structural analysis of clastic dikes using structure from motion - multi-view stereo: a case-study in the Paraná Basin, southeastern Brazil. Braz. J. Geol. 48, 839–852. http://dx.doi.org/10.1590/2317-4889201800201898.

Vianna, H., Calliari, L., 2015. Variabilidade do sistema praia-dunas frontais para o litoral norte do rio grande do sul (palmares do sul a torres, brasil) com o auxílio do Light Detection and Ranging – Lidar. Pesqui. Geociências 42 (2), 141–158. http://dx.doi.org/10.22456/1807-9806.78116, URL: https://seer.ufrgs.br/PesquisasemGeociencias/article/view/78116.

Wang, X., Dong, Z., Zhang, J., Chen, G., 2002. Geomorphology of sand dunes in the northeast taklimakan desert. Geomorphology 42 (3–4), 183–195. http://dx.doi.org/10.1016/S0169-555X(01)00085-X, URL: http://www.sciencedirect.com/science/article/pii/S0169555X0100085X.

Waskom, M., Botvinnik, O., drewokane, Hobson, P., David, Halchenko, Y., Lukauskas, S., Cole, J.B., Warmenhoven, J., de Ruiter, J., Hoyer, S., Vanderplas, J., Villalba, S., Kunter, G., Quintero, E., Martin, M., Miles, A., Meyer, K., Augspurger, T., Yarkoni, T., Bachant, P., Williams, M., Evans, C., Fitzgerald, C., Brian, Wehner, D., Hitz, G., Ziegler, E., Qalieh, A., Lee, A., 2016. Seaborn: v0.7.1 (june 2016). http://dx.doi.org/10.5281/zenodo.54844.

Wechsler, S.P., 2007. Uncertainties associated with digital elevation models for hydrologic applications: a review. Hydrol. Earth Syst. Sci. 11 (4), 1481–1500. http://dx.doi.org/10.5194/hess-11-1481-2007.

Westoby, M.J., Brasington, J., Glasser, N.F., Hambrey, M.J., Reynolds, J.M., 2012. 'Structure-from-motion' photogrammetry: A low-cost, effective tool for geoscience applications. Geomorphology 179, 300–314. http://dx.doi.org/10.1016/j.geomorph.2012.08.021.

Willmott, C.J., Matsuura, K., 2005. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. Clim. Res. 30 (1), 79–82. http://dx.doi.org/10.3354/cr030079.

Willmott, C.J., Matsuura, K., 2006. On the use of dimensioned measures of error to evaluate the performance of spatial interpolators. Int. J. Geogr. Inf. Sci. 20 (1), 89–102. http://dx.doi.org/10.1080/13658810500286976.

Wood, J., 1996. Scale-based characterization of digital elevation models. In: Parker, D. (Ed.), Innovations in GIS 3. Taylor and Francis, London, (Chapter 13).

Woodcock, C.E., Strahler, A.H., 1987. The factor of scale in remote sensing. Remote Sens. Environ. 21 (3), 311–332. http://dx.doi.org/10.1016/0034-4257(87)90015-0.

Yang, J., Dong, Z., Liu, Z., Shi, W., Chen, G., Shao, T., Zeng, H., 2019. Migration of barchan dunes in the western quruq desert, northwestern China. Earth Surf. Process. Landforms 44 (10), 2016–2029. http://dx.doi.org/10.1002/esp.4629, arXiv:https://onlinelibrary.wiley.com/doi/pdf/10.1002/esp.4629.

Zambelli, P., Gebbert, S., Ciolli, M., 2013. Pygrass: An object oriented python application programming interface (API) for geographic resources analysis support system (GRASS) geographic information system (GIS). ISPRS Int. J. Geo-Inf. 2 (1), 201–219. http://dx.doi.org/10.3390/ijgi2010201.

Anexo G. Trabalho de conclusão de curso apresentado ao departamento de ciências contábeis da Faculdade de Economia, Administração, Contabilidade e Atuária da Universidade de São Paulo

Anexo G.1. *Os desafios dos escritórios de contabilidade para garantir a conformidade com a Lei Geral de Proteção de Dados Pessoais (LGPD)*

Os desafios dos escritórios de contabilidade para garantir a conformidade com a Lei Geral de Proteção de Dados Pessoais (LGPD)

Guilherme Pereira Bento Garcia

Nahor Plácido Lisboa

Resumo

Os avanços tecnológicos foram responsáveis por causar mudanças significativas na sociedade, seja nos costumes, no mercado de trabalho ou nas legislações. Atualmente, essas mudanças são mais frequentes e rotineiras que no passado, exigindo uma adaptação mais rápida da sociedade. O mundo digital gerado por essas inovações tecnológicas permitiu uma maior conectividade e acessibilidade aos dados pessoais, ao mesmo tempo que intensificou as vulnerabilidades referentes a esses dados (Moll e Yigitbasioglu, 2019). Setores que trabalham diariamente com dados pessoais estão constantemente expostos aos riscos inerentes a essa maior acessibilidade e, portanto, necessitam de mecanismos capazes de garantir a segurança desses dados. A LGPD foi criada para regular e fiscalizar o tratamento de dados pessoais no Brasil e assim garantir a proteção dos titulares desses dados. A área da contabilidade manipula diariamente dados sensíveis de pessoas físicas, ou jurídicas, além de armazenar informações confidenciais de seus clientes, estando sujeitas as implicações da LGPD. Dessa forma, o objetivo deste projeto foi identificar os principais fatores da LGPD com implicações diretas na atividade contábil e, a partir disso, elaborar um formulário que permita a verificação da conformidade de um escritório contábil de forma rápida e prática. Pela análise da LGPD, do *General Data Protection Regulation* (GDPR) e de estudos envolvendo essas legislações, foram identificados os aspectos mais relevantes da lei e compilados em um formulário composto por 25 itens capazes de atestar a conformidade com a legislação. Uma aplicação prática do formulário em um escritório contábil foi efetuada para sua validação. Conclui-se que as premissas da LGPD irão melhorar substancialmente a segurança de dados no Brasil e que o formulário proposto se mostrou uma ferramenta útil para identificar as pendências na implementação da LGPD permitindo direcionar os esforços e tomadas de decisão para atingir a conformidade com a legislação.

Palavras chave: LGPD; Contabilidade; GDPR; SIC

1. Introdução

A introdução de novas tecnologias sempre causou grande impacto na sociedade, influenciando os costumes, comportamentos, relações pessoais e profissionais, comunicação e, principalmente, as legislações (Mulholland, 2018; Stein Smith, 2018). Atualmente, os avanços tecnológicos são mais frequentes que no passado, ocorrendo de forma constante e periódica, exigindo uma adaptação mais rápida tanto da sociedade quanto do mercado. Nas últimas décadas esses avanços promoveram a ascensão de uma era digital caracterizada por maior conectividade, acessibilidade, globalização, automatização de funções e abundância de informações. (Lindqvist, 2018; Stein Smith, 2018).

No entanto, apesar das notórias facilidades e vantagens promovidas pela tecnologia (Catarina e Couto, 2018), existe o seu lado negativo que afeta diretamente a sociedade. Seja pela influência no mercado de trabalho com a substituição de profissionais por máquinas ou inteligência artificial (IA) (Moll e Yigitbasioglu, 2019; Stanciu e Rîndașu, 2018; Stein Smith, 2018), ou pela facilidade na manipulação de dados sensíveis das pessoas (Mulholland, 2018).

O armazenamento de dados na nuvem e a utilização de sistemas de informação (SI) são serviços digitais essenciais para as empresas nos dias atuais, permitindo mais dinamismo e praticidade na execução de tarefas (Tikkinen-Piri, Rohunen e Markkula, 2018). Porém também causam grande fluxo de informações online, facilitando assim o acesso e divulgação das mesmas (Mulholland, 2018). Segundo Abu-Musa (2003), essa conectividade em uma rede global gera uma exposição constante às ameaças de roubo de dados e de informações confidenciais. Consequentemente, o desenvolvimento tecnológico, junto com a globalização, gerou novos desafios para a proteção de dados (Reding, 2011; Tikkinen-Piri, Rohunen e Markkula, 2018).

Considerando a norma da Associação Brasileira de Normas Técnicas (ABNT) NBR ISO/IEC 17799 de 2005 que caracteriza a informação como um ativo para as empresas, esta deve ter um tratamento digno de sua importância, sendo sua manipulação restrita aos usuários competentes nas empresas. Algumas classes profissionais, como os contadores, manipulam diariamente dados sensíveis tanto de pessoas físicas como jurídicas, contraindo responsabilidades quanto à utilização desses dados (Ribeiro *et al.*, 2020; Šišková e Lőrinczová, 2020).

Nesse sentido, os Sistemas de Informações Contábeis (SIC) representam um grande avanço para a contabilidade, facilitando o manuseio e armazenamento dos dados em formato digital (Ribeiro *et al.*, 2020). Contudo, aumentam os riscos envolvendo as informações contábeis, que ficam mais vulneráveis na internet (Abu-Musa, 2003; Moll e Yigitbasioglu, 2019).

Escândalos envolvendo vazamentos e roubos de dados online através de ataques cibernéticos tornaram-se comuns e sempre causam transtornos e perdas para as empresas, tanto financeiras como de credibilidade (Mulholland, 2018; Stanciu e Rîndașu, 2018). Com isso, o investimento em cibersegurança é uma demanda crescente na sociedade atual (Raddatz *et al.*, 2020; Ribeiro *et al.*, 2020).

Nesse cenário de necessidade de mecanismos de proteção de dados que foi criada, em agosto de 2018, a Lei Geral de Proteção de Dados (LGPD) - Lei n°13.709 (Brasil, 2018), com o objetivo de tornar mais transparente a manipulação dos dados pessoais através da regulamentação e responsabilização dos usuários das informações (Cots e Oliveira, 2018). A criação da LGPD se deu impulsionada pelo Regulamento Geral de Proteção de Dados Pessoais (GDPR) da União Europeia (Mulholland, 2018).

A LGPD provavelmente irá afetar diretamente diversos setores e serviços, assim como ocorreu com o GDPR na Europa (Jones, 2020; Weir *et al.*, 2017). A área da contabilidade será especialmente afetada por essa legislação, exigindo uma maior competência dos profissionais no manuseio das informações (Ribeiro *et al.*, 2020) e uma adaptação dos escritórios contábeis para estar em conformidade às suas diretrizes sob o risco de incorrer em punições (Faifr e Januska, 2019; Stanciu e Rîndaşu, 2018).

Dessa forma, o objetivo desse projeto é identificar quais os requisitos previstos na LGPD que impactam diretamente os escritórios de contabilidade e que são necessários para a conformidade com a legislação, e partir deles elaborar um formulário capaz de averiguar a conformidade de forma rápida e prática. Também foi efetuada uma pesquisa de campo em um escritório contábil para aplicação do formulário, que permitiu avaliar como o processo de adequação à legislação está sendo realizado e qual o grau de conformidade considerando o prazo até a vigência da LGPD.

De modo a atingir o objetivo especificado, o artigo foi organizado em seções. Iniciando pela seção 1 que é a introdução, responsável por apresentar o problema de pesquisa, o objetivo e a justificativa. Na sequência, na seção 2 será apresentado o referencial teórico pesquisado, englobando os conceitos de contabilidade e da LGPD. Na seção 3 é apresentada a metodologia que consiste nos procedimentos adotados para a elaboração da pesquisa. Os resultados são apresentados na seção 4 acompanhados de uma discussão sobre eles. Por fim, as conclusões são apresentadas na seção 5 junto com as limitações da pesquisa e sugestões.

2. Fundamentação Teórica

2.1. Contabilidade

Segundo Ferreira *et al.* (2010) a contabilidade pode ser definida como uma ciência social que estuda o patrimônio do ponto de vista econômico e financeiro, os seus princípios e técnicas. Atua por meio do registro de operações de uma entidade, sendo sua principal função a de controlar o patrimônio de uma pessoa ou organização.

Sua finalidade é identificar, mensurar e fornecer informações úteis para a tomada de decisões e avaliações pelos usuários das informações (Ferreira *et al.*, 2010). De modo simplificado, a contabilidade estuda o efeito da ação do homem sobre o patrimônio das entidades (Tesche *et al.*, 1992). Na Resolução CFC n° 560/83 estão especificadas as atribuições do profissional de contabilidade que corroboram com essas definições.

Ao lidar com estes tipos de informações, os profissionais de contabilidade estão sujeitos ao Código de Ética Profissional do Contabilista (CEPC) previsto na norma NBC n°1 de 2019, que serve como um guia orientando a conduta do contador no exercício de suas atividades. Além do respeito e sigilo exigidos em sua atuação, há também a responsabilidade do profissional contábil definida no Código Civil (Brasil, 2002), que prevê a responsabilização pessoal ou solidária dos contabilistas para atos culposos ou dolosos, respectivamente. Uma vez que são previstas punições, tanto na forma de sanções éticas como monetárias, para transgressões do profissional contábil, o zelo com o manuseio e armazenamento das informações deve ser prioritário.

O progresso tecnológico, apesar dos benefícios gerados para a contabilidade, é um dos responsáveis pela vulnerabilidade dos dados (Raddatz *et al.*, 2020; Ribeiro *et al.*, 2020). Os profissionais de contabilidade armazenam todas as informações contábeis, fiscais e financeiras dos seus clientes. A digitalização desses dados aumenta a necessidade de proteção dos mesmos, devido a crescente comercialização de dados sem autorização (Zanatta, 2015). Stanciu e Rîndașu (2018) afirmam que a privacidade dos dados representa uma vantagem competitiva para as empresas e que episódios de vazamento de dados evidenciam que não é dada a devida importância a segurança dos dados.

Moll e Yigitbasioglu (2019) efetuaram um estudo para analisar como as novas tecnologias estão afetando o profissional de contabilidade e os riscos envolvidos. Foram analisadas 4 tecnologias emergentes que apresentam grande potencial de impactar as atividades contábeis: (1) Armazenamento na nuvem; (2) *Big Data*; (3) *Blockchain*; e (4) Inteligência Artificial (IA). Através da identificação dos prós e contras de cada tecnologia, concluíram que o avanço tecnológico intensifica a vulnerabilidade dos dados e que o uso conjunto dessas tecnologias seria o método mais eficiente para garantir a segurança dos dados, podendo causar mudanças expressivas na área de contabilidade. Apesar das incertezas em relação ao futuro do profissional contábil e das previsões de substituição por métodos automatizados, os autores não hesitam em afirmar que o profissional contábil possui as competências necessárias para participar do processo de desenvolvimento e supervisão dessas tecnologias, sendo capaz de se adaptar aos novos sistemas e continuar relevante no que tange os processos contábeis envolvendo tratamento de dados.

Os sistemas de informação (SI) representam a principal ferramenta para a utilização das informações contábeis e evoluíram conforme às necessidades dos profissionais de contabilidade. Assim, surgiram os sistemas de informações contábeis (SIC) que apresentam funções especificas para área da contabilidade.

2.1.1. Sistemas de Informação (SI)

Os sistemas de informação (SI) representam um tipo particular de sistema de trabalho, podendo ser definido como um sistema de trabalho que processa a informação através das combinações de seis tipos de operações: captura, transmissão, armazenamento, retenção, manipulação e exibição (Alter, 1999). Consiste em um conjunto integrado de componentes computacionais e manuais estabelecidos para coletar, armazenar e gerenciar dados com a finalidade de fornecer informações úteis para os usuários (Gelinas, Dull e Wheeler, 2015).

Para Ribeiro *et al.* (2020) os SI são um conjunto de meios físicos, lógicos, financeiros, organizacionais e humanos que interagem de forma racional com a finalidade de produzir, memorizar e distribuir as informações.

Os SI existem basicamente para produzir informações, poderão auxiliar gerentes e colaboradores na análise de problemas, na criação de produtos e na busca por soluções, além da automatização de funções de outros sistemas (Alter, 1999; Oliveira, 1997)

Os sistemas de informações contábeis (SIC) são um subsistema especializado dos SI, que têm como objetivo coletar, processar e reportar informações relacionadas aos aspectos financeiros da empresa (Gelinas, Dull e Wheeler, 2015). Representa uma estrutura unificada dentro de uma organização com a finalidade de transformar dados financeiros e econômicos em informação contábil, servindo como instrumento de armazenamento das informações de acordo com os critérios contábeis aceitos (Ribeiro *et al.*, 2020). Periodicamente os SIC irão produzir balanços e declarações financeiras que servirão de base para a tomada de decisões dos gestores e demais usuários dessas informações.

O suporte pela tecnologia em nuvem é um tendência das empresas para facilitar suas operações, principalmente, no que diz respeito às tarefas contábeis, apesar da maior vulnerabilidade dos dados e exposição a vazamentos e roubos (Mulholland, 2018; Ribeiro *et al.*, 2020; Weir *et al.*, 2017).

2.2. Lei Geral de Proteção de Dados Pessoais (LGPD)

A Lei Geral de Proteção de Dados Pessoais (Brasil, 2018) de agosto de 2018, e que sofreu algumas alterações pela Lei n° 13.858 de 2019, foi criada com o intuito de regulamentar o tratamento de dados pessoais no Brasil. Dispõe sobre o tratamento de dados pessoais por pessoas naturais, ou jurídicas, em meio físico, ou digital, com a finalidade de proteger direitos fundamentais como a liberdade, privacidade e o livre desenvolvimento (art.1°).

O foco desta legislação é a proteção das operações envolvendo o tratamento de dados, que está definido em seu art. 5° como a coleta, produção, recepção, classificação, utilização, acesso, reprodução, transmissão, distribuição, processamento, arquivamento, armazenamento, eliminação, avaliação ou controle da informação, modificação, comunicação, transferência, difusão ou extração. Pela abrangência do termo, fica evidente que inúmeras atividades serão afetadas por essa legislação, sendo a contabilidade uma delas.

Ainda nos art. 5° são apresentadas as definições de dados pessoais e dados sensíveis, bem como a distinção entre o controlador e o operador dos dados pessoais. Estas definições são muito importantes para identificar a quem compete a responsabilidade sobre o tratamento de dados. No caso específico da contabilidade, o profissional contábil é enquadrado como operador e, portanto, poderá ser responsabilizado caso ocorram infrações no tratamento dos dados.

A LGPD representa apenas o primeiro passo na proteção de dados. Mulholland (2018) acredita que as legislações futuras devem ficar mais rigorosas em relação a proteção de dados

pessoais, pois considera que o tratamento de dados está relacionado com a proteção do Estado e dos interesses públicos.

Considerando a abrangência dessa legislação e os possíveis impactos de sua implementação, a preocupação com a segurança dos dados deve se tornar prioritária em muitas empresas, inclusive nos escritórios de contabilidade. Pensando nisso, Ribeiro *et al.* (2020) efetuaram um estudo para analisar a percepção do profissional contábil sobre a segurança das informações contábeis no ciberespaço. O estudo foi efetuado através de entrevistas com profissionais de um determinado escritório contábil, e devido ao espaço amostral restrito está sujeito a vieses e não permite generalizações. No entanto, os autores concluíram que os profissionais possuem conhecimento superficial sobre o tema e não compreendem corretamente os riscos aos quais estão expostos.

Inicialmente a vigência da LGPD estava prevista para se iniciar em agosto de 2020, ou seja, 24 meses após sua publicação, porém devido aos transtornos causados pela pandemia do COVID-19 foi emitida a Medida Provisória n° 959 que adiou sua vigência para o dia 03 de Maio de 2021. No entanto, no dia 26 de Agosto de 2020, o Senado Federal derrubou o adiamento previsto na MP 959/2020 e transformou a MP no Projeto de Lei de Conversão n° 34, definindo o início da vigência da LGPD para após a sanção presidencial que ocorreu em 17 de Setembro de 2020.

A LGPD foi fortemente influenciada pelas regulações europeias, principalmente pelo Regulamento Geral de Proteção de Dados da União Europeia (GDPR) que entrou em vigor em maio de 2018 (Mulholland, 2018). Consequentemente, a análise dos impactos do GDPR na comunidade europeia pode servir como parâmetro para efetuar previsões sobre os efeitos da implementação da LGPD no Brasil.

2.2.1. Regulamento Geral de Proteção de Dados da União Europeia - GDPR

O GDPR foi votado em maio de 2016 e entrou em vigor em maio de 2018 para todos os países da União Europeia, substituindo a Diretiva de Proteção de Dados de 1995 (DPD 95/46/EC). Layton (2017) considera que este é provavelmente o regulamento pan-Europeu mais importante das últimas décadas e deve se tornar uma referência mundial na proteção de dados.

Começou a ser desenvolvido em 2009, e em 2012 a Comissão Europeia publicou oficialmente a proposta para reforma da proteção de dados na União Europeia (Hert, De e Papakonstantinou, 2016). A DPD 95 tornou-se obsoleta, pois foi elaborada antes da era digital das redes sociais e serviços online, ou seja, não atende aos requisitos de privacidade do ambiente digital (Faifr e Januska, 2019; Tikkinen-Piri, Rohunen e Markkula, 2018). Assim, o GDPR foi criado impulsionado pelos novos desafios impostos pela tecnologia (Faifr e Januska, 2019; Lindqvist, 2018).

O art.1 do GDPR apresenta os objetivos do regulamento, que basicamente se resumem em estabelecer regras para o tratamento e movimentação dos dados pessoais, e garantir os direitos fundamentais dos cidadãos principalmente no que diz respeito a proteção de dados pessoais. Segundo a Comissão Europeia, o objetivo do GDPR é permitir que os usuários

tenham controle sobre seus dados pessoais, reforçando os direitos dos cidadãos em relação ao tratamento de dados (Faifr e Januska, 2019). Para Tikkinen-Piri, Rohunen e Markkula (2018) o foco do GDPR é enfrentar os desafios na proteção de dados pessoais, reforçar os direitos de privacidade online e alavancar o mercado digital europeu.

O GDPR é constituído por 99 provisões que definem os aspectos da proteção de dados desde os objetivos até as punições, abordando ainda temas como o consentimento, direitos do usuário, criação de órgãos de fiscalização, entre outros. Algumas instituições contribuíram para a elaboração do GDPR como a Comissão Europeia (EC), o Parlamento Europeu (EP), a Agência Europeia para a Segurança das Redes e da Informação (ENISA) e a Autoridade Europeia para a Proteção de Dados (EDPS), sendo que este último tem participação ativa através do Comitê Europeu de Proteção de Dados que foi criado pelo GDPR (Layton, 2017).

Antes mesmo da sua implementação, o GDPR causou polêmica sobre qual seria seu impacto nas empresas e como elas seriam capazes de se adequar aos requisitos previstos. Para Lindqvist (2018) o processo de adaptação para estar em conformidade com o GDPR seria muito trabalhoso, uma vez que o GDPR possui 99 provisões enquanto seu antecessor, a DPD 95, possuía apenas 34 artigos. Enquanto algumas provisões do GDPR apresentavam certa facilidade para serem implementadas, outras, no entanto, representavam verdadeiros desafios para as empresas como, por exemplo, o art. 33 que prevê a necessidade de notificação de vazamentos de dados ao órgão competente em até 72 h.

Faifr e Januska (2019) fizeram um estudo para averiguar o grau de conformidade das empresas antes da implementação do GDPR. Os autores constataram que a minoria das empresas estava preparada para a legislação, cerca de 25%, e que a principal razão para a baixa conformidade foi a ambiguidade da legislação associada ao prazo restrito para adequação.

Weir *et al.* (2017) e Tobin *et al.* (2017), em seus respectivos trabalhos, sugerem métodos utilizando conjuntamente criptografia e banco de dados imutáveis para aumentar a proteção de dados visando a conformidade com o art. 33 (notificação de vazamento em até 72h), evitando incorrer em multas e punições. Weir *et al.* (2017) acredita que a maioria das empresas não será capaz de se adequar a norma, ficando expostas às punições e com alto risco de falência. O estudo de Tobin *et al.* (2017) focou nos impactos que o GDPR poderia causar nas instituições financeiras do Reino Unido, com prejuízos em multas calculados em mais de 5 bilhões de euros. Assim como Weir *et al.* (2017), concluíram que a maioria das empresas terão dificuldades para se adequar a norma.

Lindqvist (2018) analisa os contratos entre controladores e operadores de dados no contexto da internet das coisas (IoT) e as mudanças promovidas pelo GDPR. Enaltece as dificuldades da legislação contratual com os novos conceitos de bens das novas tecnologias e conclui que o GDPR permite interpretações equivocadas e que os legisladores parecem estar confiando demais na conduta dos controladores de dados.

Dentre alguns estudos específicos para a área da contabilidade, Šišková e Lőrinczová (2020) analisaram os efeitos do GDPR no setor de contabilidade de uma empresa da

República Tcheca, focando nos dados necessários para efetuar os pagamentos dos funcionários. Discutem o processo de implementação do GDPR, seus custos e as medidas técnicas e organizacionais necessárias para garantir a proteção dos dados. Por fim, avaliaram que a maior transparência permite que os funcionários decidam quais dados, e por quanto tempo, devem ser guardados e tenham conhecimento do modo como estes dados são tratados.

Em um outro estudo, Stanciu e Rîndașu (2018) analisaram a percepção dos profissionais de contabilidade 2 meses antes da implementação do GDPR na Romênia. Avaliaram que os contadores possuem pouco conhecimento técnico sobre as tecnologias de informação (TI) e que suas competências abrangem apenas as partes menos técnicas da proteção de dados. A partir disso definiram 9 atividades contábeis que requerem maior proteção e são fundamentais para a conformidade com o GDPR (Tabela 1). Através das respostas de questionários virtuais preenchidos por contadores, Stanciu e Rîndașu (2018) efetuaram algumas descobertas interessantes como a falta de conhecimento dos contadores sobre a implementação do GDPR e seus impactos, o fato de empresas maiores já possuírem um controle maior sobre suas atividades facilitando a conformidade com o GDPR, e que as empresas com menos de 250 colaboradores devem sofrer menos com os efeitos do GDPR, se suas atividades principais não trabalharem diretamente com tratamento de dados pessoais. Assim, consideraram que a primeira etapa para adequação ao GDPR é o treinamento dos contadores e finalizaram o estudo alertando que a implementação do GDPR só será possível com a colaboração de todos os departamentos envolvidos com o tratamento de dados de um escritório de contabilidade.

Em um estudo mais abrangente, Tikkinen-Piri, Rohunen e Markkula (2018) analisaram o impacto do GDPR para todas as empresas que utilizam dados pessoais, principalmente pequenas e médias empresas. Foram identificadas as principais mudanças introduzidas pelo GDPR em relação ao regulamento anterior, a DPD 95, e definidas 12 implicações práticas que devem ser consideradas para a conformidade com o GDPR (Tabela 1). Cada implicação foi analisada individualmente pelos autores junto com a explicação de como as empresas deveriam proceder para se adequar a nova legislação. Considerando que pequenas e médias empresas possuem menos recursos para investir e que não existem soluções prontas para a adequação ao GDPR, os autores concluíram que entender as 12 implicações identificadas é fundamental para as empresas efetuarem um planejamento de implementação evitando incorrer em custos adicionais e se beneficiando de cada provisão à medida que é adotada.

Após o início da vigência do GDPR, percebendo as dificuldades das empresas pequenas e médias para estar em conformidade com a legislação, Brodin (2019) desenvolveu um método para implementação do GDPR. Assim como Tikkinen-Piri, Rohunen e Markkula (2018), identificou as mudanças promovidas pelo GDPR em relação a DPD 95 e criou uma estrutura, ou roteiro, para a implementação do GDPR (Tabela 1). Esse roteiro foi dividido em 3 fases: análise, projeto e implementação. Cada uma das fases possui especificidades e aplicações próprias que são apresentadas e descritas pelo autor. Também foi efetuada uma análise prática desse roteiro, sendo aplicado em 3 empresas na Suécia com diferenças em relação ao tamanho, serviços prestados e gestão. O autor considera que pequenas e médias

empresas não possuem os recursos e o conhecimento técnico necessários para implementar o GDPR devidamente, estando expostas aos riscos de punições por não conformidade. Dessa forma, sugere que o roteiro proposto seria muito útil para as empresas implementarem o GDPR com baixo custo e que os estudos de caso com as 3 empresas, apesar do pequeno espaço amostral, demonstraram a efetividade do roteiro.

(Tikkinen-Piri, Rohunen e Markkula, 2018)	**(Stanciu e Rîndaşu, 2018)**	**(Brodin, 2019)**
Especificação do uso dos dados	Garantir segurança física de dispositivos móveis e da documentação de apoio	Dados pessoais devem ser tratados com transparência em relação ao titula do dado
Consideração das condições para o tratamento de dados no contexto internacional	Senhas de acesso complexas e boas práticas para manter a segurança das credenciais	Minimização dos dados
Privacidade através do tratamento de dados por projeto (*Privacy by design*)	Não enviar dados confidenciais ou pessoais sem necessidade	Processamento de dados pessoas de menores
Demonstração de conformidade com o GDPR	Revisão constante da base de dados pessoais	Informar o titular dos dados sobre as bases legais relacionadas ao tratamento de dados
Desenvolver processo para lidar com o vazamento de dados	Atualização periódica da documentação de backup	Reforçar o direito de ser esquecido
Cálculo de sanções por não conformidade	Notificação do encarregado (DPO) sobre qualquer irregularidade	Direito à portabilidade dos dados
Designar um encarregado ou DPO (*Data Protection Officer*)	Mapeamento da informação de acordo com seu propósito	Proteção de dados por projeto (*Design and Default*)
Fornecimento de informações para os titulares dos dados	Identificação das atividades que produzem ou manuseiam dados pessoais e aumentar a segurança dessas atividades	Assegurar o tratamento apenas dos dados necessários para o propósito específico
Obtenção de consentimento para o uso de dados pessoais	Revisão das políticas dos processos que utilizam dados pessoais e confidenciais para atingir conformidade com o GDPR	Notificação de vazamento de dados em até 72h
Assegurar o direito de ser esquecido aos titulares dos dados		Execução de uma avaliação de impacto da proteção de dados quando o tratamento de dados apresentar alto risco aos titulares dos dados
Assegurar o direito de portabilidade aos titulares dos dados		Designação de um encarregado (DPO)
Manutenção da documentação que garante a conformidade		Transferência de dados pessoas para outros países

Tabela 1. Principais mudanças promovidas pelo GDPR que são necessárias para as empresas atingirem a conformidade com a legislação.

3. Procedimentos Metodológicos

Como o objetivo desse estudo consiste em identificar os principais requisitos previstos na LGPD que impactam os escritórios de contabilidade e definir os principais desafios para a implementação dessa legislação, a pesquisa foi efetuada em duas partes:

- Revisão bibliográfica sobre a LGPD para identificar os possíveis impactos na área da contabilidade e elaboração de um formulário com as atividades que deverão ser modificadas para atingir a conformidade com a lei;

- Estudo de caso com a visitação de um escritório de contabilidade para identificar, na prática, o grau de conformidade e as dificuldades para a implementação da LGPD.

Inicialmente foi efetuado um levantamento bibliográfico sobre a LGPD com foco em seus impactos para a área da contabilidade, afim de identificar quais os principais desafios das empresas para a implementação da legislação. Considerando a influência do regulamento europeu (GDPR) na elaboração da LGPD, também foi efetuada uma pesquisa sobre os efeitos do GDPR na comunidade europeia. Devido às similaridades entre as duas legislações é coerente supor que os impactos também tenham certo grau de semelhança, assim as dificuldades na implementação do GDPR na União Europeia podem auxiliar na preparação das empresas brasileiras para a implementação da LGPD.

A partir da análise do referencial teórico foram identificados os principais fatores necessários para garantir a conformidade com a LGPD. Dessa forma, foi elaborado um formulário contendo esses fatores identificados e que permitiu checar a conformidade das empresas com os itens propostos.

Uma pesquisa de campo foi conduzida em um escritório de contabilidade para apurar o grau de conformidade em relação à LGPD com base nos fatores identificados previamente. Este estudo de caso consistiu na aplicação prática do formulário que foi elaborado e na avaliação de sua eficiência. O escritório de contabilidade escolhido para a pesquisa está localizado na cidade de São Paulo, é classificado como uma pequena empresa e presta serviços de controladoria e contabilidade gerencial. A escolha do escritório ocorreu devido ao seu tamanho, que por ser uma pequena empresa deverá apresentar mais dificuldades na implementação da LGPD. Por questões de confidencialidade algumas informações, como o nome da empresa, serão preservadas. Foi efetuada uma visitação na empresa para entrevista com o sócio fundador e avaliação das instalações e sistemas conforme as exigências da LGPD. Tanto a entrevista como o formulário foram desenvolvidos a partir do referencial teórico.

A visita ocorreu no dia 30 de Setembro de 2020 acompanhada do sócio diretor do escritório. Devido a pandemia a maioria dos colaboradores ainda efetuavam trabalhos remotos e, portanto, o escritório estava vazio. Foram vistoriados todos os cômodos do escritório assim como todo o equipamento e servidores de processamento e armazenamento de dados.

4. Discussão e Resultados]

4.1. Identificação de fatores para implementação da LGPD

O processo de identificação dos principais requisitos da LGPD ocorreu pela análise de estudos sobre a LGPD, pela interpretação dos artigos previstos na lei, pelos comunicados emitidos por entidades oficiais e também pela comparação com os artigos do GDPR e seus impactos na comunidade europeia.

Referente ao GDPR, os trabalhos de Tikkinen-Piri, Rohunen e Markkula (2018), Stanciu e Rîndașu (2018), Faifr e Januska (2019) e Brodin (2019) foram fundamentais para a compreensão das principais adaptações que as empresas da União Europeia foram submetidas para atingir a conformidade com a lei. Nesses trabalhos foram identificadas as principais mudanças introduzidas pela lei, as atividades impactadas e os principais desafios enfrentados pelas empresas para a implementação do GDPR.

Tikkinen-Piri, Rohunen e Markkula (2018) e Brodin (2019) identificaram 12 mudanças relevantes introduzidas pelo GDPR, em relação ao DPD 95, e que são necessárias para a conformidade (Tabela 1). O foco dos trabalhos foi a implementação do GDPR nas pequenas e médias empresas, que possuem menos capacidade de investimento, e portanto ambos apresentam procedimentos para uma implementação completa e de baixo custo. Brodin (2019) efetua aplicações práticas da implementação proposta e apresenta uma espécie de roteiro, como um passo a passo, para essa implementação (Figura 1). Importante ressaltar que as soluções apresentadas por estes autores são adequadas para empresas de todos os segmentos, sem discriminar por ramo de atuação.

No caso específico da área da contabilidade, Stanciu e Rîndașu (2018) identificaram 9 atividades contábeis que devem ser modificadas para se adequar ao GDPR (Tabela 1). Apesar de identificar as atividades afetadas pela legislação, não descrevem os procedimentos necessários para garantir a conformidade.

Utilizando esses roteiros de implementação do GDPR como exemplo, foi efetuada uma busca de estudos similares em relação à LGPD no Brasil. No entanto, constatou-se que existem poucos estudos, tanto com aplicação prática da lei como descrevendo os principais fatores que irão impactar as empresas.

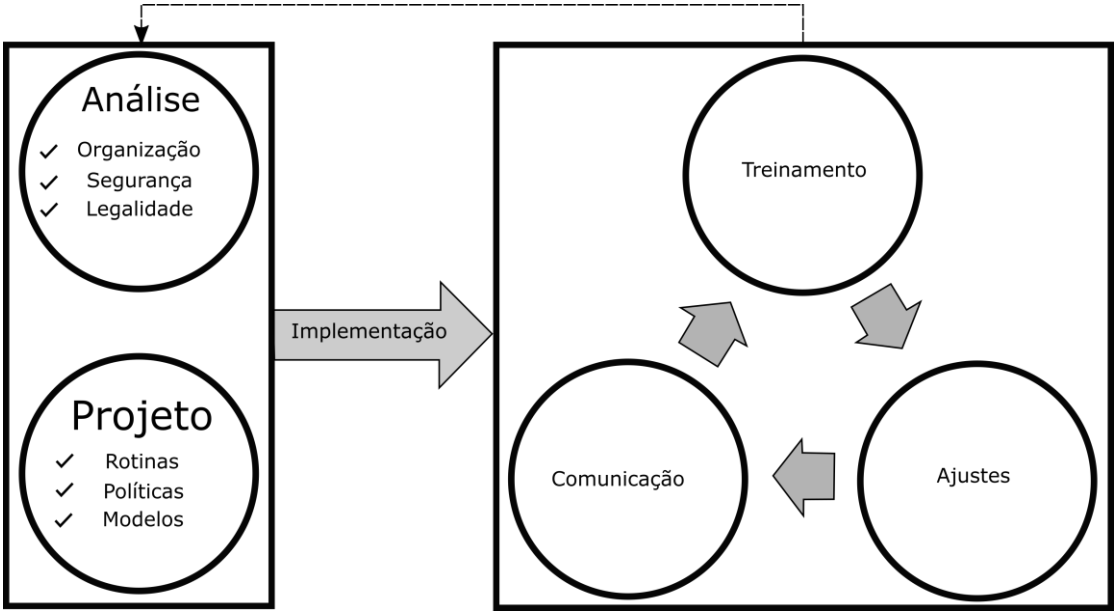

Figura 1. Metodologia para auxiliar pequenas e médias empresas na implementação do GDPR. Modificado de Brodin (2019).

Primeiramente, foi efetuada uma busca em entidades oficiais do governo a fim de identificar a existência de alguma orientação para as empresas. Na lei está prevista a criação da ANPD (Autoridade Nacional de Proteção de Dados), órgão que será responsável pela fiscalização do cumprimento da LGPD, basicamente garantindo a conformidade das empresas. Baseada em suas diretrizes, terá entre suas atribuições aplicar sanções em caso de descumprimento da lei, estabelecer padrões, regular e orientar as empresas sobre sua aplicação e elaborar estudos sobre o tema. A ANPD foi oficialmente criada pelo Decreto nº 10.474 de 2020 que aprovou a estrutura regimental e o quadro demonstrativo de cargos, porém a publicação do decreto não cria o órgão automaticamente. A organização do quadro de pessoal e as regras listadas só terão validade na data de nomeação do diretor-presidente da ANPD no Diário Oficial da União, o que ainda não tem previsão de ocorrer, deixando as empresas desamparadas durante esse processo de implementação da LGPD.

Em relação aos programas oficiais do governo, o Serpro (Serviço Federal de Processamento de Dados), em sua página na internet, possui um material bastante completo sobre a LGPD, apresentando explicações simplificadas sobre os fundamentos e princípios da lei, e sobre as principias mudanças propostas (Tabela 2). Mantém um acervo com artigos e reportagens sobre a LGPD publicados no site e também apresenta dicas para aumentar a segurança de dados pessoais dos indivíduos. Tudo é explicado de forma bem resumida e com linguagem simples de modo que facilita a compreensão, porém ainda carece de exemplos de aplicação prática ou um roteiro, passo a passo, para a implementação da lei.

O escritório de advocacia Lee Brock Camargo Advogados mantém uma página na internet (lgpdbrasil.com.br) em que fornece explicações sobre a LGPD, as principais mudanças e os procedimentos para a adequação. Fornecem, gratuitamente, um guia simplificado de implementação da LGPD com resumos dos artigos mais relevantes da lei e com um passo a passo para implantação da lei nas empresas (Tabela 2). Também fornecem uma avaliação gratuita das empresas para verificar o grau de conformidade. Apesar da praticidade desse guia e da sua utilidade para as empresas, não há clareza em como executar

os procedimentos para se adequar aos fatores apresentados no passo a passo. Não há uma demonstração prática de como esse guia funciona e nem uma validação de sua eficácia

O foco deste trabalho é sobre o impacto da LGPD especificamente em escritórios de contabilidade, e, portanto, identificar as alterações e os processos necessários para implementação da lei nesses ambientes. Dentre as entidades específicas da área contábil a FENACON (Federação Nacional das Empresas de Serviços Contábeis e das Empresas de Assessoramento, Perícias, Informações e Pesquisas) em sua página na internet apresenta uma reportagem com profissionais de diferentes áreas explicando os fundamentos da lei e seus efeitos, assim como indicando as mudanças necessárias para a adequação dos escritórios contábeis (Tabela 2). Apesar da reportagem ser bastante elucidativa, a FENACON não apresenta nenhum material oficial sobre a LGPD que possa auxiliar os escritórios de contabilidade no processo de implementação. No entanto, a FENACON, em conjunto com sedes regionais da SESCON (Sindicato das Empresas de Serviços Contábeis e das Empresas de Assessoramento, Perícias, Informações e Pesquisas), promove palestras sobre o tema com o intuito de apresentar os elementos normativos da lei e transmitir a experiência de aplicação do GDPR na Europa com foco na realidade dos escritórios de contabilidade.

11 passos para implantar a LGPD. Modificado de Soares (2020)	**Princípios da LGPD. Modificado de SERPRO (2020)**	**Medidas para adequação à LGPD (FENACON). Modificado de Mello (2019)**
1. Estudo da LGPD e demais leis que regulamentam o negócio	1. Finalidade especificada e informada explicitamente ao titular	1. Consentimento no recolhimento e uso de dados
2. Mapear a entrada e o tratamento de dados pessoais	2. Adequação à finalidade previamente acordada e divulgada	2. Diferenciação entre controlador e operador
3. Mapear os riscos do tratamento	3. Necessidade do tratamento, limitado ao uso de dados essenciais para alcançar a finalidade inicial	3. Comitês de segurança da informação
4. Elaborar o Relatório de Impacto	4. Acesso livre, fácil e gratuito das pessoas à forma como seus dados são tratados	4. Medidas de redução de exposição
5. Criar a política de proteção de dados e adaptar os documentos internos e externos	5. Qualidade dos dados, deixando-os exatos e atualizados, segundo a real necessidade no tratamento	5. Responsabilidade das terceirizadas
6. Gerenciar os pedidos dos titulares e dos órgãos	6. Transparência, ao titular, com informações claras e acessíveis sobre o tratamento e seus responsáveis	
7. Treinamento das equipes que tratam dados pessoais	7. Segurança para coibir situações acidentais ou ilícitas como invasão, destruição, perda, difusão	
8. Ser *compliance* com a proteção de dados mediante governança	8. Prevenção contra danos ao titular e a demais envolvidos	
9. Exigir o *compliance* de proteção de dados de seus fornecedores	9. Não discriminação, ou seja, não permitir atos ilícitos ou abusivos	
10. Concepção de novos produtos com o princípio de *privacy by design*	11. Responsabilização do agente, obrigado a demonstrar a eficácia das medidas adotadas	
12. Eleger um DPO com conhecimentos regulatórios sobre proteção de dados		

Tabela 2. Mudanças relevantes introduzidas pela LGPD .

A partir da análise desses trabalhos e da comparação com os aspectos do GDPR foi possível identificar os fatores considerados mais relevantes para a implementação da LGPD. Os fatores identificados representam, de certa forma, um compilado daqueles apresentados nas Tabelas 1 e 2, porém com foco específico para as atividades contábeis.

Com base nesses fatores foi elaborado um formulário (**Erro! Fonte de referência não encontrada.**) que será utilizado para a verificação *in loco* da conformidade da empresa com a LGPD, identificando as possíveis pendências existentes.

		Sim	Não
1.	Mapeamento da entrada e tratamento de dados pessoais na empresa		
2.	Identificação das atividades contábeis que utilizam dados pessoais		
3.	Diferenciação entre controlador e operador dentro da empresa		
4.	Treinamento dos colaboradores que tratam dados pessoais		
5.	Gravação dos tratamentos efetuados com os dados		
6.	Medidas de segurança específicas para cada atividade contábil		
7.	Armazenamento de dados em modo seguro (meio físico e/ou digital)		
8.	Proteção física de dispositivos móveis		
9.	Proteção dos documentos com dados pessoais ou confidenciais em meio físico		
10.	Proteção dos documentos com dados pessoais ou confidenciais em meio digital		
11.	Equipe técnica responsável pela segurança dos dados		
12.	Senhas complexas para acesso do sistema		
13.	Atualização periódica das senhas		
14.	Credenciais individuais de acesso ao escritório		
15.	Logins pessoais para acesso ao sistema		
16.	Envio de documentação confidencial de modo seguro		
17.	Consentimento do clientes e colaboradores sobre o tratamento de dados pessoais		
18.	Revisão constante do banco de dados pessoais dos clientes e dos colaboradores		
19.	Transparência sobre o tratamento de dados		
20.	Utilização de backup (físico ou digital) dos dados pessoais e confidenciais		
21.	Atualização periódica do backup		
22.	Capacidade de identificar vazamentos ou perda de dados		
23.	Revisão das políticas de segurança da empresa para adequação à LGPD		
24.	Definição de um encarregado (DPO)		
25.	Exige conformidade das terceirizadas		

Figura 2. Formulário elaborado para verificação de conformidade com a LGPD.

4.2. Exemplo de aplicação prática

4.2.1. Descrição da empresa

O escritório de contabilidade escolhido para aplicação prática do formulário elaborado neste projeto é classificado como uma pequena empresa e oferece serviços de contabilidade em geral, principalmente de controladoria e contabilidade gerencial. A empresa existe há mais de 30 anos e está localizada na cidade de São Paulo.

A empresa utiliza o sistema de informação contábil SCI (Sistemas Contábeis Integrados) com os seguintes módulos: Sucessor (contabilidade e controle patrimonial), Suprema (Fiscal), Practice (Trabalhista) e Control (Controle financeiro e faturamento). Cada módulo atua de forma independente, porém são todos integrados entre si (cadastros, bancos,

lançamentos, provisões, pagamentos e impostos), podendo receber e enviar dados para qualquer outro sistema graças ao gerador de integrações. O acesso dos colaboradores ao sistema é restrito, sendo permitido apenas acessar os dados referentes aos clientes com os quais estão trabalhando, uma vez que são definidas equipes para tratar com clientes específicos. O sócio fundador é o único com acesso aos dados de todos os clientes, podendo inclusive conferir todo o tratamento efetuado por cada colaborador. O SCI possui um sistema próprio de segurança de dados cujo acesso é efetuado apenas pelos desenvolvedores do sistema.

O serviço de Tecnologia da Informação (TI) é terceirizado e responsável pela manutenção, segurança e revisão dos servidores que sustentam a operação no escritório e que armazenam os dados. O escritório possui um técnico de TI próprio que atua em conjunto com a terceirizada e ajuda na manutenção das máquinas e dos sistemas operacionais. Os servidores se localizam na própria empresa e realizam diariamente o backup dos dados para dois discos rígidos (HD) que são espelhados, ou seja armazenam os mesmos dados. Na empresa, também há o armazenamento da documentação física dos clientes que devem ser mantidos de acordo com a legislação vigente para cada tipo de dado seja ele fiscal, contábil ou trabalhista.

4.2.2. Resultados do Formulário

Dos 25 itens que compõem o formulário, apenas 4 itens não foram identificados no escritório contábil em estudo, ou seja, ainda não apresentam conformidade com as exigências da LGPD, sendo eles os itens 7, 10, 22 e 25. O alto grau de conformidade, com 21 itens assinalados como presentes, pode ser explicado pela utilização de um SIC e pela terceirização dos serviços de TI. Muitos dos itens apresentados no formulário estão relacionados com processos do funcionamento do SIC e com os servidores que abastecem o escritório, e assim já estão sujeitos aos protocolos internos de segurança de dados de cada fornecedor específico. A LGPD também irá afetar os serviços prestados por esses fornecedores que terão que se adequar a legislação, e durante esse processo de adequações estão notificando e alertando o escritório contábil sobre as atualizações efetuadas para atingir a conformidade. Dessa forma, a garantia de conformidade dos fornecedores, irá garantir a quase totalidade da conformidade do escritório.

Sobre os itens não conformes, o sócio fundador do escritório explicou que ações já estão em andamento para atingir a conformidade desses itens. Uma das atitudes que está em curso é a migração do banco de dados e do backup para armazenamento na nuvem mantida pela empresa de TI terceirizada, assim a conformidade com os itens 7 e 10, que avaliam o tipo de armazenamento e a proteção de dados em meio digital, respectivamente, será atingida. Apesar do alto grau de segurança no armazenamento na nuvem é importante manter o armazenamento em backup físico, como descrito nos trabalhos de Tobin *et al.* (2017), Weir *et al.* (2017) e Stanciu e Rîndașu (2018).

Em relação ao item 22, sobre a capacidade de identificação de vazamento ou perda de dados, a única alternativa de proteção existente no escritório é através de *firewalls*. Autores como Tobin *et al.* (2017) e Weir *et al.* (2017), em seus estudos sobre os efeitos do GDPR, apresentam métodos capazes de aumentar a proteção dos dados e a prevenção contra ataques

cibernéticos, além de permitir identificar os vazamentos e perdas de dados, e notificar a autoridade no prazo de 72 h determinado pelo GDPR. O art. 46 da LGPD discorre sobre o aumento da proteção dos dados contra situações acidentais ou ilícitas, e o art. 48 exige a comunicação de ocorrências à autoridade assim como apresenta os critérios para essa notificação. No entanto, diferentemente do GDPR, a LGPD ainda não apresenta um prazo para essa notificação, uma vez que, pelo inciso 1° do art. 48 da lei, a ANPD será responsável por definir esse prazo. Dessa forma, como a ANPD ainda não está estruturada, os critérios que irão nortear a proteção de dados e a notificação das ocorrências ainda não estão definidos, dificultando a implementação das empresas nesse quesito.

No caso do item 25, sobre a exigência de conformidade das terceirizadas, não existe nenhum documento oficial do escritório contábil relacionado a isso, porém, como dito anteriormente, as terceirizadas que prestam serviço para o escritório e que estão sujeitas à LGPD já emitiram comunicados orientando sobre as atualizações que serão efetuadas para se adequar à legislação. Portanto, nesse caso específico, a exigência da conformidade das terceirizadas não será essencial. No entanto, considerando a contratação futura de serviços de terceiros, é recomendado a elaboração de um protocolo ou documento para aferir a conformidade da empresa terceirizada contratada.

5. Conclusão

Pela análise dos resultados obtidos e pelo conjunto da pesquisa foi possível elaborar algumas conclusões:

- Considerando o avanço tecnológico dinâmico e a grande ascensão e disponibilidade de serviços digitais, a LGPD é uma legislação fundamental para garantir a proteção de dados no Brasil, se equiparando às legislações de proteção de nível mundial. Essa legislação permitirá uma melhora nos serviços do país, assim como irá criar novas oportunidades para as empresas no mercado mundial.

- Como a ANPD ainda não foi estruturada, apesar de ter sido criada pelo Decreto nº 10.474 de 2020, não existe um órgão oficial do governo capaz de editar normas, orientar as empresas e prestar consultoria durante esse período de adaptações para a implementação da LGPD. Dessa forma, as empresas devem achar outros meios para entender a lei e se adequar a ela. Empresas maiores, com mais recursos e, consequentemente, maior capacidade de investimento são capazes de contratar serviços de terceiros, como assessoria jurídica, para auxiliar no processo de implementação da LGPD. No entanto, as micro e pequenas empresas (MPE), que representam cerca de 99% das empresas formalizadas no Brasil (Sebrae, 2014), não possuem tantos recursos para investimento, sendo dependentes de orientação e de métodos de implantação de baixo custo. Devido a carência de um órgão ou serviço oficial que seja capaz de auxiliar as empresas, se espera que a partir do início da vigência da lei e da estruturação da ANPD exista um período sem punições, de definição de normas e com certa orientação para a finalização da implantação.

- Pelo resultado obtido na aplicação do formulário foi identificado que a empresa ainda não está em conformidade com a LGPD. Dos 25 itens propostos no formulário capazes de garantir a conformidade com a LGPD, apenas 4 itens não estão conformes, sendo eles os itens: 7 (Armazenamento de dados em modo seguro); 10 (Proteção dos documentos com dados pessoais ou confidenciais em meio digital); 22 (Capacidade de identificar vazamentos ou perda de dados) e 25 (Exigir conformidade das terceirizadas). Apesar desses itens não conformes, o escritório está bem avançado no processo de implementação, muito devido a terceirização dos serviços de TI e a utilização de um sistema contábil (SIC).

- Atualizações do SIC e da empresa terceirizada de TI devem ocorrer em um futuro próximo. Os desenvolvedores do SIC utilizado na empresa se manifestaram no sentido de promover ações para adequar o software aos requisitos da LGPD, sendo que as próximas atualizações e versões já estarão em conformidade com a lei. A empresa terceirizada de TI que presta serviços para o escritório também está efetuando modificações em seus sistemas para atingir a conformidade com a LGPD. Ambos enviam notificações e recomendações ao escritório contábil alertando sobre as mudanças e orientando sobre os novos procedimentos adotados.

- Migração do backup para armazenamento na nuvem é uma forma rápida, de baixo custo e bastante efetiva para garantir a segurança do dados e a conformidade com a LGPD. Porém, é importante ressaltar que a manutenção de um backup físico para armazenamento de dados não deve ser descartada.

- O formulário elaborado neste estudo se mostrou uma ferramenta de uso fácil e ágil para verificar a conformidade com a LGPD. Não pode ser considerado como uma ferramenta completa e totalmente assertiva, mas sim uma forma rápida e prática de identificação dos principais fatores da LGPD, apontando as principais pendências de uma empresa. Capaz de direcionar os setores que mais necessitam de atenção e recursos, melhorando a tomada de decisão na implementação da LGPD.

- Nesse projeto foi efetuado a aplicação prática do formulário em apenas um escritório, como exemplo. Devido ao pequeno espaço amostral os autores não recomendam que sejam feitas generalizações com os resultados. A aplicação desse formulário em uma amostra maior de empresas se faz necessária para verificar sua eficácia.

- Os autores sugerem que trabalhos futuros sobre a LGPD e seus desafios nas empresas utilizem esse formulário como ferramenta auxiliar no processo de verificação de conformidade.

Referências Bibliográficas

ABU-MUSA, A. A. The perceived threats to the security of computerized accounting information systems. **Journal os American Academy of Business**, v. 3, 2003.

ALTER, S. A General, Yet Useful Theory of Information Systems. **Communications of the Association for Information Systems**, v. 1, n. March, 1999.

BRASIL. **Lei n°10.406 de 10 de Janeiro de 2002. Institui o Código CivilDiário Oficial da União**Brasil, 2002.

___. **Lei n° 13.709.Lei Geral de Proteção de Dados Pessoais (LGPD)**Brasil, 2018.

BRODIN, M. A Framework for GDPR Compliance for Small- and Medium-Sized Enterprises. **European Journal for Security Research**, v. 4, n. 2, p. 243–264, 2019.

CATARINA, J.; COUTO, P. Auditoria de Cibersegurança: um caso de estudo. 2018.

COTS, M.; OLIVEIRA, R. Lei geral de proteção de dados pessoais - Comentada. p. 303, 2018.

FAIFR, A.; JANUSKA, M. Companies´ Readiness of Gdpr and Implementation Barriers. n. September, p. 31–49, 2019.

FERREIRA, R. J. *et al.* **Contabilidade basica**. [s.l: s.n.].

GELINAS, U. J.; DULL, R. B.; WHEELER, P. R. **Accounting Information Systems - 10e**. [s.l.] Cengage Learning, 2015.

HERT, P. DE; PAPAKONSTANTINOU, V. The new General Data Protection Regulation: Still a sound system for the protection of individuals? **Computer Law and Security Review**, v. 32, n. 2, p. 179–194, 2016.

JONES, R. H. Accounting for surveillance. **Journal of Sociolinguistics**, v. 24, n. 1, p. 89–95, 2020.

LAYTON, R. How the GDPR Stacks Up to Best Practices for Privacy, Accountability and Trust. **SSRN Electronic Journal**, n. September, p. 1–23, 2017.

LINDQVIST, J. New challenges to personal data processing agreements: Is the GDPR fit to deal with contract, accountability and liability in a world of the internet of things? **International Journal of Law and Information Technology**, v. 26, n. 1, p. 45–63, 2018.

MELLO, R. **Escritórios de contabilidade devem estar preparados para a LGPD**. Disponível em: <http://www.fenacon.org.br/noticias/escritorios-de-contabilidade-devem-estar-preparados-para-a-lgpd-5070/>. Acesso em: 10 jun. 2020.

MOLL, J.; YIGITBASIOGLU, O. The role of internet-related technologies in shaping the work of accountants: New directions for accounting research. **British Accounting Review**, v. 51, n. 6, p. 100833, 2019.

MULHOLLAND, C. S. Dados pessoais sensíveis e a tutela de direitos fundamentais: uma análise à luz da lei geral de proteção de dados (Lei 13.709/18). **Revista de Direitos e Garantias Fundamentais**, v. 19, n. 3, p. 159–180, 2018.

OLIVEIRA, E. **Contabilidade informatizada: teoria e prática**. 3. ed. São Paulo: Atlas, 1997.

RADDATZ, J. C. *et al.* **Contabilidade e Cibersegurança: uma análise da segurança da informação contábil**Congresso Fipecafi. **Anais**...2020

REDING, V. The upcoming data protection reform for the European Union. **International Data Privacy Law**, v. 1, n. 1, p. 3–5, 2011.

RIBEIRO, R. *et al.* Cibersegurança e segurança da informação contábil: uma análise da percepção do profissional contábil. **RAGC2**, v. 8, n. 32, p. 71–85, 2020.

SEBRAE. Participação das Micro e Pequenas Empresas na Economia Brasileira. **Serviço Brasileiro de Apoio às Micro e Pequenas Empresas – Sebrae Unidade de Gestão Estratégica – UGE**, p. 106, 2014.

SERPRO. **Princípios da LGPD**. Disponível em: <https://www.serpro.gov.br/lgpd/menu/tratamento-dos-dados/principios-da-lgpd>. Acesso em: 10 jun. 2020.

ŠIŠKOVÁ, J.; LŐRINCZOVÁ, E. Implementation of GDPR into Payroll Accounting in the Czech Republic. **Proceedings of the international scientific conference Hradec Economic Days 2020**, v. 10, p. 804–811, 2020.

SOARES, P. V. C. **Guia LGPD - Lei Geral de Proteção de Dados SimplificadaLee Brock Camargo Advogados**, 2020.

STANCIU, V.; RÎNDAȘU, S.-M. The Impact of General Data Protection Regulation in The Accounting Profession – Evidences from Romania. **Journal of Information Assurance & Cybersecurity**, v. 2018, p. 1–9, 2018.

STEIN SMITH, S. Digitization and Financial Reporting – How Technology Innovation May Drive the Shift toward Continuous Accounting. **Accounting and Finance Research**, v. 7, n. 3, p. 240, 2018.

TESCHE, C. H. *et al.* **Contabilidade: ciência, técnica ou arte?Contabilidade Vista & Revista**, 1992.

TIKKINEN-PIRI, C.; ROHUNEN, A.; MARKKULA, J. EU General Data Protection Regulation: Changes and implications for personal data collecting companies. **Computer Law and Security Review**, v. 34, n. 1, p. 134–153, 2018.

TOBIN, P. *et al.* UK Financial Institutions Stand to Lose Billions in GDPR Fines: How can They Mitigate This? **The British Accounting and Finance Association: Scottish Area Group Annual Conference**, n. August, p. 6, 2017.

WEIR, G. *et al.* Cloud Accounting Systems, the Audit Trail, Forensics and the EU GDPR: How Hard Can It Be? **The British Accounting and Finance Association: Scottish Area Group Annual Conference**, p. 6, 2017.

ZANATTA, R. A. A Proteção dos Dados Pessoais entre Leis, Códigos e Programação: os limites do Marco Civil da Internet. **Direito & Internet III - Tomo I**, p. 447–470, 2015.

Anexo H. Coautoria em artigo completo publicado no periódico *Remote Sensing*

Anexo H.1. *Landslide Segmentation with Deep Learning: Evaluating Model Generalization in Rainfall-Induced Landslides in Brazil*

remote sensing

MDPI

Article

Landslide Segmentation with Deep Learning: Evaluating Model Generalization in Rainfall-Induced Landslides in Brazil

Lucas Pedrosa Soares [1,2], Helen Cristina Dias [2], Guilherme Pereira Bento Garcia [1,2] and Carlos Henrique Grohmann [2,*]

[1] Institute of Geosciences, University of São Paulo (IGc-USP), São Paulo 05508-080, Brazil; lpsoares@usp.br (L.P.S.); guilherme.pereira.garcia@usp.br (G.P.B.G.)
[2] Spatial Analysis and Modelling Lab (SPAMLab), Institute of Energy and Environment, University of São Paulo (IEE-USP), São Paulo 05508-080, Brazil; helen.dias@usp.br
* Correspondence: guano@usp.br

Abstract: Automatic landslide mapping is crucial for a fast response in a disaster scenario and improving landslide susceptibility models. Recent studies highlighted the potential of deep learning methods for automatic landslide segmentation. However, only a few works discuss the generalization capacity of these models to segment landslides in areas that differ from the ones used to train the models. In this study, we evaluated three different locations to assess the generalization capacity of these models in areas with similar and different environmental aspects. The model training consisted of three distinct datasets created with RapidEye satellite images, Normalized Vegetation Index (NDVI), and a digital elevation model (DEM). Here, we show that larger patch sizes (128 × 128 and 256 × 256 pixels) favor the detection of landslides in areas similar to the training area, while models trained with smaller patch sizes (32 × 32 and 64 × 64 pixels) are better for landslide detection in areas with different environmental aspects. In addition, we found that the NDVI layer helped to balance the model's results and that morphological post-processing operations are efficient for improving the segmentation precision results. Our research highlights the potential of deep learning models for segmenting landslides in different areas and is a starting point for more sophisticated investigations that evaluate model generalization in images from various sensors and resolutions.

Keywords: deep learning; landslides; U-Net; automatic segmentation

check for updates

Citation: Soares, L.P.; Dias, H.C.; Garcia, G.P.B.; Grohmann, C.H. Landslide Segmentation with Deep Learning: Evaluating Model Generalization in Rainfall-Induced Landslides in Brazil. *Remote Sens.* **2022**, *14*, 2237. https://doi.org/10.3390/rs14092237

Academic Editors: Federico Raspini, Simon Plank, Matteo Del Soldato, Pierluigi Confuorto, Chiara Cappadonia and Mariano Di Napoli

Received: 6 April 2022
Accepted: 2 May 2022
Published: 6 May 2022

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.

Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

1. Introduction

Landslides are one of the most frequent and destructive natural hazards worldwide. They are responsible for causing infrastructure damages, economic losses, and victims, mainly when it occurs near human habitation [1–3]. In recent years, increased deforestation, unplanned urbanization, climate change, and population growth have enhanced the impact of these events on human lives and infrastructure [4–8]. In 2021, according to the Emergency Event Database (EM-DAT), landslides were classified as the second most costly disaster and caused 40 billion dollars of economic losses in Germany alone and 234 deaths in India [9].

In South America, Brazil concentrates around 40% of all fatal landslides in the continent [2]; several events that occurred in the past few decades in the country led to social and economical losses [10–12]. Therefore, landslide detection studies have been considered critical in remote sensing [5]. However, despite the importance highlighted by many authors, detailed landslide inventories are still scarce [13–15]. Asia/Oceania and Europe lead the publication of studies about landslide inventory construction [16–19]. Nevertheless, several countries, such as Brazil, lack common procedures to recognize landslide features on the landscape [20]. Landslide inventory maps are used to prepare and validate landslide susceptibility models [16,21–24], evaluate risk and vulnerability [25–31], perform geormorphometric (geomorphology) studies [29,32–39], and evaluate landslide events [40]. Limited

and incomplete data may be a source of bias for these studies since model success depends directly on inventory accuracy [41,42].

Landslide inventory maps are usually prepared using high (HR) or very high (VHR) resolution remote sensing imagery [7]. Detection of landslides can be performed manually by aerial image visual interpretation [43–49], semi-automatically, or automatically by using object-based image analysis (OBIA) algorithms [49–51] and pixel-based classification [52,53]. Manual classification of landslides is the prevailing method [14,54,55], but is costly, exhaustive, and time-consuming, almost impracticable for large areas. OBIA is an alternative method for HR and VHR image analysis. The method is based on objects rather than individual pixels [56]. Object-based approaches have two main steps: segmentation and classification [56,57]. Subsequently expert knowledge can be added to the analysis. After segmentation, several object characteristics can be used to classify landslide areas, such as spectral, spatial, hierarchical, textural, and morphological [56]. Pixel-based methods classify each pixel of the image based on its spectral information, ignoring geometric and contextual information, which increases the salt-and-pepper noise in the results [58–60].

In recent years, deep convolutional neural networks (DCNN) have achieved state-of-the-art results in applications such as semantic segmentation, object detection, natural language processing, and speech recognition [61–65]. However, only a few studies have used DCNNs for landslide detection [7].

The recent literature covers topics that evaluate how different architectures affect the model accuracy; the impact of patch size, sampling, and different layers in the results, and the generalization capacity of deep learning models to detect landslides in different areas. Sameen and Pradhan [66] compared residual networks (ResNets) trained with topographical information fused by convolutional networks with topographical data added as additional channels. The models trained with the fused data achieved f1 score and mean intersection over union (mIoU) that were superior by 13% and 12.96% compared to the other models. Ghorbanzadeh et al. [61] compared state-of-the-art machine learning methods and DCNN using RapidEye images and a DEM, with five meters of spatial resolution. The DCNN that used only spectral information and small windows was the best model, achieving 78.26% on the mIoU metric. Yi and Zhang [67] evaluated the LandsNet architecture in two test areas with different environmental characteristics. The results were optimized with morphological operations and the proposed approach yielded an f1 score of 86.89%. Yu et al. [55] used the enhanced vegetation index (EVI), DEM degradation indexes, and a contouring algorithm on Landsat images to sample potential landslide zones with less class imbalance distribution. The trained fully convolutional network (PSPNet) achieved 65% of recall and 55.35% of precision. Prakash et al. [60] used lidar DEM and Sentinel-2 images to compare traditional pixel-based, object-based, and DCNN methods. The deep learning method, U-net with ResNet34 blocks, achieved the best results, with the Matthews correlation coefficient score of 0.495 and the probability of detection rate of 0.72. Prakash et al. [68] evaluated a U-Net in a progressive training with different image spatial resolutions and sensors that used a combination of landslide inventories to predict landslides in different locations around the world. The highest Matthews correlation coefficient achieved was 0.69.

DCNNs, in supervised learning problems, can learn to identify patterns on the training data without the need for complex operations to extract features or pre-processing methods. However, choosing the best network architecture, preparing the training dataset, and tuning the hyperparameters is still a challenge [66,69]. Landslide scar datasets usually have an imbalanced class distribution, with more pixels belonging to background objects, such as urban areas, vegetation, and water, than landslide scars [55]. Therefore, since landslide scars have different shapes and sizes, sampling methods and patch sizes may affect the model accuracy as it can be a way to reduce the class imbalance between the positive and the negative class. Moreover, to the best of our knowledge, only Prakash et al. [68] evaluated the generalization capacity of deep learning models. However, the scenes used to evaluate the models usually are in vegetated areas, where the contrast between the landslide scars

and vegetation allows the models to distinguish the landslides. Moreover, only Yi and Zhang [67] tested post-processing operations to improve the segmentation results.

Thus, the objective of this study is to evaluate model generalization and post-processing techniques with models trained with different datasets and patch sizes in scenes with varying spatial complexity. The main contribution of this paper is as follows:

- Evaluation of model generalization in areas with different scene complexity in Brazil;
- Evaluation of binary opening, closing, dilation, and erosion as post-processing techniques;
- Evaluation of how different patch sizes affect model generalization;
- Evaluation of different datasets on model generalization.

2. Study Areas

The study areas (Figure 1) were located in Rio de Janeiro (RJ) and Rio Grande do Sul (RS) states in the southern part of Brazil. The areas located in the city of Nova Friburgo (RJ state) were used to train the deep learning models and were considered as test area 1 (TA1). The area close to the city of Teresópolis, which is also located in RJ state, was used as test area 2 (TA2); and test area 3 (TA3) was located close to the city of Rolante (RS state).

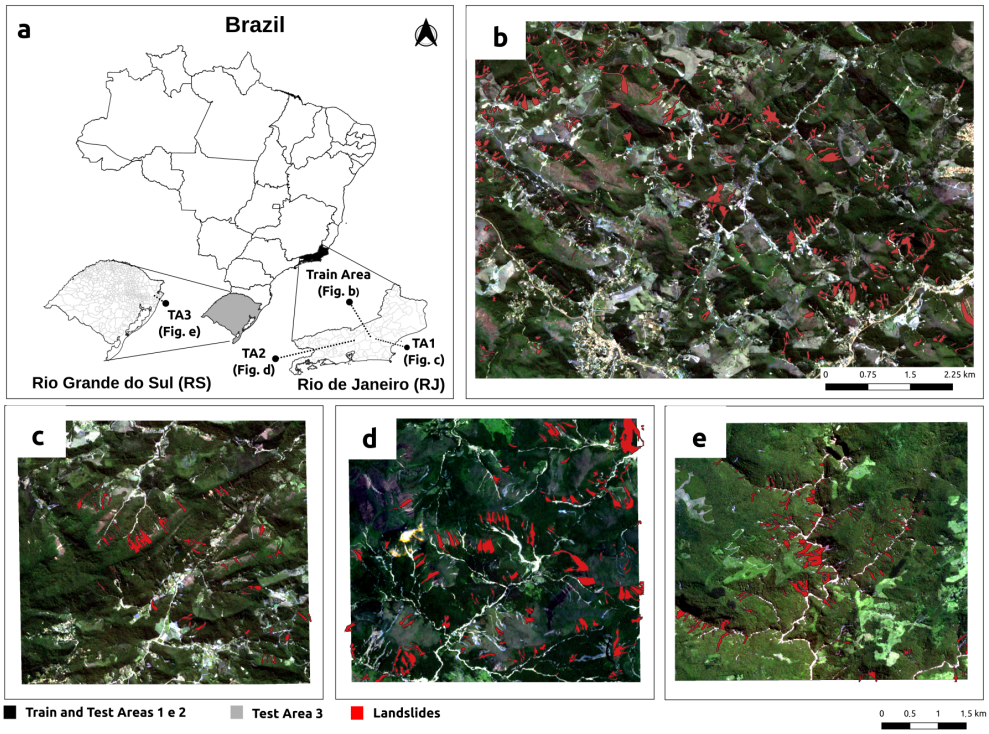

Figure 1. Location of the train and test areas used to train and evaluate the deep learning models. (**a**) Location of the train and test areas in Brazil. (**b**) Train Area. (**c**) Test Area 1 (TA1). (**d**) Test Area 2 (TA2). (**e**) Test Area 3 (TA3).

2.1. Nova Friburgo and Teresópolis

The mountainous region of Rio de Janeiro encompasses the municipalities of Nova Friburgo, Teresópolis, Petrópolis, Sumidouro, São José do Vale do Rio Preto, and Bom Jardim. In January 2011, an extreme rainfall event (140 mm/h) triggered at least 3500 translational landslides that killed more than 1500 people and disrupted all major city facilities in this mountainous region [11]. This event is considered the worst Brazilian natural disaster [70].

Nova Friburgo and Teresópolis are in the geomorphological unit of Serra dos Orgãos. The geological units have a WSW-ENE trend, and the elevation ranges between 1100 and 2000 m a.s.l. [71]. The geology consists mainly of igneous and metamorphic rocks such as

granites, diorites, gabbros, and gneisses [72] (Figure 2a). According to Köppen's climate classification scheme [73], the climate is subtropical highland (Cwb), with dry winters and mild summers. The annual mean precipitation is 1585.62 mm, with most of the rainfall in November, December, and January [74].

2.2. Rolante

The Rolante River Catchment has a drainage area of 828 km^2, with altitudes varying from 19 to 997 m a.s.l [75]. The area is inserted in the geomorphological unit of Serra Geral, with a predominance of basaltic rocks and sandstones (Figure 2b). The climate is characterized as very humid subtropical, with precipitation annual average between 1700 and 2000 mm. On 5 January 2017, an extreme precipitation event (272 mm in four hours) triggered at least 300 shallow landslide events in the area [75–78]. The flash flood caused by the material that moved from the slopes into the Mascara river (a tributary of the Rolante River) reached Rolante city.

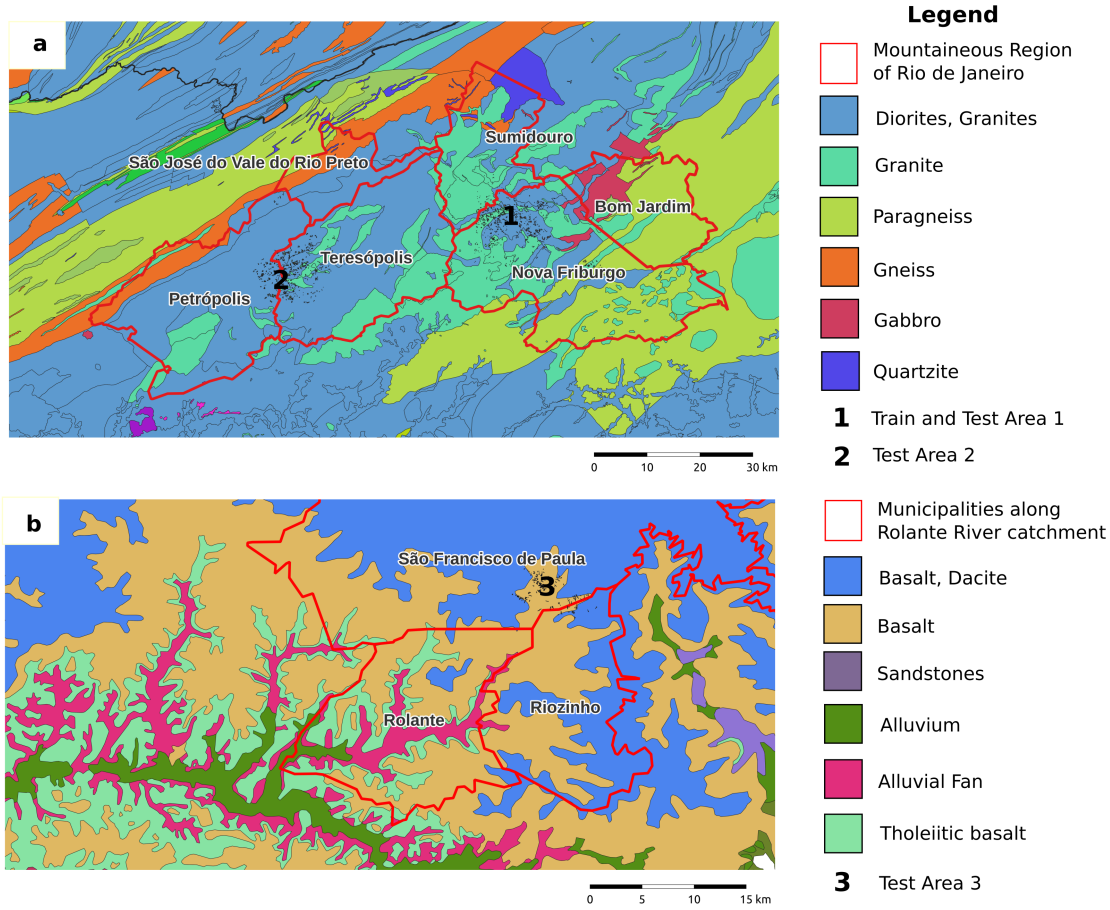

Figure 2. Simplified geological maps of the study areas. (**a**) Geological map of the mountainous region of Rio de Janeiro. (**b**) Geological map of the Rolante River area.

3. Methodology

The methodology applied in this study consists of four parts: pre-processing, training, evaluation, and post-processing (Figure 3). In the pre-processing step, the data were prepared to serve as the input to the U-Net models. Three different datasets were created to train the models. The sampling was done with regular grids in four different patch sizes: 32 × 32, 64 × 64, 128 × 128, 256 × 256. Augmentation consisted of random rotations, vertical and horizontal flips, and was used to keep the sample size the same among the different patch sizes. The training was done using the Tensorflow 2.0 Python Deep Learning Framework and used grid search to find the optimal hyperparameters. The

evaluation step used precision, recall, f1 score, and mean intersection over union (mIoU) to evaluate the accuracy of the models and their generalization capacity. The models were tested in three different areas with different scene complexities and locations. The post-processing step consisted of evaluating binary opening, closing, dilation, and erosion morphological operations.

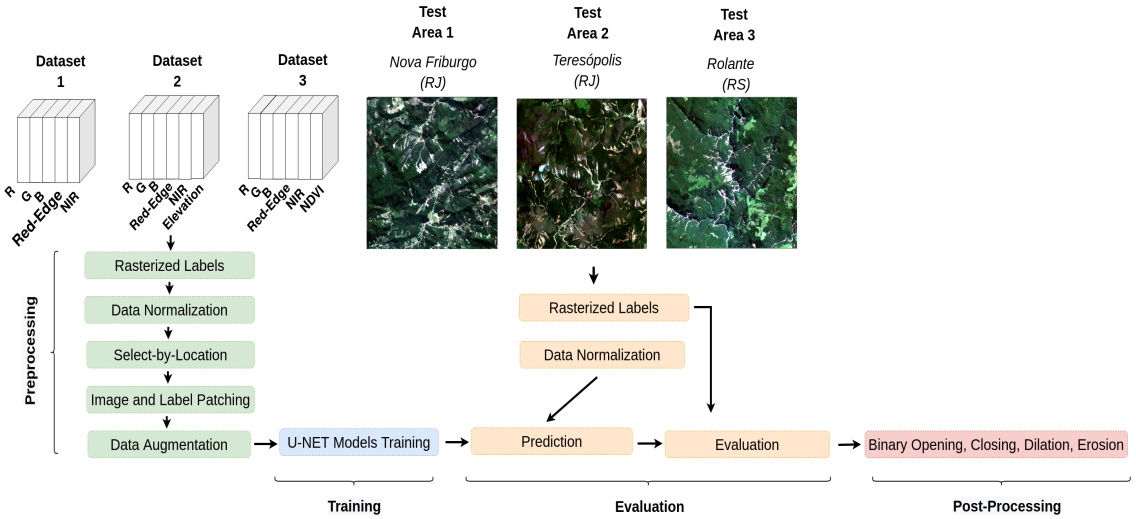

Figure 3. Workflow used to prepare the dataset and train, evaluate, and post-process the deep learning models and the results. "R", "G", "B", "Red-Edge", and "NDVI" represent the bands red, green, blue, red-edge, and the normalized vegetation index, respectively.

The data used in this study consist of the spectral information from the RapidEye satellite and topographical data from the Shuttle Radar Topography Mission (SRTM–[79]). RapidEye consists of a constellation of five identical satellites with high-resolution sensors with a 6.5 m nominal ground sampling distance at nadir. The orthorectified products are resampled and provided to users at a pixel size of 5 m. The data are acquired with a temporal resolution of 5 days in five spectral bands: blue (440–510 nm), green (520–590 nm), red (630–685 nm), red-edge (690–730 nm), near-infrared (760–850 nm) [80]. The SRTM acquired interferometric radar data with dual antennas and provided data with 1 arc-second (30 m) spatial resolution. The mission used single-pass interferometry radar to acquire two signals simultaneously by using two different radar antennas. Differences between the two signals permit the calculation of surface elevation [81].

This work used the RapidEye 3A product (orthorectified, radiometric, and geometric corrections) and was acquired from the Planet Explorer website [79]. The acquisition dates of the training and test images are in Table 1. The SRTM product was the 1 arc-second global (30 m).

Three datasets were generated to train and evaluate the deep learning models. All the datasets used the five RapidEye bands. However, dataset 1 used only those five bands, while in dataset 2, the elevation information was added as an extra channel in the image, and in dataset 3, the Normalized Difference Vegetation Index (NDVI) [82] was calculated (Equation (1)) using the red and the near-infrared (NIR) bands and added as an extra channel.

$$\mathrm{NDVI} = \frac{\mathrm{NIR} - \mathrm{RED}}{\mathrm{NIR} + \mathrm{RED}} \quad (1)$$

The landslides were interpreted from the RapidEye and Google Earth Pro version 7.3 imagery and validated with [10,75] to minimize interpretation errors. Table 1 shows the number of landslide polygons interpreted in each scene. Later, the landslides were rasterized using the Rasterio Python library [83] to a binary mask, on which "1" represents

the landslides and "0" the background. The satellite images were normalized to convert all the pixel values into a 0–1 range interval. All the image pixel values were divided by 2^{16} (16 bits image). Data normalization helps in model convergence and is a common procedure in the machine learning field.

Table 1. Train and test images acquisition date, and the number of landslides present on each scene.

Images	Acquisition Date (RapidEye/SRTM)	Number of Landslides
Train Area (Nova Friburgo)	10 January 2011/23 September 2014	455
TA1 (Nova Friburgo)	10 January 2011/23 September 2014	42
TA2 (Teresópolis)	20 January 2011/23 September 2014	117
TA3 (Rolante)	13 March 2017/23 September 2014	110

The data were sampled with regular grids in four sizes: 32 × 32, 64 ×64, 128 × 128, 256 × 256 pixels. Patching the data in different sizes is an important step to address the differences in the shapes and sizes of the landslides [61]. Moreover, since the patch sizes are directly correlated with the balance between the positive (landslides) and the negative (background) classes, training the models with different sizes is crucial to determine the optimal size for the best model performance in the study areas. A select-by-location operation was used to select only the polygons intersecting landslides. This process ensures that all sampled images will have a small portion of a landslide scar, reducing class imbalance.

Data augmentation allows the use of the annotated data more efficiently during the training phase [67,84]. In this work, because the data were sampled in different patch sizes, the smaller patch sizes have more samples than the larger ones. Hence, comparing the models trained with varying patch sizes may not be fair as the different sample sizes may affect the training of the deep learning models [4]. Thus, to keep the same sample size for all the models, augmentation processes of random rotations and vertical and horizontal flips were performed in the sampled data with patch sizes of 64 × 64, 128 × 128, and 256 × 256 pixels.

3.1. U-Net

U-Net [85] is a fully convolutional network developed for the segmentation of biomedical images. This type of architecture does not use fully connected layers in their structure; instead, they have an encoder–decoder architecture with just convolutional layers (Figure 4). The encoder path is responsible for classifying the pixels without taking the spatial location into account, while the decoder path uses up-convolutions and concatenation to recover the spatial location of the classified pixels and return a mask with the same dimensions of the input image.

The convolutional blocks on the encoder path have two 3 × 3 convolutional layers, activated with the Rectified Linear Unit (ReLU) function, and followed by a max-pooling operation that reduces the spatial dimension by 2. The dropout layer was used with a 0.5 probability after each max-pooling to randomly deactivate some of the layers of the network as a method to reduce the overfitting.

The convolutional layers are responsible for creating feature maps of the input image to allow the model to predict the landslide. During the training step, the 3 × 3 kernels present in these layers are calibrated to find specific features of the landslides. The nonlinear activation function ReLU was calculated according to Equation (2). The use of ReLU increased the degrees of freedom of the computed function, which allows the model to learn nonlinear patterns present in the data [86]. The max-pooling layers with 2 × 2 kernels

translate around the image, obtaining only the highest values and reducing the image dimensions by half. This operation is essential to reduce the computation cost and to preserve the values with the highest relevance. Dropout [87] layers are commonly used in the training phase to reduce the complexity of the model and, consequently, the overfitting with random deactivation of the layers with a p probability. In the architecture used in this study, the dropouts were implemented after each max-pooling layer in the encoder path.

On the decoder path, 2×2 up-sampling operations increase the data's spatial dimension to concatenate feature maps with the same dimension from the encoder path. Then, the concatenated data serve as input for two convolutional layers before another up-sampling operation. At the last layer, a sigmoid function converts the output into a binary mask. The 2×2 kernels of the transposed convolutions learn how to increase the dimensions of the feature maps during the training step and increase the size of the feature maps by 2. The sigmoid function (Equation (3)) converts the values to the 0–1 range at the last layer.

$$\text{ReLU} = max(0, x) \tag{2}$$

$$\sigma(x) = \frac{1}{1 + e^{-x}} \tag{3}$$

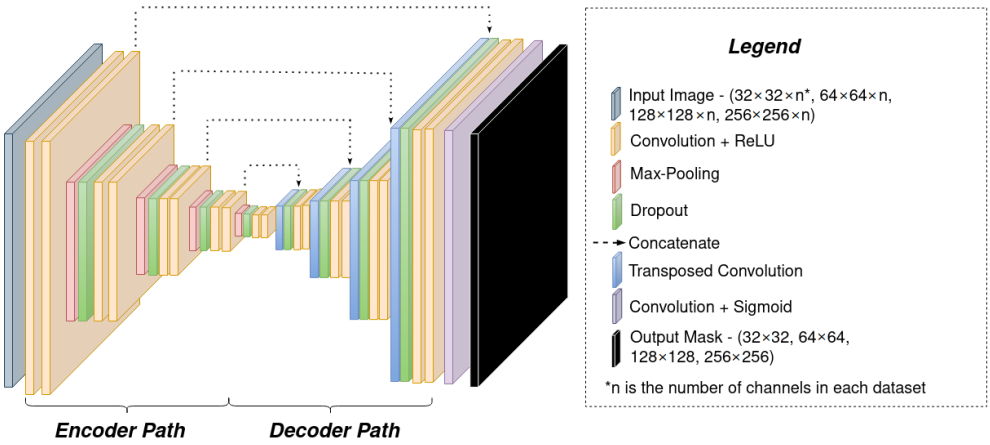

Figure 4. U-Net network architecture.

The models were trained for 200 epochs with a dynamic learning rate of 0.001 that reduces by 0.1 in a loss function plateau. Binary Cross Entropy and Adam function were used as the loss and optimization function, respectively. The models were trained with four different batch sizes (16, 32, 64, 128 samples). The model's weights were saved when the validation loss function decreased to reduce the overfitting. The models were trained on Keras [88] and Tensorflow 2.0 [89] Python libraries. Moreover, 30% of each dataset was used as validation data. The training was held in a NVIDIA^{TM} GeForce RTX 2060 GPU (8 GB memory, NVIDIA, Santa Clara, CA, USA).

3.2. Validation Metrics

The model's performance was evaluated over two test areas by using the f1 score, recall, precision, and mean intersection over union (mIoU) metrics. These metrics are based on true positives (TP), false positives (FP), and false negatives (FN) [61,90,91]. TP are pixels correctly classified as landslides. FP represents the pixels incorrectly classified as landslides, and FN the pixels incorrectly classified as the background. The models that were trained with DEM and NDVI as an additional channel were evaluated on test areas with an additional DEM and NDVI channel. Precision (Equation (4)) defines how accurate the model is by evaluating how many of the classified areas are landslides. The metric is useful for evaluating the cost of false positives. Recall (Equation (5)) calculates how many of the actual positives are true positives. This metric is suitable to evaluate the cost

associated with false negatives. The f1 score (Equation (6)) combines precision and recall to measure if there is a balance between true positives and false negatives. Mean intersection over union (Equation (7)), also known as the Jaccard Index, computes the overlapping of areas between the ground truth (A) and the model prediction (B) divided by the union of these areas. Then, the values are averaged for each class. A value of 1 (one) represents perfect overlapping, while 0 (zero) represents no overlap.

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}} \tag{4}$$

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}} \tag{5}$$

$$\text{f1-Score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \tag{6}$$

$$\text{mIoU} = \frac{A \cap B}{A \cup B} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives} + \text{False Negatives}} \tag{7}$$

3.3. Post-Processing

In this study, post-processing morphological operations were used to optimize the results. Binary opening, closing, erosion, and dilation operators were evaluated individually and combined to find the greater improvement (Figure 5). The binary opening helps in removing minor errors that do not represent landslide candidates. Meanwhile, closing, which consists of a dilation followed by erosion, fills the holes inside predicted landslides [67]. Erosion is a mathematical morphological operation that erodes the boundaries of the foreground to shrink the landslide candidates and enlarge the background. Dilation opening helps in removing small noises (i.e., "salt") in the landslide prediction and connects small dark cracks. This tends to open background gaps between the landslides [92]. Several parameters were tested to find the optimal configuration for the post-processing operations. The best structuring element was a 3 × 3 square and the interaction was done until the results did not change anymore.

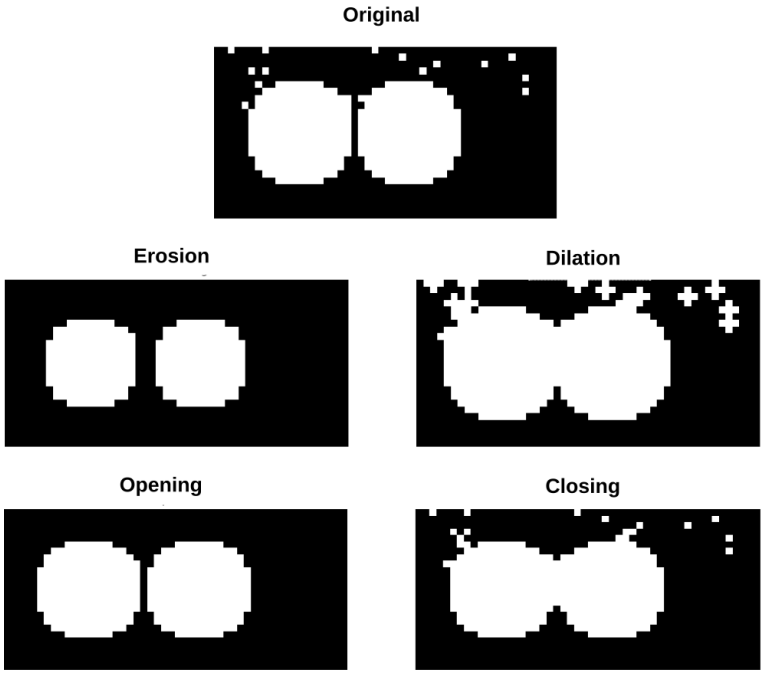

Figure 5. Morphological operations used to post-process the segmentation results.

4. Results and Discussion

The models were trained with four different patch sizes. In general, models trained with all patch sizes learned the feature maps to detect the landslides. The result shows (Figure 6) that the models trained with 32 × 32 and 64 × 64 pixels achieved the best f1 scores in TA2 (0.53) and TA3 (0.60). In contrast, models trained with 128 × 128 pixels patches achieved the best f1 score results in TA1 (0.52). Since TA1 is located close to the training area, the results show that the models trained with larger patches became better in detecting landslides similar to the training images. This occurs because the patches with greater dimensions facilitate the understanding of the global scene context. Consequently, the deep learning model specialized in detecting landslides with similar spectral and morphological characteristics to the training images. On the other hand, the models trained with the smaller tiles learn the local context of the landslide better. Therefore, they make excessive predictions (low precision), reducing the f1 and mIoU in TA1. However, they achieve better results in TA2 and TA3.

Ghorbanzadeh et al. [61] and Soares et al. [93] evaluated samples with different patch sizes to address the difference in landslide shapes. Ghorbanzadeh et al. [61] conclude that the patch sizes affected the results in a non-systematic way. Meanwhile, Soares et al. [93] observed that models trained with larger patches achieved higher precision and lower recall. Similar results were observed by Prakash et al. [68], where the authors trained the models with 224 × 224 pixels and obtained results with bias towards high precision and lower recall. In this study, the results show that the models tend to achieve better precision and lower recall rates with larger patch sizes. Moreover, comparing the results achieved, it is possible to see that this pattern is more evident in TA1 than the other areas. Thus, once models trained with larger patch sizes become highly specialized in detecting the shape and spectral characteristics of the training area, they tend to achieve better precision in those areas and have worse results in the regions that differ from the training regions.

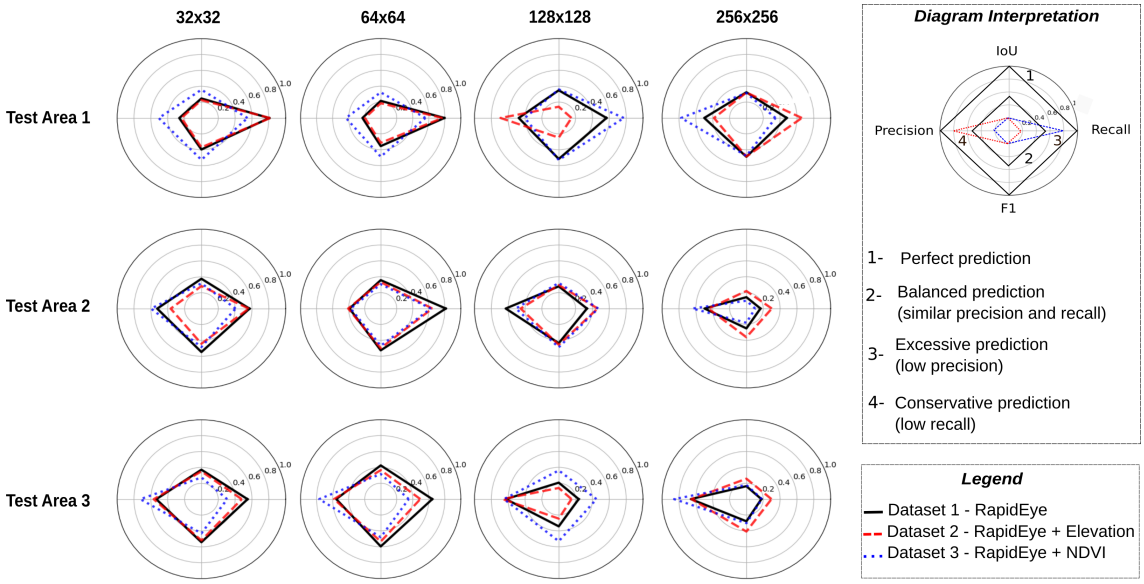

Figure 6. F1 score, precision, recall, and mIoU results of the best segmentation models trained with different patch sizes.

Dataset 3 achieved more balanced results than the other datasets, while dataset 1 achieved better f1 and mIoU scores in most models. The higher balance of dataset 3 may be related to the extra NDVI band. NDVI is a band normalization computation with values that range from 0 to 1 and are comparable even in different images. Consequently, it provides information that facilitates the model generalization. Furthermore, dataset 1 has a lower dimensionality (five bands); therefore, according to the Hughes Phenomena [94], it needs less data to train the model than the other datasets with higher dimensionality

(six bands). The topographical data do not improve the results, which are in accordance with the results obtained by Sameen and Pradhan [66]. This may be related to the greater dimensionality of dataset 3 and the SRTM spatial resolution (30 m).

Spectral indices, such as NDVI, are commonly used in remote sensing to help in the interpretation of the spectral signatures of various objects [95]. The correct selection of features based on these indices is crucial in improving traditional machine learning algorithms [96–98]. However, there is a tradeoff between the number of samples and the dimensionality of the data [99]. The extra bands with spectral indices may not improve the algorithm's performance if the dataset is not large enough to overcome the Hughes Phenomena. Moreover, the deep learning convolution operations may learn to calculate the NDVI in the training process from the spectral bands, and the extra band will be redundant. To the best of our knowledge, only the study of Ghorbanzadeh et al. [100] evaluated the impact of using spectral bands and topographic factors (slope, aspect, plan curvature, elevation). However, in this study, the NDVI was used as the basis for landslide detection and was not evaluated; the model architecture used is a classification network that predicts in a pixel-wise manner. For fully convolutional networks, such as U-Net, still, no study evaluates each band's impact on the model performance.

Evaluating the histogram of the best model results in each test area (Figure 7) and it is possible to see that in TA1, the model prediction achieves higher true and false positive rates than the other test areas. Meanwhile, in the other test areas, false negative results were higher. This pattern shows that despite the models' generalization capacity, the areas with different environmental and spectral characteristics from the training area made the model more restrictive. Therefore, fewer landslides are predicted correctly, and the number of false negatives is greater. Prakash et al. [68] observed a similar pattern, where the models trained with different study areas were biased towards high false negatives. Thus, the false positives of TA1 may represent landslides missing in the ground truth inventory, which does not directly represent a poor result.

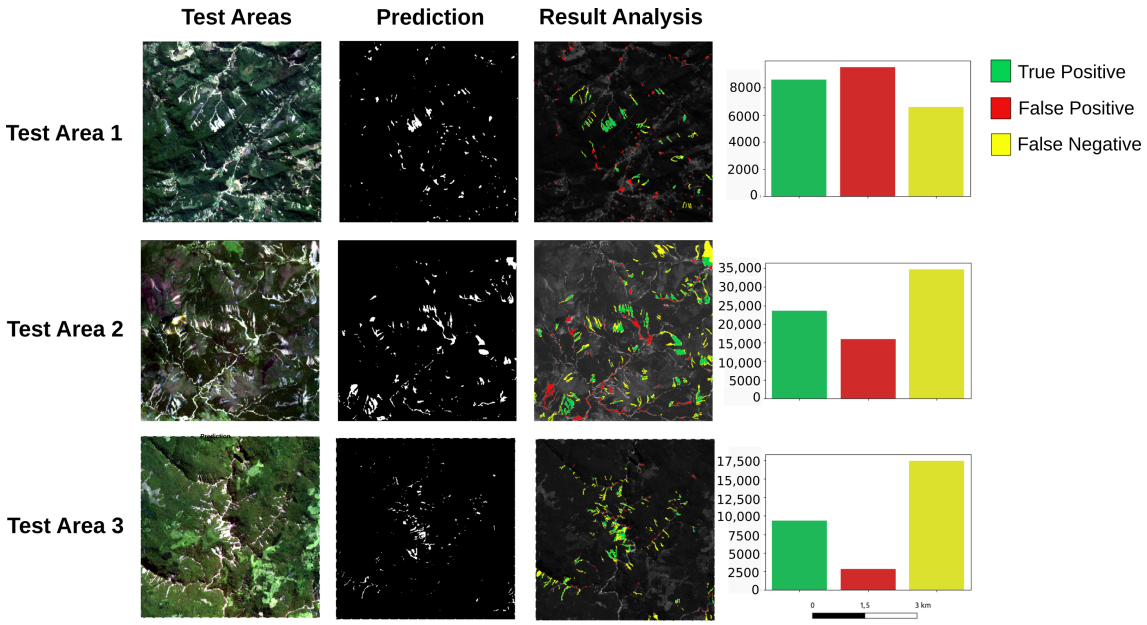

Figure 7. Segmentation results of each test area and result histograms showing the number of pixels representing true positives, false positives, and true negatives. These results correspond to the prediction of the model trained with 128 × 128 pixel tiles and dataset 3 for TA1; the model trained with 32 × 32 tile pixels and dataset 1 for TA2, and the model trained with 64 × 64 pixels and dataset 1 TA3.

The complexity of the scene is also an essential factor in evaluating the generalization capacity of the models. In previous studies [61,67,68], the test areas are usually vegetated

areas around the landslide scars. Models trained and tested with these scenes may not be efficient to detect landslides in urban areas due to the higher complexity of the scene and may not be feasible for applications in disaster scenarios. In Qi et al. [98], the authors noticed that the deep learning models had difficulties distinguishing roads and buildings from landslides. In this study, the test areas were chosen to represent areas with different characteristics and complexity. As shown in the histogram of Figure 8, the scores of the models evaluated on TA1 and TA2, which are close to Nova Friburgo and Teresópolis, were reduced by false positives caused by roads and the roofs of the houses. The errors occur in areas with similar spectral responses to the landslides. Since the spatial resolution of the RapidEye images used in this study is 5 m, the model cannot differentiate the shape of the landslides from rivers with increased bedload, areas with bare soil, roads, and roofs. Consequently, the models made these mistakes in all areas. It was expected that the models trained with the DEM layer would overcome the misclassification of the drainage and urban areas since these areas usually have different terrain morphological attributes such as slope and aspect. Probably, these errors occurred due to the coarse resolution of the available DEM (30 m), which cannot clearly detach objects and generalizes the terrain. In Ghorbanzadeh et al. [61], the authors used a 5 m DEM and observed that the DEM helped in differentiating the human settlement areas.

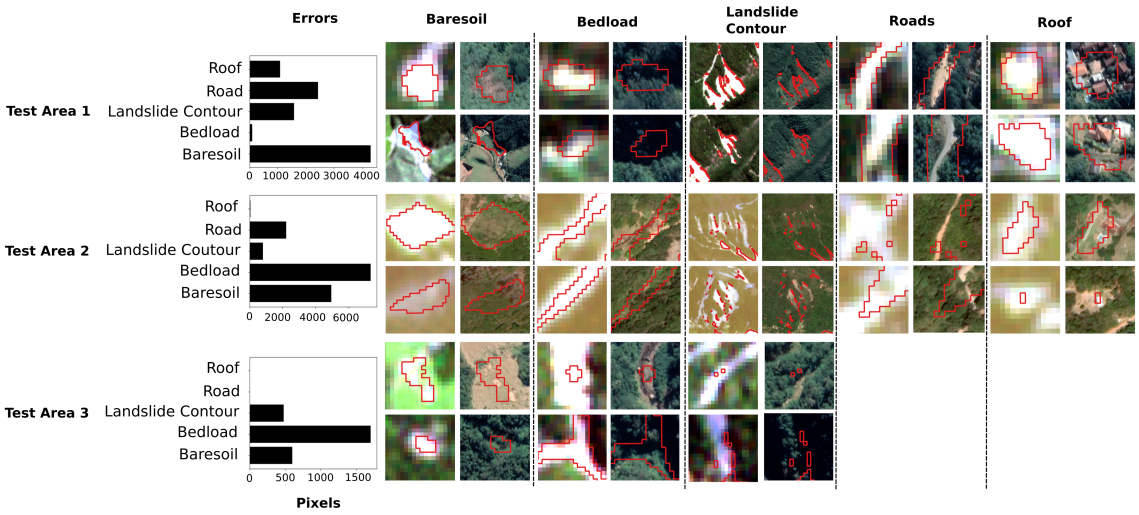

Figure 8. Comparison of the most frequent errors made by the deep learning models during landslide segmentation and histograms showing the number of pixels for each error category. Images with lower resolution (**left**) are from the RapidEye satellite, and images with higher resolution (**right**) are from Google Earth.

The post-processing operations were efficient in improving the precision of all test areas. The precision values improved from 0.56 to 0.64 in TA1, 0.57 to 0.65 in TA2, and 0.64 to 0.81 in TA3 (Figure 9). The results of all operations are given in the Supplementary Material Table S1. These results show that the post-processing techniques are efficient in removing the model's systematic errors and are efficient for improving the segmentation precision results.

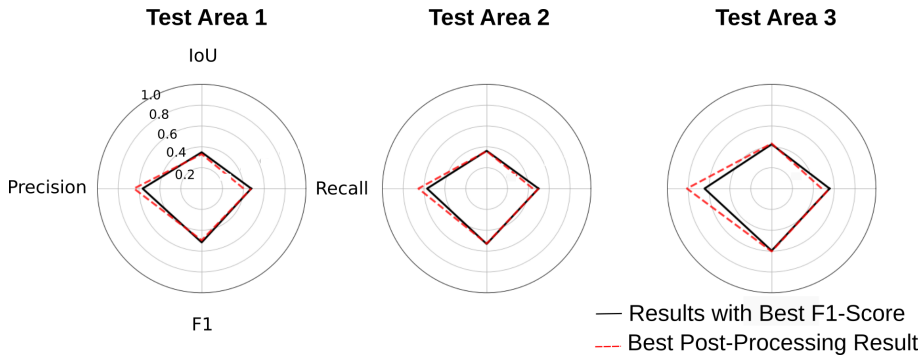

Figure 9. F1 score, recall, precision, and mIoU of the best segmentation results of each test area after the post-processing operations. The data used for the post-processing operations correspond to the prediction of the model trained with 128 × 128 pixel tiles and dataset 3 for TA1; the model trained with 32 × 32 pixel tiles and dataset 1 for TA2, and the model trained with 64 × 64 pixel tiles and dataset 1 for TA3.

The morphological operations were evaluated individually and in combination; Table 2 shows the best three combinations' average results for each test area. TA2 and TA3 achieved the best results with the same operations (dilation; closing/dilation; erosion/opening/closing), while in TA1, the operations that yielded the best results were opening; erosion/dilation; and dilation/erosion/opening. Such similarity in the post-processing of TA2 and TA3 and the difference with TA1 may be related to the environmental differences in the training area and the prediction pattern of the model. TA3 achieved better precision results in comparison with the other test areas. This difference seems to be related to each area's landslide characteristics and the model results. Therefore, post-processing operations cannot be generalized and different operations should be tested to find the optimal solution.

Table 2. Best post-processing operations and results for each test area. The best results were calculated by summing all the result values. Values in bold represent the best results before the post-processing operations.

Area	Operation	Recall	Precision	F1-Score	mIoU
TA1	**-**	**0.57**	**0.47**	**0.52**	**0.35**
TA1	Opening Erosion + Dilation Dilation + Erosion + Opening	0.48	0.56	0.52	0.35
TA2	**-**	**0.50**	**0.57**	**0.53**	**0.36**
TA2	Dilation Closing + Dilation Erosion + Opening + Closing	0.44	0.65	0.53	0.36
TA3	**-**	**0.56**	**0.64**	**0.60**	**0.42**
TA3	Dilation Closing + Dilation Erosion + Opening + Closing	0.48	0.81	0.60	0.43

5. Conclusions

This study evaluated the generalization capacity of deep learning models and post-processing techniques. The results show that the patch size highly affects the prediction accuracy in areas that are different from the training zone. The larger patch improved the test area results that were close to the training area because larger patches favor a global comprehension of the scene. Consequently, the model becomes specialized in detecting landslides similar to the ones used for the training. On the other hand, the models trained with the smaller patches achieved better results in TA2 and TA3 in locations different from the training zone. This is because the models trained with smaller patches understand the

local context better; they can predict the landslides in a more satisfactory way in different locations. Nevertheless, they also tend to be more restrictive and make more false negative errors. The complexity of the scene is directly correlated with the performance of the models. Therefore, comparing results obtained from different authors, and from different data acquisition methods, such as lidar and Remote Piloted Aircrafts (RPA), may not be reasonable since each training and test area has its own characteristics and complexities. In this way, to better evaluate the machine and deep learning models, a future effort should be made towards an open dataset to evaluate landslide deep learning models. Such open datasets are standard in other computer vision studies such as ImageNet [101], MNIST [102], EuroSat [103] UC Merced Land Use Dataset [104], AID dataset [105], and Brazilian Coffee Scene [106]. Post-processing the results is an efficient step to improve the precision of the segmentation results. The TA3 results improved by 0.17 after combining binary erosion, opening, and closing. The best method to post-process the results will depend on the landslides' characteristics and the model results. Therefore, one should test different combinations and parameters in a semi-supervised way to find the optimal solution. The use of spectral indexes seems to help in balancing the precision and recall of the models and improving model generalization. Since spectral indexes have comparable ranges that facilitate model convergence, the calculation of these indexes is important for predicting landslides in areas with different characteristics from the training areas. Future work should evaluate whether the use of these indexes also facilitates landslide detection in images from different sensors and resolutions.

Supplementary Materials: The following supporting information can be downloaded at: https://www.mdpi.com/article/10.3390/rs14092237/, Table S1: Post-processing operation results.

Author Contributions: Conceptualization, L.P.S. and C.H.G.; methodology, L.P.S.; software, L.P.S.; validation, L.P.S.; formal analysis, L.P.S., H.C.D. and G.P.B.G.; investigation, L.P.S., H.C.D. and G.P.B.G.; resources, L.P.S.; data curation, L.P.S., H.C.D. and G.P.B.G.; writing—original draft preparation, L.P.S.; writing—review and editing, L.P.S., C.H.G., H.C.D. and G.P.B.G.; visualization, L.P.S.; supervision, C.H.G.; project administration, C.H.G.; funding acquisition, L.P.S. and C.H.G. All authors have read and agreed to the published version of the manuscript.

Funding: This study was funded by the Sao Paulo Research Foundation (FAPESP) grants #2019/17555-1, #2016/06628-0, and #2019/26568-0 and by Brazil's National Council of Scientific and Technological Development, CNPq grants #423481/2018-5 and #304413/2018-6. This study was financed in part by CAPES Brasil—Finance Code 001.

Data Availability Statement: The code used in this research is available at the following link: https://github.com/SPAMLab/data_sharing/tree/main/Landslide_Segmentation_with_Deep_Learning_Evaluating_Model_Generalization_in_Rainfall-Induced_Landslides_in_Brazil (accessed on 1 May 2021).

Acknowledgments: Acknowledgments are extended to the Editor-in-Chief and the anonymous reviewers for their critique and suggestions, which helped to improve this paper.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Metternicht, G.; Hurni, L.; Gogu, R. Remote sensing of landslides: An analysis of the potential contribution to geo-spatial systems for hazard assessment in mountainous environments. *Remote Sens. Environ.* **2005**, *98*, 284–303. [CrossRef]
2. Froude, M.J.; Petley, D.N. Global fatal landslide occurrence from 2004 to 2016. *Nat. Hazards Earth Syst. Sci.* **2018**, *18*, 2161–2181. [CrossRef]
3. Schuster, R.L.; Highland, L.M. The Third Hans Cloos Lecture. Urban landslides: Socioeconomic impacts and overview of mitigative strategies. *Bull. Eng. Geol. Environ.* **2007**, *66*, 1–27. [CrossRef]
4. Yi, Y.; Zhang, Z.; Zhang, W.; Zhang, C.; Li, W.; Zhao, T. Semantic segmentation of urban buildings from VHR remote sensing imagery using a deep convolutional neural network. *Remote Sens.* **2019**, *11*, 1774. [CrossRef]
5. Hong, H.; Chen, W.; Xu, C.; Youssef, A.M.; Pradhan, B.; Tien Bui, D. Rainfall-induced landslide susceptibility assessment at the Chongren area (China) using frequency ratio, certainty factor, and index of entropy. *Geocarto Int.* **2017**, *32*, 139–154. [CrossRef]

6. Alexander, D.E. A brief survey of GIS in mass-movement studies, with reflections on theory and methods. *Geomorphology* **2008**, *94*, 261–267. [CrossRef]
7. Zhong, C.; Liu, Y.; Gao, P.; Chen, W.; Li, H.; Hou, Y.; Nuremanguli, T.; Ma, H. Landslide mapping with remote sensing: Challenges and opportunities. *Int. J. Remote Sens.* **2019**, *41*, 1555–1581. [CrossRef]
8. Tominaga, L.K.; Santoro, J.; Amaral, R. *Desastres Naturais*; Instituto Geológico: São Paulo, Brazil, 2009.
9. CRED. EM-DAT: The International Emergency Disasters Database. 2022. Available online: https://www.emdat.be/ (accessed on 1 May 2022).
10. Coelho-Netto, A.L.; de Souza Avelar, A.; Lacerda, W.A. Landslides and disasters in southeastern and southern Brazil. *Dev. Earth Surf. Process.* **2009**, *13*, 223–243.
11. Netto, A.L.C.; Sato, A.M.; de Souza Avelar, A.; Vianna, L.G.G.; Araújo, I.S.; Ferreira, D.L.; Lima, P.H.; Silva, A.P.A.; Silva, R.P. January 2011: The extreme landslide disaster in Brazil. In *Landslide Science and Practice*; Springer: Berlin/Heidelberg, Germany, 2013; pp. 377–384.
12. Vieira, B.C.; Gramani, M.F. Serra do Mar: The most "tormented" relief in Brazil. In *Landscapes and Landforms of Brazil*; Springer: Berlin/Heidelberg, Germany, 2015; pp. 285–297.
13. Mondini, A.C.; Santangelo, M.; Rocchetti, M.; Rossetto, E.; Manconi, A.; Monserrat, O. Sentinel-1 SAR Amplitude Imagery for Rapid Landslide Detection. *Remote Sens.* **2019**, *11*, 760. [CrossRef]
14. Guzzetti, F.; Mondini, A.C.; Cardinali, M.; Fiorucci, F.; Santangelo, M.; Chang, K.T. Landslide inventory maps: New tools for an old problem. *Earth-Sci. Rev.* **2012**, *112*, 42–66. [CrossRef]
15. Catani, F.; Tofani, V.; Lagomarsino, D. Spatial patterns of landslide dimension: A tool for magnitude mapping. *Geomorphology* **2016**, *273*, 361–373. [CrossRef]
16. Mavroulis, S.; Diakakis, M.; Kranis, H.; Vassilakis, E.; Kapetanidis, V.; Spingos, I.; Kaviris, G.; Skourtsos, E.; Voulgaris, N.; Lekkas, E. Inventory of Historical and Recent Earthquake-Triggered Landslides and Assessment of Related Susceptibility by GIS-Based Analytic Hierarchy Process: The Case of Cephalonia (Ionian Islands, Western Greece). *Appl. Sci.* **2022**, *12*, 2895. [CrossRef]
17. Shao, X.; Ma, S.; Xu, C.; Shen, L.; Lu, Y. Inventory, distribution and geometric characteristics of landslides in Baoshan City, Yunnan Province, China. *Sustainability* **2020**, *12*, 2433. [CrossRef]
18. Ardizzone, F.; Basile, G.; Cardinali, M.; Casagli, N.; Del Conte, S.; Del Ventisette, C.; Fiorucci, F.; Garfagnoli, F.; Gigli, G.; Guzzetti, F.; et al. Landslide inventory map for the Briga and the Giampilieri catchments, NE Sicily, Italy. *J. Maps* **2012**, *8*, 176–180. [CrossRef]
19. Conforti, M.; Muto, F.; Rago, V.; Critelli, S. Landslide inventory map of north-eastern Calabria (South Italy). *J. Maps* **2014**, *10*, 90–102. [CrossRef]
20. Dias, H.C.; Hölbling, D.W.; Grohmann, C.H. Landslide inventory mapping in Brazil: Status and challenges. In Proceedings of the XIII International Symposium on Landslides, virtual, 22–26 February 2021.
21. Marcelino, E.V.; Formagio, A.R. Análise comparativa entre métodos heurísticos de mapeamento de áreas susceptíveis a escorregamento. *Simpósio Bras. Desastr. Nat.* **2004**, *1*, 392–407.
22. Schulz, W.H. Landslide susceptibility revealed by LIDAR imagery and historical records, Seattle, Washington. *Eng. Geol.* **2007**, *89*, 67–87. [CrossRef]
23. Kawabata, D.; Bandibas, J. Landslide susceptibility mapping using geological data, a DEM from ASTER images and an Artificial Neural Network (ANN). *Geomorphology* **2009**, *113*, 97–109. [CrossRef]
24. Chen, H.; Zeng, Z. Deformation prediction of landslide based on improved back-propagation neural network. *Cogn. Comput.* **2013**, *5*, 56–62. [CrossRef]
25. Du, J.C.; Teng, H.C. 3D laser scanning and GPS technology for landslide earthwork volume estimation. *Autom. Constr.* **2007**, *16*, 657–663. [CrossRef]
26. Lingua, A.; Piatti, D.; Rinaudo, F. Remote monitoring of a landslide using an integration of GB-INSAR and LIDAR techniques. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2008**, *37*, 133–139.
27. Baldo, M.; Bicocchi, C.; Chiocchini, U.; Giordan, D.; Lollino, G. LIDAR monitoring of mass wasting processes: The Radicofani landslide, Province of Siena, Central Italy. *Geomorphology* **2009**, *105*, 193–201. [CrossRef]
28. Jaboyedoff, M.; Oppikofer, T.; Abellán, A.; Derron, M.H.; Loye, A.; Metzger, R.; Pedrazzini, A. Use of LIDAR in landslide investigations: A review. *Nat. Hazards* **2012**, *61*, 5–28. [CrossRef]
29. Brideau, M.A.; McDougall, S.; Stead, D.; Evans, S.G.; Couture, R.; Turner, K. Three-dimensional distinct element modelling and dynamic runout analysis of a landslide in gneissic rock, British Columbia, Canada. *Bull. Eng. Geol. Environ.* **2012**, *71*, 467–486. [CrossRef]
30. Ghuffar, S.; Székely, B.; Roncat, A.; Pfeifer, N. Landslide displacement monitoring using 3D range flow on airborne and terrestrial LiDAR data. *Remote Sens.* **2013**, *5*, 2720–2745. [CrossRef]
31. Casagli, N.; Cigna, F.; Bianchini, S.; Hölbling, D.; Füreder, P.; Righini, G.; Del Conte, S.; Friedl, B.; Schneiderbauer, S.; Iasio, C.; et al. Landslide mapping and monitoring by using radar and optical remote sensing: Examples from the EC-FP7 project SAFER. *Remote Sens. Appl. Soc. Environ.* **2016**, *4*, 92–108. [CrossRef]
32. Hsiao, K.; Liu, J.; Yu, M.; Tseng, Y. Change detection of landslide terrains using ground-based LiDAR data. In Proceedings of the XXth ISPRS Congress, Istanbul, Turkey, Commission VII, WG, Istanbul, Turkey, 12–13 July 2004; Volume 7, p. 5.

33. McKean, J.; Roering, J. Objective landslide detection and surface morphology mapping using high-resolution airborne laser altimetry. *Geomorphology* **2004**, *57*, 331–351. [CrossRef]
34. Glenn, N.F.; Streutker, D.R.; Chadwick, D.J.; Thackray, G.D.; Dorsch, S.J. Analysis of LiDAR-derived topographic information for characterizing and differentiating landslide morphology and activity. *Geomorphology* **2006**, *73*, 131–148. [CrossRef]
35. Dewitte, O.; Jasselette, J.C.; Cornet, Y.; Van Den Eeckhaut, M.; Collignon, A.; Poesen, J.; Demoulin, A. Tracking landslide displacements by multi-temporal DTMs: A combined aerial stereophotogrammetric and LIDAR approach in western Belgium. *Eng. Geol.* **2008**, *99*, 11–22. [CrossRef]
36. Kasai, M.; Ikeda, M.; Asahina, T.; Fujisawa, K. LiDAR-derived DEM evaluation of deep-seated landslides in a steep and rocky region of Japan. *Geomorphology* **2009**, *113*, 57–69. [CrossRef]
37. Liu, J.K.; Chang, K.T.; Rau, J.Y.; Hsu, W.C.; Liao, Z.Y.; Lau, C.C.; Shih, T.Y. The geomorphometry of rainfall-induced landslides in taiwan obtained by airborne lidar and digital photography. In *Geoscience and Remote Sensing*; In-Tech, Inc.: Garching Bei München, Germany, 2009.
38. Burns, W.J.; Coe, J.A.; Kaya, B.S.; Ma, L. Analysis of elevation changes detected from multi-temporal LiDAR surveys in forested landslide terrain in western Oregon. *Environ. Eng. Geosci.* **2010**, *16*, 315–341. [CrossRef]
39. Ventura, G.; Vilardo, G.; Terranova, C.; Sessa, E.B. Tracking and evolution of complex active landslides by multi-temporal airborne LiDAR data: The Montaguto landslide (Southern Italy). *Remote Sens. Environ.* **2011**, *115*, 3237–3248. [CrossRef]
40. Van Westen, C.J.; Castellanos, E.; Kuriakose, S.L. Spatial data for landslide susceptibility, hazard, and vulnerability assessment: An overview. *Eng. Geol.* **2008**, *102*, 112–131. [CrossRef]
41. Korup, O.; Stolle, A. Landslide prediction from machine learning. *Geol. Today* **2014**, *30*, 26–33. [CrossRef]
42. Steger, S.; Brenning, A.; Bell, R.; Glade, T. The influence of systematically incomplete shallow landslide inventories on statistical susceptibility models and suggestions for improvements. *Landslides* **2017**, *14*, 1767–1781. [CrossRef]
43. Nilsen, T.H. *Preliminary Photointerpretation Map of Landslide and Other Surficial Deposits of the Concord 15-Minute Quadrangle and the Oakland West, Richmond, and Part of the San Quentin 7 1/2-Minute Quadrangles, Contra Costa and Alameda Counties, California*; Technical Report; US Geological Survey: Reston, VA, USA, 1973.
44. Guzzetti, F.; Carrara, A.; Cardinali, M.; Reichenbach, P. Landslide hazard evaluation: A review of current techniques and their application in a multi-scale study, Central Italy. *Geomorphology* **1999**, *31*, 181–216. [CrossRef]
45. Van Den Eeckhaut, M.; Poesen, J.; Verstraeten, G.; Vanacker, V.; Moeyersons, J.; Nyssen, J.; Van Beek, L. The effectiveness of hillshade maps and expert knowledge in mapping old deep-seated landslides. *Geomorphology* **2005**, *67*, 351–363. [CrossRef]
46. Booth, A.M.; Roering, J.J.; Perron, J.T. Automated landslide mapping using spectral analysis and high-resolution topographic data: Puget Sound lowlands, Washington, and Portland Hills, Oregon. *Geomorphology* **2009**, *109*, 132–147. [CrossRef]
47. Burns, W.J.; Madin, I. Protocol for Inventory Mapping of Landslide Deposits from Light Detection and Ranging (LiDAR) Imagery. 2009. Available online: https://www.oregongeology.org/pubs/dds/slido/sp-42_onscreen.pdf (accessed on 1 May 2022).
48. Roering, J.J.; Mackey, B.H.; Marshall, J.A.; Sweeney, K.E.; Deligne, N.I.; Booth, A.M.; Handwerger, A.L.; Cerovski-Darriau, C. 'You are HERE': Connecting the dots with airborne lidar for geomorphic fieldwork. *Geomorphology* **2013**, *200*, 172–183. [CrossRef]
49. Scaioni, M.; Longoni, L.; Melillo, V.; Papini, M. Remote sensing for landslide investigations: An overview of recent achievements and perspectives. *Remote Sens.* **2014**, *6*, 9600–9652. [CrossRef]
50. Van Den Eeckhaut, M.; Hervás, J.; Jaedicke, C.; Malet, J.P.; Montanarella, L.; Nadim, F. Statistical modelling of Europe-wide landslide susceptibility using limited landslide inventory data. *Landslides* **2012**, *9*, 357–369. [CrossRef]
51. Knevels, R.; Petschko, H.; Leopold, P.; Brenning, A. Geographic object-based image analysis for automated landslide detection using open source GIS software. *ISPRS Int. J. Geo-Inf.* **2019**, *8*, 551. [CrossRef]
52. Li, Y.; Chen, W. Landslide susceptibility evaluation using hybrid integration of evidential belief function and machine learning techniques. *Water* **2020**, *12*, 113. [CrossRef]
53. Wang, Y.; Fang, Z.; Wang, M.; Peng, L.; Hong, H. Comparative study of landslide susceptibility mapping with different recurrent neural networks. *Comput. Geosci.* **2020**, *138*, 104445. [CrossRef]
54. Xu, C. Preparation of earthquake-triggered landslide inventory maps using remote sensing and GIS technologies: Principles and case studies. *Geosci. Front.* **2015**, *6*, 825–836. [CrossRef]
55. Yu, B.; Chen, F.; Xu, C. Landslide detection based on contour-based deep learning framework in case of national scale of Nepal in 2015. *Comput. Geosci.* **2020**, *135*, 104388. [CrossRef]
56. Blaschke, T. Object based image analysis for remote sensing. *ISPRS J. Photogramm. Remote Sens.* **2010**, *65*, 2–16. [CrossRef]
57. Hossain, M.D.; Chen, D. Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. *ISPRS J. Photogramm. Remote Sens.* **2019**, *150*, 115–134. [CrossRef]
58. Stumpf, A.; Kerle, N. Object-oriented mapping of landslides using Random Forests. *Remote Sens. Environ.* **2011**, *115*, 2564–2577. [CrossRef]
59. Blaschke, T.; Hay, G.J.; Kelly, M.; Lang, S.; Hofmann, P.; Addink, E.; Feitosa, R.Q.; Van der Meer, F.; Van der Werff, H.; Van Coillie, F.; et al. Geographic object-based image analysis–towards a new paradigm. *ISPRS J. Photogramm. Remote Sens.* **2014**, *87*, 180–191. [CrossRef]
60. Prakash, N.; Manconi, A.; Loew, S. Mapping landslides on EO data: Performance of deep learning models vs. traditional machine learning models. *Remote Sens.* **2020**, *12*, 346. [CrossRef]

61. Ghorbanzadeh, O.; Blaschke, T.; Gholamnia, K.; Meena, S.R.; Tiede, D.; Aryal, J. Evaluation of different machine learning methods and deep-learning convolutional neural networks for landslide detection. *Remote Sens.* **2019**, *11*, 196. [CrossRef]
62. Peng, D.; Zhang, Y.; Guan, H. End-to-End Change Detection for High Resolution Satellite Images Using Improved UNet++. *Remote Sens.* **2019**, *11*, 1382. [CrossRef]
63. Zhu, X.X.; Tuia, D.; Mou, L.; Xia, G.S.; Zhang, L.; Xu, F.; Fraundorfer, F. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geosci. Remote Sens. Mag.* **2017**, *5*, 8–36. [CrossRef]
64. Long, J.; Shelhamer, E.; Darrell, T. Fully convolutional networks for semantic segmentation. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA, USA, 7–12 June 2015; pp. 3431–3440.
65. Radovic, M.; Adarkwa, O.; Wang, Q. Object recognition in aerial images using convolutional neural networks. *J. Imaging* **2017**, *3*, 21. [CrossRef]
66. Sameen, M.I.; Pradhan, B. Landslide Detection Using Residual Networks and the Fusion of Spectral and Topographic Information. *IEEE Access* **2019**, *7*, 114363–114373. [CrossRef]
67. Yi, Y.; Zhang, W. A new deep-learning-based approach for earthquake-triggered landslide detection from single-temporal RapidEye satellite imagery. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2020**, *13*, 6166–6176. [CrossRef]
68. Prakash, N.; Manconi, A.; Loew, S. A new strategy to map landslides with a generalized convolutional neural network. *Sci. Rep.* **2021**, *11*, 1–15. [CrossRef]
69. Pradhan, B.; Seeni, M.I.; Nampak, H. Integration of LiDAR and QuickBird data for automatic landslide detection using object-based analysis and random forests. In *Laser Scanning Applications in Landslide Assessment*; Springer: Berlin/Heidelberg, Germany, 2017; pp. 69–81.
70. Avelar, A.S.; Netto, A.L.C.; Lacerda, W.A.; Becker, L.B.; Mendonça, M.B. Mechanisms of the recent catastrophic landslides in the mountainous range of Rio de Janeiro, Brazil. In *Landslide Science and Practice*; Springer: Berlin/Heidelberg, Germany, 2013; pp. 265–270.
71. Dantas, M.E. *Geomorfologia do Estado do Rio de Janeiro*; CPRM. Estudo Geoambiental do Estado do Rio de Janeiro: Brasília, Brazil, 2001.
72. Tupinambá, M.; Heilbron, M.; Duarte, B.P.; de Almeida, J.C.H.; Valladares, C.S.; Pacheco, B.T.; dos Santos Salomão, M.; Conceição, F.R.; da Silva, L.G.E.; de Almeida, C.G.; et al. *Mapa Geológico Folha Nova Friburgo SF-23-Z-B-II*; Technical Report; CPRM—Serviço Geológico do Brasil: Rio de Janeirom, Brazil, 2012.
73. Köppen, W. *Das Geographische System der Klimate*; Gerbrüder Bornträger: Stuttgart, Germany, 1936; Volume 1, Das geographische System der Klimate; pp. 1–44.
74. Sobral, B.S.; Oliveira-Júnior, J.F.; Gois, G.; de Bodas Terassi, P.M.; Muniz-Júnior, J.G.R. Variabilidade espaço-temporal e interanual da chuva no estado do Rio de Janeiro. *Rev. Bras. Climatol.* **2018**, *22*. [CrossRef]
75. Uehara, T.D.T.; Correa, S.P.L.P.; Quevedo, R.P.; Körting, T.S.; Dutra, L.V.; Rennó, C.D. Classification algorithms comparison for landslide scars. *GEOINFO* **2019**, *20*, 158.
76. Gameiro, S.; Quevedo, R.P.; Oliveira, G.; Ruiz, L.; Guasselli, L. Análise e correlação de atributos morfométricos e sua influência nos movimentos de massa ocorridos na Bacia do Rio Rolante, RS. In Proceedings of the Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, Santos, Brazil, 14–17 April 2019; pp. 2880–2883.
77. Quevedo, R.P.; Oliveira, G.; Gameiro, S.; Ruiz, L.; Guasselli, L. Modelagem de áreas suscetíveis a movimentos de massa com redes neurais artificiais. In Proceedings of the Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, Santos, Brazil, 14–17 April 2019; Volume 19, pp. 2910–2913.
78. Quevedo, R.P.; Guasselli, L.A.; Oliveira, G.G.; Ruiz, L.F.C. Modelagem de áreas suscetíveis a movimentos de massa: Avaliação comparativa de técnicas de amostragem, aprendizado de máquina e modelos digitais de elevação. *Geociências* **2020**, *38*, 781–795. [CrossRef]
79. Farr, T.G.; Rosen, P.A.; Caro, E.; Crippen, R.; Duren, R.; Hensley, S.; Kobrick, M.; Paller, M.; Rodriguez, E.; Roth, L.; et al. The Shuttle Radar Topography Mission. *Rev. Geophys.* **2007**, *45*, RG2004. [CrossRef]
80. RapidEye, A. Satellite imagery product specifications. In *Satellite Imagery Product Specifications: Version*; BlackBridge: Lethbridge, AB, Canada, 2011.
81. Planet Team. Planet Application Program Interface: In Space for Life on Earth. 2017. Available online: https://api.planet.com (accessed on 1 May 2020).
82. Tucker, C.J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* **1979**, *8*, 127–150. [CrossRef]
83. Rasterio: Geospatial Raster I/O for Python Programmers. 2013. Available online: https://github.com/rasterio/rasterio (accessed on 1 May 2022).
84. Dixit, M.; Kwitt, R.; Niethammer, M.; Vasconcelos, N. Aga: Attribute-guided augmentation. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, 21–26 July 2017; pp. 7455–7463.
85. Ronneberger, O.; Fischer, P.; Brox, T. U-net: Convolutional networks for biomedical image segmentation. In Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, Munich, Germany, 5–9 October 2015; pp. 234–241.
86. Quinn, J.; McEachen, J.; Fullan, M.; Gardner, M.; Drummy, M. *Dive into Deep Learning: Tools for Engagement*; Corwin Press: Thousand Oaks, CA, USA, 2019.

87. Srivastava, N.; Hinton, G.; Krizhevsky, A.; Sutskever, I.; Salakhutdinov, R. Dropout: A simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res.* **2014**, *15*, 1929–1958.
88. Keras. 2015. Available online: https://keras.io/ (accessed on 1 May 2022).
89. Abadi, M.; Agarwal, A.; Barham, P.; Brevdo, E.; Chen, Z.; Citro, C.; Corrado, G.S.; Davis, A.; Dean, J.; Devin, M.; et al. TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems. 2015. Available online: tensorflow.org (accessed on 1 May 2022).
90. Ghorbanzadeh, O.; Tiede, D.; Dabiri, Z.; Sudmanns, M.; Lang, S. Dwelling extraction in refugee camps using cnn–first experiences and lessons learnt. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2018**. [CrossRef]
91. Guirado, E.; Tabik, S.; Alcaraz-Segura, D.; Cabello, J.; Herrera, F. Deep-learning convolutional neural networks for scattered shrub detection with google earth imagery. *arXiv* **2017**, arXiv:1706.00917.
92. Van der Walt, S.; Schönberger, J.L.; Nunez-Iglesias, J.; Boulogne, F.; Warner, J.D.; Yager, N.; Gouillart, E.; Yu, T. Scikit-image: Image processing in Python. *PeerJ* **2014**, *2*, e453. [CrossRef]
93. Soares, L.P.; Dias, H.C.; Grohmann, C.H. Landslide segmentation with u-net: Evaluating different sampling methods and patch sizes. *arXiv* **2020**, arXiv:2007.06672.
94. Hughes, G. On the mean accuracy of statistical pattern recognizers. *IEEE Trans. Inf. Theory* **1968**, *14*, 55–63. [CrossRef]
95. Verstraete, M.M.; Pinty, B. Designing optimal spectral indexes for remote sensing applications. *IEEE Trans. Geosci. Remote Sens.* **1996**, *34*, 1254–1265. [CrossRef]
96. Mondini, A.; Guzzetti, F.; Reichenbach, P.; Rossi, M.; Cardinali, M.; Ardizzone, F. Semi-automatic recognition and mapping of rainfall induced shallow landslides using optical satellite images. *Remote Sens. Environ.* **2011**, *115*, 1743–1757. [CrossRef]
97. Lu, P.; Qin, Y.; Li, Z.; Mondini, A.C.; Casagli, N. Landslide mapping from multi-sensor data through improved change detection-based Markov random field. *Remote Sens. Environ.* **2019**, *231*, 111235. [CrossRef]
98. Qi, W.; Wei, M.; Yang, W.; Xu, C.; Ma, C. Automatic mapping of landslides by the ResU-net. *Remote Sens.* **2020**, *12*, 2487. [CrossRef]
99. Altman, N.; Krzywinski, M. The curse (s) of dimensionality. *Nat. Methods* **2018**, *15*, 399–400. [CrossRef] [PubMed]
100. Ghorbanzadeh, O.; Meena, S.R.; Abadi, H.S.S.; Piralilou, S.T.; Zhiyong, L.; Blaschke, T. Landslide Mapping Using Two Main Deep-Learning Convolution Neural Network Streams Combined by the Dempster–Shafer Model. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2020**, *14*, 452–463. [CrossRef]
101. Krizhevsky, A.; Sutskever, I.; Hinton, G.E. Imagenet classification with deep convolutional neural networks. *Adv. Neural Inf. Process. Syst.* **2012**, *25*, 1097–1105. [CrossRef]
102. Bottou, L.; Cortes, C.; Denker, J.S.; Drucker, H.; Guyon, I.; Jackel, L.D.; LeCun, Y.; Muller, U.A.; Sackinger, E.; Simard, P.; et al. Comparison of classifier methods: A case study in handwritten digit recognition. In Proceedings of the 12th IAPR International Conference on Pattern Recognition, Vol. 3-Conference C: Signal Processing (Cat. No. 94CH3440-5), Jerusalem, Israel, 9–13 October 1994; Volume 2, pp. 77–82.
103. Helber, P.; Bischke, B.; Dengel, A.; Borth, D. Eurosat: A novel dataset and deep learning benchmark for land use and land cover classification. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2019**, *12*, 2217–2226. [CrossRef]
104. Yang, Y.; Newsam, S. Bag-of-visual-words and spatial extensions for land-use classification. In Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems, San Jose, CA, USA, 2–5 November 2010; pp. 270–279.
105. Xia, G.S.; Hu, J.; Hu, F.; Shi, B.; Bai, X.; Zhong, Y.; Zhang, L.; Lu, X. AID: A benchmark data set for performance evaluation of aerial scene classification. *IEEE Trans. Geosci. Remote Sens.* **2017**, *55*, 3965–3981. [CrossRef]
106. Penatti, O.A.; Nogueira, K.; Dos Santos, J.A. Do deep features generalize from everyday objects to remote sensing and aerial scenes domains? In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, Boston, MA, USA, 7–12 June 2015; pp. 44–51.

Anexo I. Coautoria em artigo completo publicado no periódico *MethodsX*

Anexo I.1. *Remotely piloted aircraft -based automated vertical surface survey*

MethodsX 10 (2023) 101982

Contents lists available at ScienceDirect

MethodsX

journal homepage: www.elsevier.com/locate/mex

Method Article

Remotely piloted aircraft-based automated vertical surface survey

Carlos H. Grohmann [a,c,*], Camila D. Viana [b,c], Guilherme P.B. Garcia [b,c], Rafael W. Albuquerque [a,c]

[a] Institute of Energy and Environment (IEE), Universidade de São Paulo (USP), São Paulo 05508-010, Brazil
[b] Institute of Geosciences (IGc), Universidade de São Paulo (USP), São Paulo 05508-080, Brazil
[c] Spatial Analysis And Modelling Lab (SPAMLab) - https://spamlab.github.io/, Brazil

ARTICLE INFO

Method name:
DJI Remotely Piloted Aircraft-based automated vertical surface survey

Keywords:
RPA
Drone
Vertical
Quarry
Mining
Slope stability
Structural geology
Outcrop

ABSTRACT

Remotely Piloted Aircrafts (RPAs) are commonly used as a platform for collecting images which can be processed with Structure from Motion-Multi View Stereo (SfM-MVS) to generate 3D models. However, mobile applications for mapping planning are not designed for image acquisition of vertical surfaces, such as quarry walls or large cliffs, leaving the user to a manual flight operation, which does not ensure optimal overlap between images. Here we describe a workflow, based on the Litchi App, for automated RPA missions designed to acquire images of vertical surfaces or structures.

- An easy-to-follow 8 steps method to survey vertical surfaces using a Remotely Piloted Aircraft.
- It can be applied to outcrops, quarry walls, high cliffs and virtually any other type of vertical surface.
- The workflow is flexible and can be adapted to a variety of target configurations and user-defined parameters.

Specifications table

Subject area:	Earth and Planetary Sciences
More specific subject area:	Geology; Structural Geology
Name of your method:	*DJI Remotely Piloted Aircraft-based automated vertical surface survey*
Name and reference of original method:	*The method was described initially at a conference:* *Grohmann, C.H.; Viana, C.D.; Garcia, G.P.B; Albuquerque, R.W.; Barale, F.; Ferretti, F.A., 2019. Semi-Automatic UAV-based SfM survey of vertical surfaces. XIX Brazilian Symposium on Remote Sensing. Santos, SP.* https://proceedings.science/sbsr-2019/papers/semiautomatic-uav-based-sfm-survey-of-vertical-surfaces
Resource availability:	*Litchi app for DJI drones:* https://flylitchi.com/

Introduction

Remotely Piloted Aircrafts (RPAs) can be programmed to fly automated missions for orthophoto and DEM generation with Structure from Motion–Multi View Stereo (SfM-MVS) [1], where the aircraft usually follows a square grid path while acquiring images at a predefined distance or time intervals. The user can choose from a wide number of applications for flight control, including free or commercial, installed on a computer (desktop/laptop) or mobile device (phone/tablet), and with different sets of features, such as

* Corresponding author at: Institute of Energy and Environment (IEE), Universidade de São Paulo (USP), São Paulo 05508-010, Brazil.
E-mail address: guano@usp.br (C.H. Grohmann).

https://doi.org/10.1016/j.mex.2022.101982
Received 14 October 2022; Accepted 20 December 2022
Available online 21 December 2022
2215-0161/© 2022 The Authors. Published by Elsevier B.V. This is an open access article under the CC BY-NC-ND license (http://creativecommons.org/licenses/by-nc-nd/4.0/)

allowing the RPA to fly at a constant height over the terrain instead of the same height from the take-off point regardless of variations in topography.

Despite the options offered by flight control applications, which include grid flight, double (crossed) grid, flight parallel to linear features (roads, power lines) or orbiting flight around vertical structures (towers), there is no option for automated flight and image acquisition of vertical surfaces, such as quarry walls, outcrops or large cliffs. If the subject of analysis is a vertical surface, the user is left with the option of terrestrial photogrammetry [2,3], which is not well suited for high surfaces, where high camera tilt angles cause image border distortions; or manual RPA flight [4], which will depend on a skilled pilot, will increase operation time and might not assure that the images will be taken from a constant distance from the target or that image overlap and orientation will meet the requirements for a successful 3D reconstruction.

In this work we describe a workflow to program automated RPA missions designed to acquire images of vertical surfaces with the desired parameters of distance to target and overlap, using the Litchi App. The intention is to simulate the grid pattern used for terrain mapping while placing the grid in a vertical plane. This can be achieved by creating an individual mission running parallel to the vertical surface, with waypoints spaced according to the desired lateral image overlap. This mission is then repeated at different heights, proportional to the vertical overlap.

Method

The Litchi App (https://flylitchi.com) is used to program the automated flight of the RPA. Litchi is a commercial (paid) Android/iOS application for DJI RPA control aimed towards photography and video capture. Among its many features, it allows the user to fly on a path defined by waypoints, and to execute up to 15 different 'actions' at each waypoint, such as taking a photograph, rotating the aircraft, tilting the camera gimbal and others. The path and actions joint is called a mission. Although other applications have similar features, Litchi has a 'Mission Hub' (https://flylitchi.com/hub) where missions can be created using a desktop or laptop computer, enabling the possibility of using multiple auxiliary tools (e.g., QGIS, Google Earth) to plan missions in a quick and easy way.

The workflow described here requires a valid Litchi licence, and uses Litchi Mission Hub (via web browser), Google Earth or a GIS software, an ASCII text editor (such as Notepad) and Litchi for mobile devices (for the actual flight). In brief, the steps are:

1. Define lateral and vertical overlap of images, based on the RPA camera specifications.
2. Create the first flight line in Google Earth and save it as a KML file.
3. Import the KML into Mission Hub and edit the actions for first waypoint.
4. Export the mission as a CSV (comma separated file) and open it in a text editor.
5. In the text editor, adjust flight height and duplicate the actions for all waypoints.
6. Save one mission for each required flight height as a CSV.
7. Import the CSV into Mission Hub and save it into the user account.
8. Fly each mission via Litchi Mobile App.

The first step is to define the distances for lateral and vertical overlap of images, based on the image footprint size at the vertical surface. This will vary depending on the RPA used and the desired pixel size (Ground Sampling Distance - GSD). For instance, a DJI Phantom 4 Pro RPA digital camera has an 1'' CMOS 20 MP sensor (13.2 × 8.8 mm), with FOV (Field of View) of 84° and 8.8 mm focal distance (*f* - 24 mm at 35 mm equivalent). Images can be saved as JPEG or RAW, with 5472 × 3648 px (3:2 ratio). If the distance from the camera to the vertical surface (*H*) is set as 20 m, this results in an image footprint (*dw* x *dh*) of 30 × 20 m and a GSD of ~0.5 cm. With this configuration, to achieve a vertical and lateral image overlap of 80% we need to shift the image position by 20% of its width and height, and so the distance between photos needs to be of 6 m horizontally and 4 m vertically for this example (Fig. 1). A simple and free tool that can be used to calculate these dimensions is the 'GSD calculator' provided by Pix4D (https://support.pix4d.com/hc/en-us/articles/202560249-TOOLS-GSD-calculator).

The second step is to create the flight path in Google Earth or in a GIS software. Create a polyline parallel to the surface of interest, with nodes spaced according to the necessary lateral overlap, 6 m for our example, (each node will be a waypoint in Litchi Mission Hub) and export it as a KML file. In Google Earth, the 'Measurements' tab of the path creation dialog window can be used to guide the polyline creation. In QGIS the 'Advanced Digitizing' panel can be used to lock the length and/or angle when moving the mouse. Alternatively, the QGIS menu *Processing* > *Toolbox* > *Split lines by maximum length* tool can be used to split a line in multiple parts with a specified maximum length. For a near planar surface it is reccomended to use a slightly convergent patch to reduce dome error [6].

Next, import the KML file into Litchi Mission Hub (Missions > Import). Checking the "Add Take Photo Action" will automatically add a take photo action to each point of the flight path. Edit manually the parameters only for the first waypoint (Fig. 2). Define flight height above the take-off point (Altitude), set 'curve size' to zero and 'heading' to the azimuth of the first photo.

Then edit the actions (take photo, rotate etc.) for this waypoint. The actions will vary from one application to another, depending on the surface characteristics. It is recommended to evaluate the position and persistence of structures to define the actions so the image set can fully reconstruct the 3D surface. For instance, if there are vertical or near-vertical persistent structures (fractures, faults, etc.) it is recommended to include images with aircraft rotation, while if there are horizontal or near-horizontal persistent structures it is recommended to include images with camera gimbal tilt, limiting the variations to 15° so that there are no image edge distortions.

Once the parameters and actions for the first waypoint are set, export the mission as a CSV (comma separated file) file (Missions > Export as CSV) and open it in an ASCII text editor. The file has a long header with self-explanatory labels, followed by the waypoints

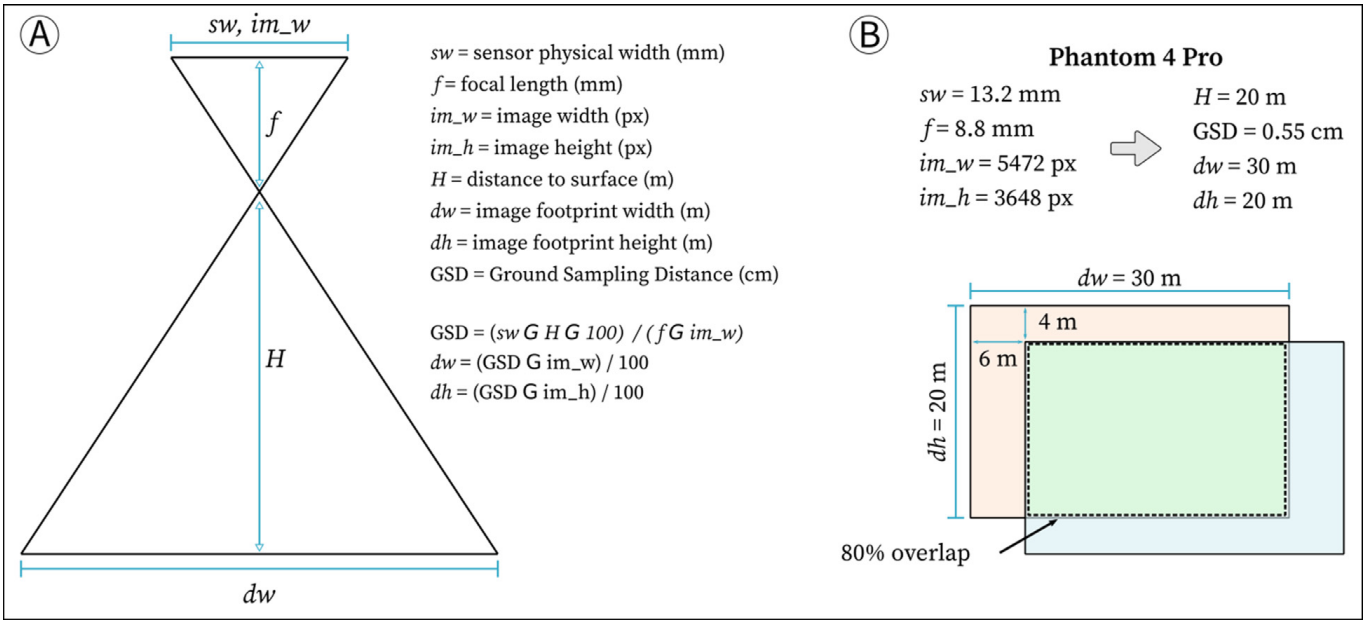

Fig. 1. (A) Determination of image footprint dimensions. (B) Example of calculations with Phantom 4 Pro RPA, distance from surface of 20 m and image overlap of 80% (area in green).

Fig. 2. Litchi Mission Hub with imported polyline (one flight path). The menu is used to define flight parameters and waypoint actions for the first waypoint. In this image, only one flight line is shown, as each flight line correspond to one flight mission.

and their actions (Fig. 3). In the example CSV file shown, the values of the curvesize(m) field were edited and set to zero, or else Litchi will not perform the defined actions at each waypoint but instead will fly through them as if in a video mission.

In the CSV file, each action has a numerical code and an associated parameter, such as: latitude/longitude/altitude(m): coordinates of waypoints heading(deg): azimuth to which the aircraft (and camera) is pointing curvesize(m): radius of curve between waypoints. Must be set to zero actiontype: 0 (stay hovering) actionparam: time in miliseconds actiontype: 1 (take photo) actionparam: 0 (no associated parameter) actiontype: 2 (start recording video) actionparam: 0 (no associated parameter) actiontype: 3 (stop recording video) actionparam: 0 (no associated parameter) actiontype: 4 (rotate aircraft) actionparam: azimuth in degrees actiontype: 5 (rotate gimbal) actionparam: angle in degrees, positive upwards, negative downwards

```
latitude,longitude,altitude(m),heading(deg),curvesize(m),rotationdir,gimbalmode,gimbalpitchangle,
actiontype1,actionparam1,actiontype2,actionparam2,actiontype3,actionparam3,actiontype4,actionparam4,actiontype5,actionparam5,
actiontype6,actionparam6,actiontype7,actionparam7,actiontype8,actionparam8,actiontype9,actionparam9,actiontype10,actionparam10,
actiontype11,actionparam11,actiontype12,actionparam12,actiontype13,actionparam13,actiontype14,actionparam14,actiontype15,actionparam15,
altitudemode,speed(m/s),poi_latitude,poi_longitude,poi_altitude(m),poi_altitudemode
-22.9035544946994,-47.1184402458146,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9036275426808,-47.1184118144023,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9037005906621,-47.1183833829901,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9037736386434,-47.1183549515778,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9038466866247,-47.1183265201655,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9039197346061,-47.1182980887533,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9039927825874,-47.1182696573410,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9040658305687,-47.1182412259287,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9041388785500,-47.1182127945164,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9042119265314,-47.1181843631042,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9042849745127,-47.1181559316919,4,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9043580224940,-47.1181275002796,5,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9044310704753,-47.1180990688674,5,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9045041184566,-47.1180706374551,5,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9045771664380,-47.1180422060428,5,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
-22.9046502144193,-47.1180137746306,5,280,0,0,0,0,0,1000,1,0,4,265,1,0,4,250,1,0,5,-15,1,0,4,265,1,0,4,280,1,0,0,1000,5,0,-1,0,0,0,0,0,0
```

Fig. 3. Example contents of a CSV file defining a Litchi 'waypoint' mission.

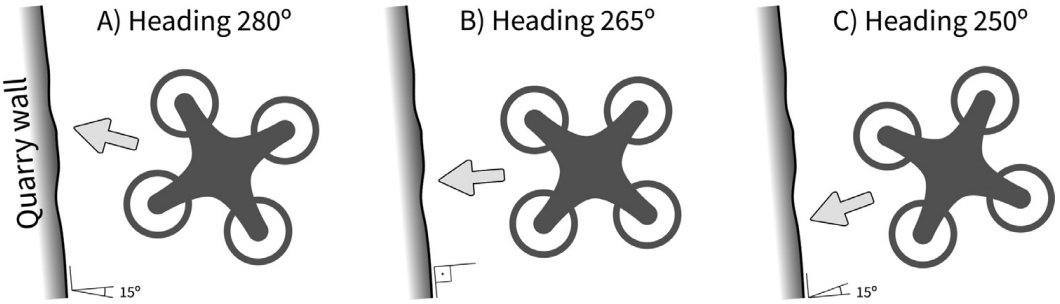

Fig. 4. Scheme of RPA orientation used in the method validation.

From here it is easy to copy/paste the actions of the first waypoint to all the others. Adjust the flight height as needed. Edit and save one CSV file for each flight height (that is, each flight height correspond to one flight mission), according to the vertical overlap defined beforehand. Import all files into Mission Hub and check for any errors. Once the missions are imported into the user's account, they can be opened in the mobile App for flight control. It is always safer to check all missions at the office, while connected to the Internet, which will also allow Litchi to download and cache the base map images, for better visualization during fieldwork.

Method validation

The method was validated in a deactivated quarry used as a recreational area for activities such as rock climbing and aeromodelling. We used a DJI Phantom 4 Pro-RPA, set the distance to the wall as 20 m and distance between photos of 6 m horizontally and 4 m vertically (80% overlap lateral and vertical). To avoid doming effects observed in datasets acquired with cameras positioned only at a perpendicular orientation about the target [5], we planned to acquire images at three orientations: N265° (approximately perpendicular to the quarry wall), N250° and N280° (Fig. 4). Additionally, after these images were obtained, the camera gimbal was tilted −15° (downwards from the horizontal position) and the images reacquired, in a total of 6 images per waypoint.

The following actions were defined for each waypoint:

1. Hover for 1 s (to stabilize the RPA).
2. Take photo (aircraft is oriented at initial 'heading' setting of N280° – Fig. 4A).
3. Rotate aircraft to N265°.
4. Take photo (Fig. 4B).
5. Rotate aircraft to N250°.
6. Take photo (Fig. 4C).
7. Tilt camera gimbal −15°.
8. Take photo;
9. Rotate aircraft back to N265°.
10. Take photo.
11. Rotate aircraft back to N280°.
12. Take photo.
13. Hover for 1 s.
14. Tilt camera gimbal back to 0°.

In this case, the ground was gently sloping so the last point was about one meter below the first one; the height of the waypoints was adjusted so the last points were one meter above the take-off point. In our fieldwork, each flight line (with 16 waypoints) was

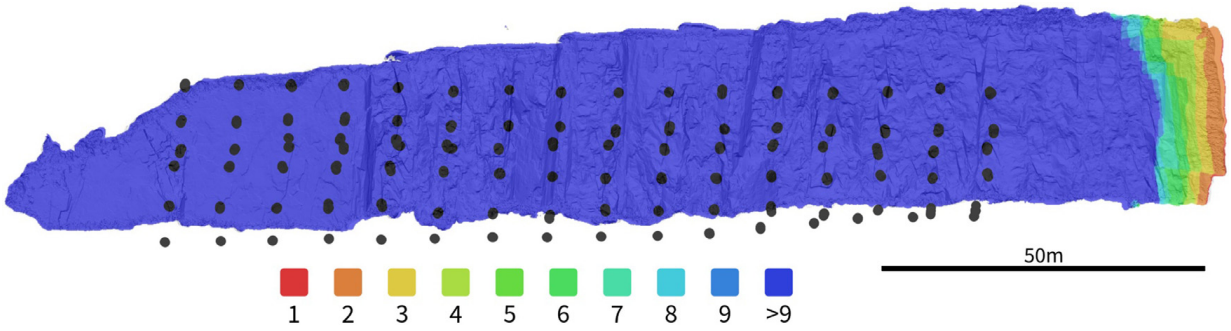

Fig. 5. Image overlap map of the quarry wall, with camera positions (black dots). Note the regular layout of flight lines. Colors represent number of overlapping photos in each sector of the quarry wall.

Fig. 6. Resulting 3D model of the quarry wall.

Fig. 7. Detail of the reconstructed dense cloud. Note that persistent horizontal and vertical planes were correctly reconstructed.

flown in about 8 min (i.e., one mission per flight line). Total operation time, including returning the RPA to the initial position, uploading the new mission and replacing the battery (each battery was used in two missions) was around 1:15". The layout of the flight lines and waypoints resulted in an image overlap greater than nine photos for almost all the wall area (Fig. 5). Small deviations of the flights pattern from a perfect grid are expected due the precision of the onboard GPS used for navigation.

The 3D model of the quarry wall (Fig. 6) was generated with Agisoft Metashape Professional using 534 images. Photos containing features such as sky and vegetation were masked to reduce processing time. The SfM step of the reconstruction identified 129,806 tie points between the images; using the 'high quality' setting, the MVS step produced a dense cloud with 39,599,660 points which was interpolated to a 3D mesh with 7,919,932 faces. The images taken at different azimuths and inclinations allowed the correct reconstruction of horizontal and vertical persistent structures on the rock wall (Fig. 7).

The workflow is flexible and can be adapted to a variety of target configurations and user-defined parameters. Flight missions can be saved and shared, ensuring not only repeatability but also reproducibility of data collection.

Ethics statements

Not applicable.

Declaration of Competing Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

CRediT authorship contribution statement

Carlos H. Grohmann: Conceptualization, Methodology, Software, Validation, Formal analysis, Investigation, Resources, Writing – original draft, Writing – review & editing, Visualization, Supervision, Project administration, Funding acquisition. **Camila D. Viana:** Methodology, Software, Formal analysis, Resources, Writing – review & editing, Visualization. **Guilherme P.B. Garcia:** Validation, Formal analysis, Investigation, Writing – review & editing. **Rafael W. Albuquerque:** Validation, Formal analysis, Investigation, Writing – review & editing.

Data Availability

Related data can be accessed at https://github.com/SPAMLab/data_sharing.

Acknowledgments

This project was supported by FAPESP (grants #2016/06628-0, #2019/26568-0) and CNPq (grant # 311209/2021-1). During the development of this method, C.D.V., G.P.B.G. and R.W.A. were PhD students financed by CAPES Brasil (Finance Code 001).

References

[1] M.J. Westoby, J. Brasington, N.F. Glasser, M.J. Hambrey, J.M. Reynolds, 'Structure-from-Motion' photogrammetry: a low-cost, effective tool for geoscience applications, Geomorphology 179 (2012) 300–314, doi:10.1016/j.geomorph.2012.08.021.
[2] W.C. Haneberg, Using close range terrestrial digital photogrammetry for 3-D rock slope modeling and discontinuity mapping in the United States, Bull. Eng. Geol. Environ. 67 (4) (2008) 457–469, doi:10.1007/s10064-008-0157-y.
[3] M. Sturzenegger, D. Stead, Close-range terrestrial digital photogrammetry and terrestrial laser scanning for discontinuity characterization on rock cuts, Eng. Geol. 106 (3–4) (2009) 163–182, doi:10.1016/j.enggeo.2009.03.004.
[4] A.J. Cawood, C.E. Bond, J.A. Howell, R.W.H. Butler, Y. Totake, LiDAR, UAV or compass-clinometer? Accuracy, coverage and the effects on structural models, J. Struct. Geol. (2017), doi:10.1016/j.jsg.2017.04.004.
[5] M.R. James, S. Robson, Mitigating systematic error in topographic models derived from UAV and ground-based image networks, Earth Surf. Process. Landf. 39 (10) (2014) 1413–1420, doi:10.1002/esp.3609.
[6] E. Sanz-Ablanedo, J.H. Chandler, P. Ballesteros-Pérez, J.R. Rodríguez-Pérez, Reducing systematic dome errors in digital elevation models through better UAV flight design. Earth surf, Process. Landf. 45 (2020) 2134–2147, doi:10.1002/esp.4871.

Anexo J. Coautoria em capítulo do livro intitulado *Earth Observation Applications to Landslide Mapping, Monitoring and Modelling* previsto para ser lançado em Outubro de 2023

Anexo J.1. *Landslide 3D reconstruction and monitoring using drone aerial imagery*

CHAPTER

11

Landslide 3D reconstruction and monitoring using drone aerial imagery

Carlos, Henrique, Grohmann, MSc, DSc, University of Sao Paulo, Institute of Energy and Environment, Sao Paulo, Brazil

Carlos Henrique Grohmann[1,6], Guilherme P.B. Garcia[2,6], Camila Duelis Viana[2,6], Helen Cristina Dias[1,6], Marcelo F. Gramani[3,6], Luiz Fernando dos Santos[4,6], Amanda Mendes de Sousa[5,6], Lucas Pedrosa Soares[2,6], Rebeca Durço Coelho[2,6]

1 - Institute of Energy and Environment, University of São Paulo (IEE-USP), São Paulo, SP, 05508-010, Brazil (guano@usp.br , helen.dias@usp.br)

2 - Institute of Geosciences, University of São Paulo (IGc-USP), São Paulo, SP, 05508-080, Brazil (guilherme.pereira.garcia@usp.br , camila.viana@usp.br , lpsoares@usp.br , rebeca.coelho@usp.br)

3 - São Paulo Institute of Technological Research (IPT-SP), São Paulo, SP, 05508-901, Brazil (mgramani@ipt.br)

4 - Geological Survey of Brazil (GSB-CPRM), São Paulo, SP, 01304-010, Brazil (luiz.fernando@cprm.gov.br)

5 - Municipal Department of Urban Planning and Licensing (SMUL), São Paulo City Hall, São Paulo, SP, 01011-100, Brazil (amanda_mendes@usp.br)

6 - Spatial Analysis and Modelling Lab (SPAMLab, IEE-USP, https://spamlab.github.io/)

UNCORRECTED PROOF NOT FOR DISTRIBUTION

1 – Introduction

Remotely Piloted Aircrafts (RPAs), also called Uncrewed Aerial Vehicles (UAVs), Uncrewed Aircraft Systems (UASs), or simply "drones", are essential tools to acquire high-resolution geospatial data in various scientific fields (Colomina & Molina, 2014; Kelleher et al., 2018; Niedzielski, 2018). RPAs offer an easy-to-use, low-cost, and off-the-shelf solution to capture aerial imagery, geophysical data, or collect samples, depending on the payload carried by these platforms.

Digital imagery collected by RPAs can be used to generate high-resolution (i.e., centimeter-level) Digital Elevation Models (DEMs) using Structure from Motion-Multi View Stereo (SfM-MVS) algorithms (Carrivick et al., 2016; Westoby et al., 2012). Given that most cameras onboard RPAs operate on the visible and near-infrared spectrum, the SfM-MVS process will produce a Digital Surface Model (DSM), that is, a surface that represents the top of the canopy and man-made structures (Guth et al., 2021).The DSM might be filtered to produce a Digital Terrain Model (DTM) representing the "bare-earth" or ground surface, although the effectiveness of these procedures will depend on the characteristics of each location (Anders et al., 2019; Pijl et al., 2020).

Before the popularization of RPAs and SfM-MVS, high-resolution elevation data have been collected over the last two decades by lidar (light detection and ranging), using terrestrial (Buckley et al., 2008) or airborne platforms (Carter et al., 2001). The possibility to record multiple returns, or the full return waveform, for each emitted laser pulse allows effective filtering of above-ground elements such as dense vegetation (Brovelli et al., 2004; Khosravipour et al., 2016; Zhang et al., 2016).

RPAs as platforms for lidar sensors provide another option for high-resolution terrain mapping. However, this is a recent technological development and most of the publications found in scholarly databases refer to forestry applications (da Costa et al., 2021) or powerline inspection (Guan et al., 2021).

The first applications of lidar on the study of landslides are from the early 2000s. (Hobbs et al., 2002) applied terrestrial lidar to map a number of cliff surfaces in southeast England and discuss the influence of geology and climate on cliff recession and landslide occurrence. (McKean & Roering, 2004) analyzed the surface morphology of a landslide complex near Christchurch, New Zealand, based on airborne lidar data, and used patterns of surface roughness to delimit the slide from non-slide and to identify morphological domains within the landslide.

Nearly a decade later, (Niethammer et al., 2012, 2009, 2005) presented the first studies of landslides based on RPA imagery. The authors developed a quad-rotor RPA and performed a manual flight over the Super-Sauze landslide (southern French Alps). The photographs were captured by a low-budget camera and used to produce an orthomosaic; it wasn't possible to create a DEM due to the low overlap of the

images. The RPA orthomosaic was compared to an airborne orthomosaic of the previous year, and the authors were able to determine displacements in the range of 2.7 m to 55.4 m between the surveys.

In Brazil, the use of RPAs to study landslides is still incipient. (Santos da Silva, 2017) used SfM-MVS to analyze mass movements on selected sites of the Vitória-Minas Railroad (southeastern Brazil). (Garcia et al., 2019) and (L. F. Santos, 2020) considered the RPA-derived data to be similar to airborne and terrestrial lidar when assessing landslides. Other studies include slope stability, definition of source and depositional areas, estimation of volume and material types, and risk analysis (Duarte, 2018; Gramani et al., 2018; Lima, 2019; Niemann, 2019; L. F. Santos & Grohmann, 2019).

Figure 11.1 shows the results of a bibliographic search on the Scopus(™) database using keywords for "landslide", combined with "drone, UAV, UAS, RPA", "lidar, laser scanner" and "structure from motion, sfm". While the majority of articles focus on lidar data (airborne and terrestrial), there is a growing trend of research based on SfM-MVS, and a steep increase in the use of RPAs as a platform for analysis of landslides. For comprehensive reviews on the use of RPAs and remote sensing in the study of landslides and disaster response, the reader is referred to (Casagli et al., 2017; Giordan et al., 2020; Gomez & Purdie, 2016).

This chapter analyzes how the flight paths of RPA surveys and the presence/absence of Ground Control Points will impact the surface reconstruction of a stable landslide in southeastern Brazil. We compare the SfM-MVS results from two surveys campaigns in terms of their completeness, georeferencing, and morphometry. Based on the results, we discuss their implications in terms of different scenarios, such as multi-temporal monitoring or situations of rapid response to landslide events.

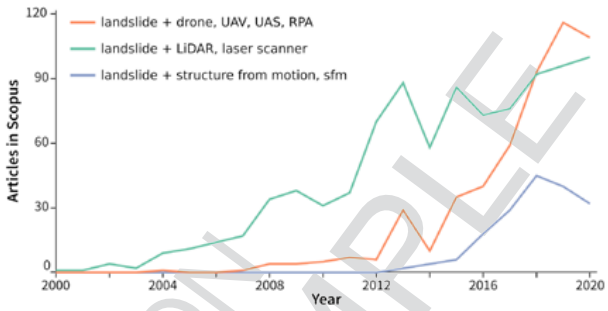

Fig. 11.1 Plot of articles published since 2000 with subjects related to the use of RPAs in the study of landslides. No Permission Required An increasing trend of articles published since 2000 with subjects related to the use of RPAs in the study of landslides. Data retrieved from Scopus on 2021-07-21 using the queries "landslide AND drone", "landslide AND RPA OR RPAS", "landslide AND UAV OR UAVS", "landslide AND UAS OR UASS", "landslide AND structure from motion", "landslide AND sfm", "landslide AND sfm-mvs", "landslide AND lidar", "landslide AND laser scanner". The queries results were combined to produce the plot.

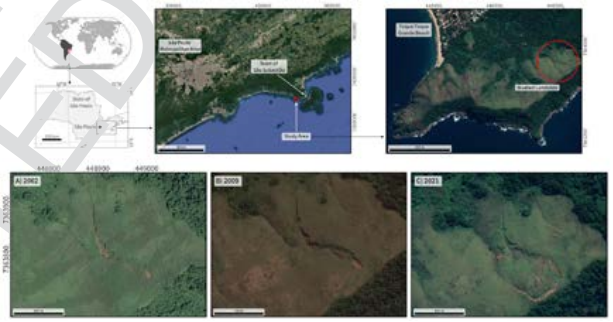

Fig. 11.2 Location of the study area in southeastern Brazil and historical satellite imagery showing the development of the studied landslide. SPAMLab/IEE-USP. Satellite images provided by Google, Maxar Technologies. Location of the study area in southeastern Brazil and historical satellite imagery showing the development of the studied landslide.

2 - Study Area

The area selected is located in the Town of São Sebastião, São Paulo State, southeastern Brazil. It consists of a hillslope vegetated by tall grass with a shallow landslide measuring approximately 250x100 m (Figure 11.2). Historical satellite imagery shows that the first ruptures of the landslide occurred around the year 2002 (Figure 11.2A).

The local climate is defined as Af (Tropical Wet Climate), without dry season (Köppen, 1936). Precipitation can exceed 2000 mm in spring and summer and reach 500 mm in the fall and winter (D. D. dos Santos & Galvani, 2014). Natural vegetation coverage is a dense ombrophilous forest with trees 15 to 40 m high (Atlantic Forest).

3 - Methods

Fieldwork for the RPA surveys was carried out in October 2019 and May 2021. Images for the SfM-MVS reconstruction were acquired by a DJI Phantom 4 Pro V2 RPA, carrying a 1′ ′ CMOS 20 MP sensor, with global shutter and 8.8 mm focal distance (24 mm at 35 mm equivalent), which is capable of produce results with accuracies similar to enterprise-grade RPAs (Stark et al., 2021). Flight missions were planned and executed with the MapPilot app (https://www.mapsmadeeasy.com/) using the "Terrain Aware" option to plan flights with constant height above ground, providing a constant Ground Sampling Distance (GSD) throughout the study area (Mosbrucker et al., 2017), regardless of elevation differences. The flight height is based on an SRTM DEM (Farr et al., 2007).

UNCORRECTED PROOF NOT FOR DISTRIBUTION

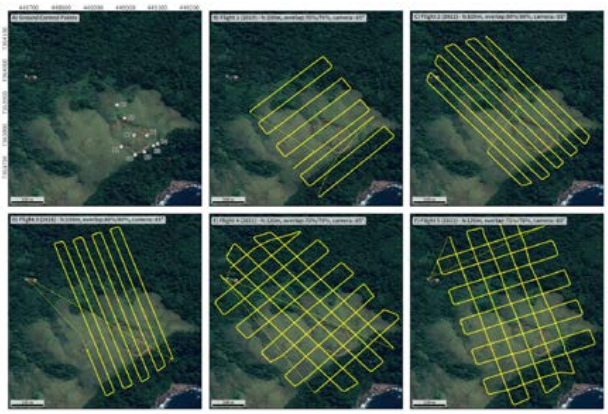

Fig. 11.3 Ground control points and flight missions SPAMLab/IEE-USP. Satellite images provided by Google, Maxar Technologies. A) Ground Control Points used for georeferencing the SfM-MVS reconstructions. B-F) Flight missions of the RPA surveys. Dashed lines indicate the RPA path to and from the takeoff point.

The 2019 campaign had a reconnaissance objective, so the RPA flights were performed without deploying targets to be used as Ground Control Points (GCPs) for georeferencing the SfM-MVS output (Harwin et al., 2015). Two missions were flown (Flight #1 - Figure 11.3B) with height above ground of 100 m, 70% overlap along and across-track, and camera positioned at -85º.

In the 2021 campaign, nine targets were positioned around the landslide area (Figure 11.3A), and their coordinates were determined by Differential Global Positioning System (DGPS). A Spectra Precision SP60 DGPS was used in a base-rover static configuration, and raw data were post-processed in Survey Office 4.10 software (https://spectrageospatial.com/), using the Ubatuba Station of the Brazilian GPS Network as reference.

The flight missions were planned to allow a comparison of different flight patterns in the landslide 3D reconstruction. Two simple patterns were flown with height above ground of 100 m, 80% overlap along and across-track, and camera positioned at -85º (Flights #2 and #3 - Figure 11.3C,D). Two "cross-grid" patterns were flown with height above ground of 120 m, 70% overlap along and across-track, and camera positioned at -85º (Flights #4 and #5 - Figure 11.3E,F). Each flight was processed individually as well as the combination of flights #2+#3 and #4+#5. The combination of flight lines with different orientations is recommended to mitigate distortions from the camera's self-calibration (James & Robson, 2014), while the combination of cross-grid patterns with lower overlap intents to simulate the amount of overlap of the simple pattern flights, but with flight plans that are faster to execute (OpenDroneMap Community, 2020).

The SfM-MVS workflow (James et al., 2019; Viana et al., 2018; Westoby et al., 2012) was processed in Agisoft Metashape Pro version 1.7.1 (https://www.agisoft.com). In the SfM step, images were aligned with 'High' accuracy. Camera alignment optimization was performed considering a marker accuracy of 0.005 m. The MVS reconstruction was set to 'High' quality and 'Moderate' depth filtering.

Data analysis was performed in GRASS-GIS version 7.8 (GRASS Development Team, 2020; Neteler et al., 2012) through Jupyter notebooks (Kluyver et al., 2016; Rule et al., 2019). Data access and statistical analyses relied on the Python libraries Pygrass, Rasterio, Scipy, Numpy, Pandas, Seaborn, and Matplotlib (Gillies, 2020; Harris et al., 2020; Hunter, 2007; McKinney, 2011; Oliphant, 2007; The SciPy community, 2013; Waskom et al., 2016; Zambelli et al., 2013). All processing was carried out in a computer with Intel^{R} Core^{TM} i9 processor with 2.80GHz, 64 GB of RAM memory, and NVIDIA GeForce RTX 3060 Ti with 8 GB RAM Graphic Processing Unit (GPU).

As a first comparison of the SfM-MVS results, we evaluated the 'completeness' of the reconstructions. The point clouds were imported into GRASS-GIS using the *r.in.xyz* module as rasters with 10 cm resolution. We set a mask to limit the analysis to the mid and upper portion of the landslide and counted the number of empty (void) pixels.

The subsequent analyses were run using DSMs with 25 cm resolution. The point clouds were imported using the *r.in.xyz* module, and the voids were filled with bilinear splines (Brovelli & Cannata, 2004). We evaluated the descriptive statistics of each DSM as well as topographic profiles and surface roughness.

Surface roughness measures the variability of the topography at a given scale (Berti et al., 2013; C.H. Grohmann et al., 2011; M. W. Smith, 2014) and was calculated as the standard deviation of slope (C.H. Grohmann et al., 2011) using moving-windows with 3x3 pixels. Additionally, shaded relief maps were also used for a visual comparison of the DSMs; the maps were created in GRASS-GIS with artificial illuminant positioned at 30º azimuth, 30º above the horizon.

4 - Results

Processing of the DGPS data resulted in horizontal precision ranging from 0.003-0.005 m and vertical precision between 0.007-0.012 m. The characteristics of the point clouds from the SfM-MVS workflow are summarized in Table 11.1, including the processing time of each step and the number of voids (i.e., empty 10 cm pixels). shows the distribution of voids for the 2021 flights (2-5 and combinations).

Processing time ranged from ~10' for flight #1 (2019) to ~30' for the single and cross-grid flights (2021), up to ~1:30' for the combined flights. The combination of flights resulted in a significant decrease in the number of voids, both for the simple and the cross-grid flight patterns (Figure 11.4C and F).

UNDER DISTRIBUTION
UNCORRECTED TEXT

Table 11.1 Characteristics of the point clouds obtained by SfM-MVS.

Characteristics of the point clouds obtained by SfM-MVS.

Flight	# of Photos	# of points SfM	Time SfM	# of points MVS	Time MVS	Total time	Ortho-photo resolu-tion (m)	Voids
1	90	262,691		62,228,877	00:08:35	00:09:59	0.030	17094
2	240	701,467			00:31:46	00:36:47	0.027	5206
3	208	585,187			00:25:49	00:29:59	0.025	5905
2+3	448	1,285,173			01:22:35	01:33:24	0.026	1448
4	157	496,613			00:17:31	00:20:48	0.032	13710
5	209	572,845			00:30:17	00:35:41	0.032	9220
4+5	366	1,061,729			01:13:10	01:24:17	0.030	3310

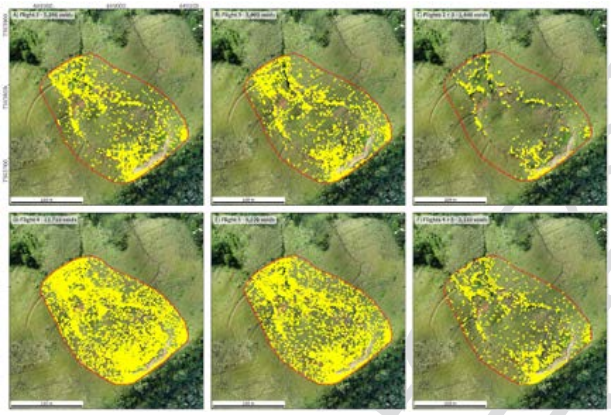

Fig. 11.4 Distribution of voids for the analyzed flight missions SPAMLab/IEE-USP Distribution of voids for the analyzed flight missions. Each dot represents one empty 10 cm pixel. The underlying image is the orthomosaic produced with data from flight #2.

The combination of the cross-grid flights #4 and #5 resulted in a dense point cloud with a similar number of points to the simple flights #2 or #3, despite a longer processing time. The combination of simple flights #2 and #3 resulted in ~3-4x fewer voids than in the simple flights, occurring mainly in areas of shadows or dense vegetation.

Five topographic profiles were extracted from the DSMs with 25 cm resolution (Figure 11.5). The results from the 2021 flights are all very similar, and no visual differences can be identified (solid lines in Figure 11.5). Profiles from the 2019 flight (dashed lines in Figure 11.5), in which no GCPs were used, show only a small difference in the horizontal position compared to the 2021 flights. The vertical position, on the other hand, is almost 60 meters lower than its true value.

Descriptive statistics of the 25 cm-resolution DSMs are presented in Table 11.2. All DSMs from the 2021 campaign show similar results, with minor differences in the minimum and maximum values. In the histograms of Figure 11.6, the curves of the 2021 DSMs overlap almost perfectly, except for the interval between 20 m and 40 m, which corresponds to the densely vegetated area in the NW portion of the surveys. The curve of the 2019 flight shows a similar shape to the 2021 flights, but shifted to the left in the X-axis, as a consequence of the difference of ~60 m in elevation.

Considering the similarities between the DSMs, slope and surface roughness are presented only for the combination of flights #2 and #3. In the slope map (Figure 11.7A), the landslide area is well delineated in its full extension. The main scarp can be isolated from the displaced mass and it is also possible to identify small steps within the landslide. Surface roughness (Figure 11.7C), calculated as the standard deviation of slope in a 3x3 window, does show clearly the upper break-of-slope of the main scarp, although the steps identified in the slope map are not so easily observed. While figures 7A and 7C show the maps with a standard application of the 'viridis' colormap

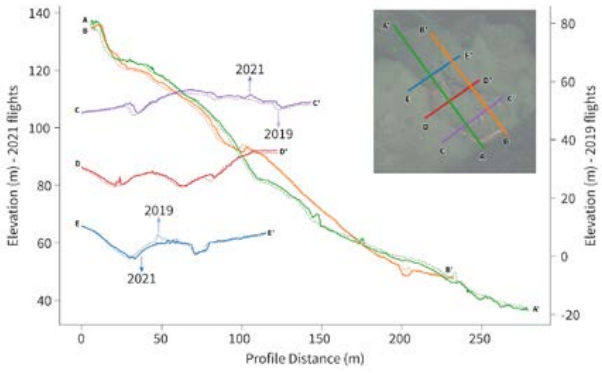

Fig. 11.5 Topographic profiles for the 2019 (dashed lines) and 2021 flights (solid lines). SPAMLab/IEE-USP Topographic profiles for the 2019 (dashed lines) and 2021 flights (solid lines).

UNCORRECTED DISTRIBUTION SAMPLE

Table 11.2 Descriptive statistics of the DSMs

Descriptive statistics of the DSMs

Flight	min	max	mean	median	std. dev.	25% quant.	75% quant.
1	-35.076	89.981	13.157	3.541	30.311	-11.076	38.161
2	19.877	149.344	68.423	58.758	31.537	43.302	94.563
3	19.859	147.865	68.413	58.774	31.545	43.262	94.555
2+3	19.860	148.002	68.387	58.749	31.562	43.222	94.551
4	20.516	146.984	68.506	58.809	31.456	43.430	94.557
5	19.514	148.130	68.487	58.806	31.462	43.389	94.554
4+5	19.127	148.130	68.392	58.741	31.549	43.237	94.546

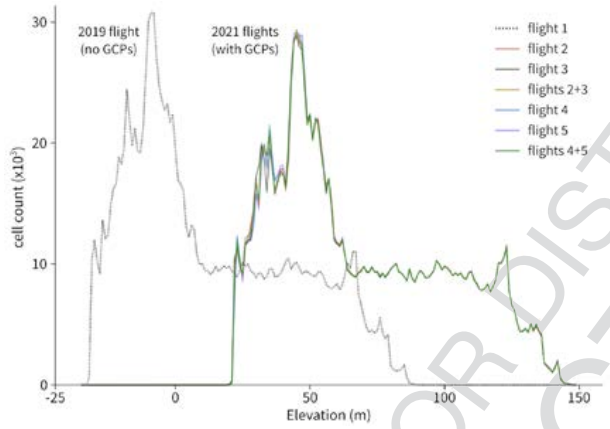

Fig. 11.6 Histograms for the 2019 (dashed line) and 2021 flights (solid lines). SPAMLab/IEE-USP Histograms for the 2019 (dashed line) and 2021 flights (solid lines).

(that is, with a linear distribution of the color gradient between the minimum and maximum map values), figures 7B and 7D show the same maps with a 'histogram equalization' of the color table (calculated by the r.colors module of GRASS-GIS). The main scarp and the steps are highlighted in the slope map (Figure 11.7B). In the surface roughness map (Figure 11.7D), the steps are more clearly defined. This is a simple but effective operation that can help in the visual interpretation of the landslide features.

Shaded relief maps are commonly used in the interpretation of landscape features and geological structures such as faults and lineaments (Carlos Henrique Grohmann, 2004; M. J. Smith & Clark, 2005). In Figure 11.8, two shaded relief maps are presented for flight #1 (2019 - Figure 11.8A) and the combination of flights #2 and #3 (2021 - Figure 11.8B). Minor differences can be seen in the 2021 map, such as an increase in area for erosional features and sinuous lines marking cracks at the lower portion of the landslide. A possible crack is also visible close to the main scarp.

5 – Discussions and Conclusions

RPA data were collected over a landslide in southeastern Brazil. In a 2019 reconnaissance field campaign, a simple grid pattern was flown without precise geometric control given by GCPs.

In the 2021 campaign, four RPA flight patterns (two simple grids and two cross-grids) were deployed to evaluate the differences in the resulting 3D reconstructions about their com-

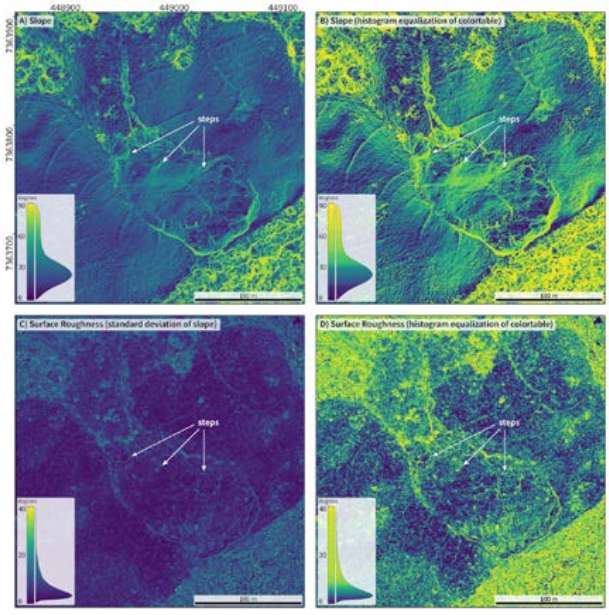

Fig. 11.7 Slope (A,B) and surface roughness (C,D) maps. SPAMLab/IEE-USP Slope (A,B) and surface roughness (C,D) maps.

UNCORRECTED SAMPLE NOT FOR DISTRIBUTION

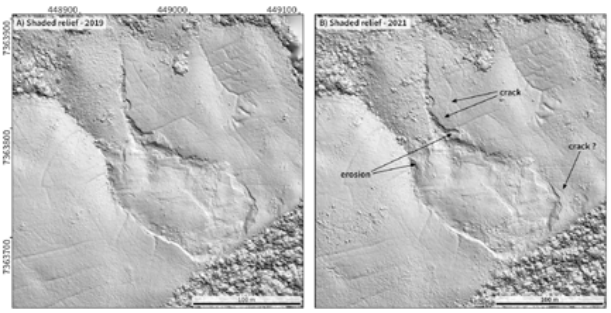

Fig. 11.8 Shaded relief maps for the 2019 (A) and 2021 flights (B). SPAMLab/IEE-USP Shaded relief maps for the 2019 (A) and 2021 flights (B).

pleteness (i.e., number of voids in the DSMs), topographic profiles, statistics, and morphometry. The data were processed as the individual flights and as a combination of the two simple grids and two cross-grids. Nine GPCs were placed and precise coordinates were obtained by DGPS.

Visually, all the resulting DSMs are similar. Processing time was around 20-30' for the simple and cross-grids, and 1:30' for the combinations. The DSMs from the simple grid flights had fewer voids than any of the cross-grid flights. The combination of the simple grids resulted in the most complete DSM, at the expense of a larger processing time. The intention of combining cross-grid flights was to simulate the amount of overlap of the simple grid flights. Indeed, the DSM from the combined cross-grids had fewer voids than those from the simple grids, but with the downside of requiring two flights and longer processing time.

Topographic profiles extracted from the DSMs of 2021 are virtually indistinguishable from one another, confirming that the flight patterns did not influence the surface reconstruction. Profiles from the 2019 DSM show small differences in shape that can be attributed to changes in the tall grass vegetation covering the hillside. The main difference is with respect to the Z-axis, where the 2019 DSM is about 60 m lower than the 2021 DSMs.

Slope, surface roughness, and shaded relief maps are helpful in the visual interpretation of the landslide. We show how a simple histogram equalization of the color table can improve the visualization and help to identify its limits, scarps, and other features. In addition, shaded relief maps are helpful in the identification of linear features, such as cracks.

The presence of vegetation cannot be dismissed when interpreting these data, as the SfM-MVS process will generate a DSM and not a DTM. However, if the area of interest is covered by dense vegetation, one must consider the use of lidar, as the multiple returns of the laser pulse (in the case of airborne lidar) or the very high density of points/m² (in the case of RPA-borne lidar), allow the removal of vegetation and creation of a "bare earth" surface.

In situations of rapid response to landslide events, time is of utmost importance. Our results indicate that a simple grid flight will be enough to produce a good surface reconstruction, with a short processing time. In such situations, deploying GCPs and collecting coordinates with DGPS might also not be feasible (both in terms of time, accessibility, and safety). We show that the DSM produced without GCPs had little difference in the XY coordinates from those where GCPs were applied; the main difference was in the Z-axis, which can be easily adjusted in a GIS environment based on other data (such as previous DSMs/DTMs or topographic maps). In this case, it is essential to plan the flights to cover a larger area, capture features that can be used in the georeferencing, and set the camera position to off-nadir (85º is sufficient) to prevent dome-shaped distortions in the results. Mapping a larger area also allows monitoring the landslide without GCPs, since point clouds or DSMs from different dates can be aligned based on their stable features. Given that landslides usually occur in areas of high relief, the flight plans should consider the terrain and be executed with constant height above ground to provide a consistent pixel size across the region.

UNCORRECTED SAMPLE NOT FOR DISTRIBUTION

REFERENCES

Anders, N., Valente, J., Masselink, R., & Keesstra, S. (2019). Comparing filtering techniques for removing vegetation from uav-based photogrammetric point clouds. *Drones*, *3*(3), 1–14. https://doi.org/10.3390/drones3030061

Berti, M., Corsini, A., & Daehne, A. (2013). Comparative analysis of surface roughness algorithms for the identification of active landslides. *Geomorphology*, *182*, 1–18. https://doi.org/10.1016/j.geomorph.2012.10.022

Brovelli, M. A., & Cannata, M. (2004). Digital terrain model reconstruction in urban areas from airborne laser scanning data: the method and an example for Pavia (northern Italy). *Computers & Geosciences*, *30*(4), 325–331. https://doi.org/10.1016/j.cageo.2003.07.004

Brovelli, M. A., Longoni, U. M., & Cannata, M. (2004). LIDAR data filtering and DTM interpolation within GRASS. *Transactions in GIS*, *8*(2), 155–174. https://doi.org/10.1111/j.1467-9671.2004.00173.x

Buckley, S. J., Howell, J. A., Enge, H. D., & Kurz, T. H. (2008). Terrestrial laser scanning in geology: Data acquisition, processing and accuracy considerations. *Journal of the Geological Society*, *165*(3), 625–638. https://doi.org/10.1144/0016-76492007-100

Carrivick, J. L., Smith, M. W., & Quincey, D. J. (2016). Structure from Motion in the Geosciences. *Analytical Methods in Earth and Environmental Science*.

Carter, W., Shrestha, R., Tuell, G., Bloomquist, D., & Sartori, M. (2001). Airborne laser swath mapping shines new light on Earth's topography. *Eos, Transactions American Geophysical Union*, *82*(46), 549–549. https://doi.org/10.1029/01eo00321

Casagli, N., Frodella, W., Morelli, S., Tofani, V., Ciampalini, A., Intrieri, E., Raspini, F., Rossi, G., Tanteri, L., & Lu, P. (2017). Spaceborne,

UAV and ground-based remote sensing techniques for landslide mapping, monitoring and early warning. *Geoenvironmental Disasters*, *4*(1). https://doi.org/10.1186/s40677-017-0073-1

Colomina, I., & Molina, P. (2014). Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, *92*, 79–97. https://doi.org/10.1016/j.isprsjprs.2014.02.013

da Costa, M. B. T., Silva, C. A., Broadbent, E. N., Leite, R. V., Mohan, M., Liesenberg, V., Stoddart, J., do Amaral, C. H., de Almeida, D. R. A., da Silva, A. L., Lucas, L. R., Cordeiro, V. A., Rex, F., Hirsch, A., Marcatti, G. E., Cardil, A., de Mendonça, B. A. F., Hamamura, C., Corte, A. P. D., … Klauberg, C. (2021). Beyond trees: Mapping total aboveground biomass density in the Brazilian savanna using high-density UAV-lidar data. *Forest Ecology and Management*, *491*. https://doi.org/10.1016/j.foreco.2021.119155

Duarte, R. B. (2018). *Movimentos de massa no município de Blumenau - Santa Catarina: estudo de caso no bairro Progresso, localidade de Nova Rússia*.

Farr, T. G., Rosen, P. A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D., & Alsdorf, D. E. (2007). The shuttle radar topography mission. *Reviews of Geophysics*, *45*(2). https://doi.org/10.1029/2005RG000183

Garcia, G. P. B., Gomes, E. B., Viana, C. D., & Grohmann, C. H. (2019). Comparing Terrestrial Laser Scanner and UAV-based photogrammetry to generate a landslide DEM. In *XIX Brazilian Symposium on Remote Sensing, 17, 95863. Santos, SP.: Galoa. Retrieved from.*

Gillies, s. (2020). *Rasterio: geospatial raster I/O for Python programmers. Mapbox*. https://github.com/mapbox/rasterio

Giordan, D., Adams, M. S., Aicardi, I., Alicandro, M., Allasia, P., Baldo, M., De Berardinis, P., Dominici, D., Godone, D., Hobbs, P., Lechner, V., Niedzielski, T., Piras, M., Rotilio, M., Salvini, R., Segor, V., Sotier, B., & Troilo, F. (2020). The use of unmanned aerial vehicles (UAVs) for engineering geology applications. *Bulletin of Engineering Geology and the Environment*, *79*(7), 3437–3481. https://doi.org/10.1007/s10064-020-01766-2

Gomez, C., & Purdie, H. (2016). UAV- based Photogrammetry and Geocomputing for Hazards and Disaster Risk Monitoring – A Review. *Geoenvironmental Disasters*, *3*(1). https://doi.org/10.1186/s40677-016-0060-y

Gramani, M. F., Cavalhieri, C. P., Silva, A. P. S., Mantovani, J. C., & Carou, C. B. (2018). *O uso de drone multirrotor de pequeno porte para diagnóstico e monitoramento de acidentes geológicos, XIX Congresso Brasileiro de Mecanica dos Solos e Engenharia Geotécnica (COBRAMSEG)* (Vol. 19).

GRASS Development Team. (2020). *Geographic Resources Analysis Support System (GRASS GIS) Software, Version 7.8. Open Source Geospatial Foundation*. http://grass.osgeo.org

Grohmann, Carlos Henrique. (2004). Morphometric analysis in geographic information systems: applications of free software GRASS and R. *Computers & Geosciences*, *30*(9–10), 1055–1067. https://doi.org/10.1016/j.cageo.2004.08.002

Grohmann, C.H., Smith, M. J., & Riccomini, C. (2011). Multiscale analysis of topographic surface roughness in the Midland Valley, Scotland. *IEEE Transactions on Geoscience and Remote Sensing*, *49*(4), 1200–1213. https://doi.org/10.1109/TGRS.2010.2053546

Guan, H., Sun, X., Su, Y., Hu, T., Wang, H., Wang, H., Peng, C., & Guo, Q. (2021). UAV-lidar aids automatic intelligent powerline inspection. *International Journal of Electrical Power & Energy Systems*, *130*, 106987. https://doi.org/10.1016/j.ijepes.2021.106987

Guth, P., Van Niekerk, A., Grohmann, C. H., Muller, J.-P., Hawker, L., Florinsky, I. V., Gesch, D., Reuter, H. I., Herrera-Cruz, V., Riazanoff, S., López-Vásquez, C., Carabajal, C. C., Albinet, C., & Strobl, P. (2021). Digital Elevation Models: Terminology and Definitions. *Remote Sensing*.

Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M. H., Brett, M., Haldane, A., del Río, J. F., Wiebe, M., Peterson, P., … Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, *585*(7825), 357–362. https://doi.org/10.1038/s41586-020-2649-2

Harwin, S., Lucieer, A., & Osborn, J. (2015). The impact of the calibration method on the accuracy of point clouds derived using unmanned aerial vehicle multi-view stereopsis. *Remote Sensing*, *7*(9), 11933–11953. https://doi.org/10.3390/rs70911933

Hobbs, P. R. N., Humphreys, B., Rees, J. G., Tragheim, D. G., Jones, L. D., Gibson, A., Rowlands, K., Hunter, G., & Airey, R. (2002). *Monitoring the role of landslides in 'soft cliff'coastal recession. Instability–Planning and Management* (pp. 589–600). https://doi.org/10.1680/ipamssstgmp.31326.0062

Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science and Engineering*, *9*(3), 90–95. https://doi.org/10.1109/MCSE.2007.55

James, M. R., Chandler, J. H., Eltner, A., Fraser, C., Miller, P. E., Mills, J. P., Noble, T., Robson, S., & Lane, S. N. (2019). Guidelines on the use of structure-from-motion photogrammetry in geomorphic research. *Earth Surface Processes and Landforms*, *44*(10), 2081–2084. https://doi.org/10.1002/esp.4637

James, M. R., & Robson, S. (2014). Mitigating systematic error in topographic models derived from UAV and ground-based image networks. *Earth Surface Processes and Landforms*, *39*(10), 1413–1420. https://doi.org/10.1002/esp.3609

Kelleher, C., Scholz, C., Condon, L., & Reardon, M. (2018). Drones in Geoscience Research: The Sky Is the Only Limit. *Eos*. https://doi.org/10.1029/2018EO092269

Khosravipour, A., Skidmore, A. K., & Isenburg, M. (2016). Generating spike-free digital surface models using LiDAR raw point clouds: A new approach for forestry applications. *International Journal of Applied Earth Observation and Geoinformation*, *52*, 104–114. https://doi.org/10.1016/j.jag.2016.06.005

Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B., Bussonnier, M., Frederic, J., Kelley, K., Hamrick, J., Grout, J., Corlay, S., Ivanov, P., Avila, D., Abdalla, S., & Willing, C. (2016). Jupyter Notebooks—a publishing format for reproducible computational workflows. In *Positioning and Power in Academic Publishing: Players, Agents and Agendas - Proceedings of the 20th International Conference on Electronic Publishing, ELPUB 2016* (pp. 87–90). IOS Press BV. https://doi.org/10.3233/978-1-61499-649-1-87

Köppen, W. P. (1936). *Handbuch der Klimatologie*.

Lima, L. C. (2019). *Avaliação de áreas vulneráveis a movimento de massa na cidade de João Pessoa - PB (Universidade Federal da Paraíba)*.

McKean, J., & Roering, J. (2004). Objective landslide detection and surface morphology mapping using high-resolution airborne laser altimetry. *Geomorphology*, *57*(3–4), 331–351. https://doi.org/10.1016/S0169-555X(03)00164-8

UNCORRECTED PROOF

McKinney, W. (2011). *pandas: a Foundational Python Library for Data Analysis and Statistics. Python for High Performance and Scientific Computing* (pp. 1–9).

Mosbrucker, A. R., Major, J. J., Spicer, K. R., & Pitlick, J. (2017). Camera system considerations for geomorphic applications of SfM photogrammetry. *Earth Surface Processes and Landforms*, *42*(6), 969–986. https://doi.org/10.1002/esp.4066

Neteler, M., Bowman, M. H., Landa, M., & Metz, M. (2012). GRASS GIS: A multi-purpose open source GIS. *Environmental Modelling and Software*, *31*, 124–130. https://doi.org/10.1016/j.envsoft.2011.11.014

Niedzielski, T. (2018). Applications of Unmanned Aerial Vehicles in Geosciences: Introduction. *Pure and Applied Geophysics*, *175*(9), 3141–3144. https://doi.org/10.1007/s00024-018-1992-9

Niemann, R. S. (2019). *O uso de Vant (Veículo Aéreo Não Tripulado) para estudos de movimentos de massa. XIII Enconstro Nacional da Associação Nacional de Pós-Graduação em Geografia (ENANPEGE)*.

Niethammer, U., James, M. R., Rothmund, S., Travelletti, J., & Joswig, M. (2012). UAV-based remote sensing of the Super-Sauze landslide: Evaluation and results. *Engineering Geology*, *128*, 2–11. https://doi.org/10.1016/j.enggeo.2011.03.012

Niethammer, U., Rothmind, S., & Joswig, M. (2009). UAV-based remote sensing of the slow-moving landslide Super-Sauze. In *Proceedings of the International Conference on Landslide Processes: From Geomorpholgic Mapping to Dynamic Modelling* (pp. 69–74).

Niethammer, U., Rothmund, S., James, M. R., Travelletti, J., & Joswig, M. (2005). Uav-Based Remote Sensing of Landslides. International Archives of Photogrammetry. *Remote Sensing and Spatial Information Sciences*, 496–501.

Oliphant, T. E. (2007). Python for scientific computing. *Computing in Science and Engineering*, *9*(3), 10–20. https://doi.org/10.1109/MCSE.2007.58

OpenDroneMap Community. (2020). *OpenDroneMap's documentation*. https://docs.opendronemap.org/tutorials.html#calibrating-the-camera

Pijl, A., Bailly, J. S., Feurer, D., El Maaoui, M. A., Boussema, M. R., & Tarolli, P. (2020). TERRA: Terrain Extraction from elevation Rasters through Repetitive Anisotropic filtering. *International Journal of Applied Earth Observation and Geoinformation*, *84*. https://doi.org/10.1016/j.jag.2019.101977

Rule, A., Birmingham, A., Zuniga, C., Altintas, I., Huang, S.-C., Knight, R., Moshiri, N., Nguyen, M. H., Rosenthal, S. B., Pérez, F., Rose, P. W., & Lewitter, F. (2019). Ten simple rules for writing and sharing computational analyses in Jupyter Notebooks. *PLOS Computational Biology*, e1007007. https://doi.org/10.1371/journal.pcbi.1007007

Santos da Silva, D. F. (2017). *Avaliação do alcance de deslizamentos em função da geometria da encosta. Estudo de caso: Estrada de Ferro Vitória-Minas (EFVM)*. Universidade Federal de Ouro Preto. http://www.repositorio.ufop.br/handle/123456789/9636

Santos, D. D. dos, & Galvani, E. (2014). DISTRIBUIÇÃO SAZONAL E HORÁRIA DAS PRECIPITAÇÕES EM CARAGUATATUBA-SP E A OCORRÊNCIA DE EVENTOS EXTREMOS NOS ANOS DE 2007 A 2011. *Ciência e Natura*. https://doi.org/10.5902/2179460X11891

Santos, L. F. (2020). *Utilização de dados 3D de alta resolução para detecção de mudanças em movimentos de massa em Perus, São Paulo (SP)*. https://doi.org/10.11606/D.44.2020.tde-25082020-090103

Santos, L. F., & Grohmann, C. H. (2019). Processamento fotogramétrico digital por Structure from Motion de imagens obtidas em voos de diferentes alturas sobre o solo. In *XIX Brazilian Symposium on Remote Sensing, 17, 97009. Santos, SP.: Galoa. Retrieved from.*

Smith, M. J., & Clark, C. D. (2005). Methods for the visualization of digital elevation models for landform mapping. *Earth Surface Processes and Landforms*, *30*(7), 885–900. https://doi.org/10.1002/esp.1210

Smith, M. W. (2014). Roughness in the Earth Sciences. *Earth-Science Reviews*, *136*, 202–225. https://doi.org/10.1016/j.earscirev.2014.05.016

Stark, M., Heckmann, T., Piermattei, L., Dremel, F., Kaiser, A., Machowski, P., Haas, F., & Becht, M. (2021). From consumer to enterprise grade: How the choice of four UAS impacts point cloud quality. *Earth Surface Processes and Landforms*, *46*(10), 2019–2043. https://doi.org/10.1002/esp.5142

The SciPy community. (2013). *SciPy Reference Guide – Release 0.13.0*. http://docs.scipy.org/doc/scipy/scipy-ref.pdf

Viana, C. D., Grohmann, C. H., dos Santos Toledo Busarello, M., & Garcia, G. P. B. (2018). Structural analysis of clastic dikes using Structure from Motion - Multi-View Stereo: A case-study in the Paraná Basin, southeastern Brazil. *Brazilian Journal of Geology*, *48*(4), 839–852. https://doi.org/10.1590/2317-4889201800201898

Waskom, M., Botvinnik, O., drewokane, Hobson, P., David, Halchenko, Y., Lukauskas, S., Cole, J. B., Warmenhoven, J., Ruiter, de, Hoyer, S., Vanderplas, J., Villalba, S., Kunter, G., Quintero, E., Martin, M., Miles, A., Meyer, K., Augspurger, T., … Lee, A. (2016). https://doi.org/10.5281/zenodo.54844

Westoby, M. J., Brasington, J., Glasser, N. F., Hambrey, M. J., & Reynolds, J. M. (2012). "Structure-from-Motion" photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, *179*, 300–314. https://doi.org/10.1016/j.geomorph.2012.08.021

Zambelli, P., Gebbert, S., & Ciolli, M. (2013). Pygrass: An object oriented python application programming interface (api) for geographic resources analysis support system (grass) geographic information system (GIS). *ISPRS International Journal of Geo-Information*, *2*(1), 201–219. https://doi.org/10.3390/ijgi2010201

Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., & Yan, G. (2016). An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing*, *8*(6). https://doi.org/10.3390/rs8060501

UNCORRECTED PROOFS NOT FOR DISTRIBUTION