LUIZ AUGUSTO MANFRÉ

**Identificação e mapeamento de áreas de deslizamentos associadas
a rodovias utilizando imagens de sensoriamento remoto**

São Paulo
2015

LUIZ AUGUSTO MANFRÉ

**Identificação e mapeamento de áreas de deslizamentos associadas a
rodovias utilizando imagens de sensoriamento remoto**

Tese apresentada à Escola Politécnica da
Universidade de São Paulo para obtenção do
título de Doutor em Ciências

São Paulo
2015

LUIZ AUGUSTO MANFRÉ

**Identificação e mapeamento de áreas de deslizamentos associadas a
rodovias utilizando imagens de sensoriamento remoto**

Tese apresentada à Escola Politécnica da
Universidade de São Paulo para obtenção do
título de Doutor em Ciências

Área de Concentração: Engenharia de
Transportes

Orientador: Professor Livre-Docente José Alberto
Quintanilha

Co-orientador: Professor Doutor Rodrigo Affonso
de Albuquerque Nóbrega

São Paulo
2015

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, _____ de _____ de _____

Assinatura do autor: _____

Assinatura do orientador: _____

Catálogo-na-publicação

Manfré, Luiz Augusto

Identificação e mapeamento de áreas de deslizamentos associadas a rodovias utilizando imagens de sensoriamento remoto / L. A. Manfré -- versão corr. -- São Paulo, 2015.

117 p.

Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Transportes.

1.Sensoriamento Remoto 2.Deslizamento 3.Processamento Digital de Imagens I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Transportes II.t.

Dedico esta Tese a toda a minha família, pelo apoio que foi fundamental para a conclusão deste trabalho. Dedico especialmente à minha avó (Maria Aparecida de Moraes Manna) por todo o apoio e dedicação em todos os meus anos de vida, à minha mãe (Tania Benedita Manna Manfré) e à minha esposa Bruna, por estar sempre ao meu lado me apoiando e sendo minha fonte de energia e vida.

AGRADECIMENTOS

Agradeço à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pela concessão da bolsa de estudo de doutorado e pelo financiamento do estágio no exterior que tornarão o desenvolvimento desta Tese viável.

Agradeço ao meu orientador, Professor Livre Docente José Alberto Quintanilha pelos ensinamentos, atenção, conselhos, dedicação e amizade durante os quatro anos de desenvolvimento desta Tese.

Agradeço ao meu co-orientador, Professor Doutor Rodrigo Affonso de Albuquerque Nóbrega por ter me recebido no Geosystem Research Institute da Mississippi State University, pelos conselhos e ensinamento e pela amizade desde então.

Agradeço a Professora Doutora Mariana Abrantes Giannotti pelas contribuições e conselhos.

Agradeço a todos os colegas do Laboratório de Geoprocessamento pelo apoio e colaboração durante os últimos 4 anos.

Agradeço a todos os meus amigos e familiares pelo apoio e compreensão nestes 4 anos de trabalho.

Agradeço principalmente à minha mãe (Tania Benedita Manna Manfré) à minha avó (Maria Aparecida de Moraes Manna) e à minha esposa (Bruna Botti Cruz) por estarem do lado dando apoio e suporte durante todo o período de desenvolvimento do trabalho.

RESUMO

Ferramentas de geoinformação possuem grande aplicabilidade na compreensão e no mapeamento de deslizamentos. Considerando-se a importância dos componentes do relevo e da cobertura do solo neste processo, torna-se essencial o estabelecimento de metodologias para a síntese de informações do relevo e para a identificação de cicatrizes de deslizamento, de maneira a facilitar o monitoramento de áreas de risco. O objetivo desta Tese é propor metodologias de processamento digital de imagens para o mapeamento e identificação de cicatrizes de deslizamento próximo a rodovias. Um deslizamento de grande porte com várias consequências econômicas, ocorrido no ano de 1999, às margens da Rodovia Anchieta, na bacia hidrográfica do Rio Pilões foi utilizado como área de estudo deste trabalho. Utilizando dados gratuitos, mapas de cobertura do solo e de compartimentação do relevo foram gerados e analisados conjuntamente para a identificação das áreas de potenciais cicatrizes na região das Rodovias Anchieta e Imigrantes. A análise do relevo foi realizada utilizando técnicas de classificação baseada em objeto. A identificação de áreas de cicatrizes de deslizamento foi realizada através da avaliação de duas estratégias metodológicas: uma utilizando o algoritmo de classificação supervisionada SVM (*Support Vector Machine*) aplicado ao índice de vegetação NDVI (*Normalized Difference Vegetation Index*) e outra que utilizando combinação entre diferentes classificadores para a composição de uma classificação final. Os resultados obtidos para o mapeamento do relevo mostraram que a metodologia proposta possui grande potencial para a descrição de feições do relevo, com maior nível de detalhamento, facilitando a identificação de áreas com grande potencial de ocorrência de deslizamentos. Ambas as metodologias de identificação de cicatrizes de deslizamento apresentaram bons resultados, sendo que a combinação entre os algoritmos SVM, Redes Neurais e Máxima Verossimilhança apresentou o resultado mais adequado com os objetivos do trabalho, atingindo erro de omissão inferior a 10% para a classe de deslizamento. A combinação dos dois produtos permitiu a análise e identificação de diversas áreas de potenciais cicatrizes de deslizamento associadas à rodovias na região de estudo. A metodologia proposta possui ampla replicabilidade, podendo ser utilizada para análises de risco associadas a assentamentos urbanos, empreendimentos lineares e para o planejamento territorial e ambiental.

Palavras-chave: Sensoriamento Remoto; Deslizamento; Processamento Digital de Imagens; Sistemas de Múltiplos Classificadores; Compartimentação do Relevo.

ABSTRACT

Geoinformation tools have great applicability in understanding and mapping landslides. Considering the significance of relief components and land cover in this process, it is essential the establishment of methods for the synthesis of the relief information and identification landslides, aiming to facilitate areas risk monitoring. The objective of this Dissertation is to propose digital image processing methodologies for map and identify landslide near to highways. A large landslide with several economic consequences was used as a study area of this work, occurred in 1999, near the Highway Anchieta, in Piloos river basin. Using free data, land cover and relief subdivision maps were generated and intersected to identify areas of potential landslides in the region of Highways Anchieta and Imigrantes. The relief analysis was performed using based on object classification techniques. The identification of the landslide was performed by evaluating two methodological strategies: one using the supervised classification algorithm SVM (Support Vector Machine) applied to the NDVI vegetation index (Normalized Difference Vegetation Index) and another using combination of different classifiers for the composition of a final classification. The results obtained for relief mapping showed that the proposed method has great potential for the description of the relief features, with greater detail, facilitating the identification of areas with high potential for occurrence of landslides. Both landslides identification methodologies showed good results, and the combination of SVM, Neural Network and Maximum Likelihood algorithms presented the most appropriate result, reaching omission error of less than 10% for the landslide class. The combination of the two products allowed the analysis and identification of several areas of potential landslide scars associated with roads in the study area. The proposed methodology has extensive replication and can be used for risk analysis associated with urban settlements, linear infrastructures and the territorial and environmental planning.

Keywords: Remote Sensing; Landslides; Digital Image Processing; Multiple Classifier Systems; Relief Subset.

LISTA DE FIGURAS

Capítulo 1

Figura 1 – Estratégia metodológica adotada para o desenvolvimento da Tese.	23
Figura 2 - Localização da área de estudo e imagem do deslizamento.....	30
Figura 3 - Localização do deslizamento em relação à Rodovia Anchieta e aos limites municipais e sobreposição a Modelo Digital de Elevação	31
Figura 4. - Localização do Município e do Estado de São Paulo.....	35
Figura 5. - Fator de escala e variância local para o recorte do Município de São Paulo.....	37
Figura 6. - Exemplo de objetos da imagem e seus valores médios de elevação.	38
Figura 7. - Mapa da Compartimentação do relevo para o Estado de São Paulo. As seguintes regiões são destacadas: A) Vale do Paraíba; B) Serra do Mar; C) Vale do Ribeira; D) Cuesta Central; E) Vale do Tietê; F) Vale do Paranapanema; e G) Serra da Mantiqueira.	42
Figura 8. - Mapa das formas do relevo para o Estado de São Paulo. As seguintes regiões são destacadas: A) Vale do Paraíba; B) Serra do Mar; C) Vale do Ribeira; D) Cuesta Central; E) Vale do Tietê; F) Vale do Paranapanema; e G) Serra da Mantiqueira.	43
Figura 9. - Mapa da compartimentação do relevo para o Município de São Paulo, recorte do Mapa para o Estado de São Paulo. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.	45
Figura 10. - Mapa das formas do relevo para o Município de São Paulo, recorte do Mapa para o Estado de São Paulo. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.	46
Figura 11. - Mapa da compartimentação do relevo para o Município de São Paulo utilizando abordagem local. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.	48
Figura 12. - Mapa de formas do relevo para o Município de São Paulo utilizando a abordagem local. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.	49
Figura 13 - Metodologia proposta para a compartimentação e identificação de formas do relevo.	50
Figura 14 - Mapa da compartimentação do relevo para o Município de São Paulo utilizando a nova metodologia proposta. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.	51

Figura 15. - Mapa das formas do relevo para o Município de São Paulo utilizando a nova metodologia proposta. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.	52
Figura 16. - Sobreposição do mapa de formas do relevo ao deslizamento de terra próximo à Rodovia Anchieta.	57
Figura 17. - Resultado do classificador MV baseado na imagem LANDSAT TM 5 de 2000.	64
Figura 18. - Resultado do classificador SVM baseado na imagem LANDSAT TM 5 de 2000 utilizando as bandas 3 e 4.	65
Figura 19. - Resultado do classificador SVM baseado na imagem LANDSAT TM 5 de 2000 utilizando NDVI.	65
Figura 20. - Sobreposição do resultado da classificação SVM/NDVI com imagem de alta resolução.	66
Figura 21. - Visão em perspectiva da classificação SVM/NDVI sobreposto ao modelo de elevação digital do terreno.	66
Figura 22. - Fluxograma das etapas metodológicas empregadas neste trabalho.	78
Figura 23. - Amostra da cena LANDSAT 219-077 de 25 de junho de 2000 no espaço de cores HSV.	79
Figura 24. - Mapas das classificações de cada algoritmo utilizado. A – Binary Encoding, B – Árvore de Decisão, C – Mahalanobis Distance, D – Mínima Distância, E – Máxima Verossimilhança, F – Redes Neurais, G – Paralelepípedo, H – SAM, I – SID, L – SVM.	83
Figura 25 – Evolução do índice Kappa para os resultados das composições entre os classificadores.	85
Figura 26 – Evolução da acurácia geral para as combinações entre os classificadores.	86
Figura 27 – Evolução dos erros de comissão para as combinações entre os classificadores.	86
Figura 28. Evolução dos erros de omissão para as combinações entre os classificadores.	87
Figura 29 – Evolução do percentual de acerto para as combinações entre os classificadores.	88
Figura 30 – Classificação final composta de três algoritmos (SVM, RN e MV) e abordagem de desempate por análise do contexto.	89
Figura 31 – Feições do relevo na região do Rio Pilões, Serra do Mar, Estado de São Paulo.	93
Figura 32 – Sobreposição do resultado final da classificação com a imagem de alta resolução que permite a visualização do deslizamento do rio Pilões.	95
Figura 33. Áreas potenciais de deslizamento e destaque para outras cicatrizes e cortes em taludes.	97

LISTA DE TABELAS

Tabela 1. - Resumo dos dados utilizados em cada método.	41
Tabela 2. - Valores do índice e acurácia geral para cada algoritmo utilizado.	67
Tabela 3 - Matriz de confusão para a classificação MV para a cena de 2000.	67
Tabela 4 - Erros de comissão e omissão para classificação MV para a cena de 2000.	67
Tabela 5 - Matriz de Confusão da Classificação SVM (Bandas 3 e 4)	68
Tabela 6 - Erros de Comissão e Omissão da Classificação SVM (bandas 3 e 4).	68
Tabela 7 - Matriz de Confusão da Classificação SVM (NDVI)	68
Tabela 8 - Erros de Comissão e Omissão da Classificação SVM (NDVI).	68
Tabela 9 - Área das classes para cada uma das classificações.	72
Tabela 10 - Matriz de Confusão para a Classificação baseada no NDVI.	72
Tabela 11 - Matriz de Confusão para a Classificação baseada nas bandas 1 e 2.	72
Tabela 12 - Matriz de confusão para a classificação baseada nas bandas 3 e 4.	73
Tabela 13 - Matriz de confusão para a Classificação baseada nas bandas 1, 2 e 3.	73
Tabela 14 - Matriz de confusão para a classificação baseada nas bandas 1, 2, 3 e 4.	73
Tabela 15 - Porcentagem dos erros de comissão e omissão para cada uma das classificações.	73
Tabela 16 - Porcentagem das acurácias do produtor e do usuário para cada uma das classificações.	74
Tabela 17 – Algoritmos de classificação utilizados e suas respectivas descrições.	80
Tabela 18 – Classificadores utilizados em cada uma das composições realizadas.	81
Tabela 19 – Avaliação da acurácia para os 10 algoritmos de classificação utilizados.	82
Tabela 20 – Avaliação da acurácia dos resultados das composições entre os classificadores.	84
Tabela 21 – Matriz de confusão com as probabilidades de classificar e confundir as classes, utilizando a combinação de 10 algoritmos.	88

LISTA DE ABREVIATURAS E SIGLAS

AD	Árvore de Decisão
ALOS	<i>Advanced Land Observing Satellite “Daichi”</i>
ASTER	<i>Advanced Spaceborne Thermal Emission and Reflectance Radiometer</i>
BE	<i>Binary Encoding</i>
CBERS	<i>China-Brazil Earth Research Satellite</i>
DD	Densidade de Drenagem
ETM	<i>Enhanced Thematic Mapper</i>
EVI	<i>Enhanced Vegetation Index</i>
GNSS	<i>Global Navigation Satellite System</i>
HAND	Altura Acima da Drenagem Mais Próxima
HN	Curvatura Horizontal Numérica
HSV	<i>Hue, Saturation and Value</i>
INPE	<i>Instituto Nacional de Pesquisas Espaciais</i>
MD	Mínima Distância
MDE	Modelo de Elevação Digital
MHD	<i>Mahalanobis Distance</i>
MV	Máxima Verossimilhança
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	infravermelho próximo
NN	<i>Neural Network</i>
OBIA	<i>Object Based Image Analysis</i>
OLI	<i>Operational Land Imager</i>
PAR	<i>Paralelepípedo</i>
RBF	<i>Radial Basis Function</i>
RGB	<i>Red, Green and Blue</i>
RN	Redes Neurais
SAM	<i>Spectral Angle Mapper</i>
SID	<i>Spectral Information Divergence</i>
SMC	Sistema de Múltiplos Classificadores
SN	Declividade Numérica
SRTM	Shuttle Radar Topography Mission
SVM	<i>Support Vector Machine</i>
TM	<i>Thematic Mapper</i>
UBC	Unidades Básicas de Compartimentação
USGS	<i>United States Geological Survey</i>
UTB	Unidades Territoriais Básicas
VN	Curvatura Vertical Numérica
ZN	Elevação Numérica

SUMÁRIO

1. Introdução	17
1.1. Justificativa	17
1.2. Objetivos	20
1.2.1. Objetivo Geral	20
1.2.2. Objetivos Específicos	20
1.3. Apresentação	21
1.4. Revisão Bibliográfica	24
1.4.1. Sensoriamento remoto no mapeamento geomorfológico e de deslizamentos	24
1.4.2. Processamento digital de imagens e identificação deslizamentos	25
1.5. Área de Estudo	30
2. Metodologia de compartimentação do relevo	32
2.1.1. Introdução	32
2.1.2. Metodologia	35
2.1.3. Resultados	41
2.1.4. Discussão	53
2.1.5. Conclusões	59
3. Identificação de cicatrizes utilizando <i>Support Vector Machine</i> aplicado ao Índice de Vegetação da Diferença Normalizada	61
3.1. Verificação da empregabilidade do NDVI para identificação de deslizamentos	61
3.1.1. Introdução	61
3.1.2. Metodologia	62
3.1.3. Resultados e Discussão	64
3.1.4. Conclusão	69
3.2. Avaliação comparativa dos indicadores de acurácia na identificação de deslizamentos	71
3.2.1. Introdução	71
3.2.2. Metodologia	71

3.2.3. Resultados e Discussão.....	71
3.2.4. Conclusão	75
4. Sistemas de Múltiplos Classificadores para a identificação de deslizamentos	76
4.1. Avaliação de Sistemas de Múltiplos Classificadores para a identificação de deslizamentos em imagens LANDSAT Thematic Mapper (TM)	76
4.1.1. Introdução	76
4.1.2. Metodologia.....	78
4.1.3. Resultados.....	82
4.1.4. Discussões	89
4.1.5. Conclusões.....	92
5. Análise Integrada dos Resultados	93
6. Conclusões.....	98
7. Referências	100

1. Introdução

1.1. Justificativa

A frequência e a intensidade dos desastres naturais aumentaram nas últimas décadas. De acordo com o Relatório de Desastres Mundiais (World Disaster Report) de 2011, 4.022 desastres ocorreram entre os anos de 2001 e 2010, vitimando mais de 1 milhão de pessoas (IFRC, 2011). De acordo com Kobiyama *et al.* (2006), o alto crescimento populacional, intensos processos de urbanização e industrialização aliados a ocupação desordenada promoveram a presença de alta densidade populacional em áreas de risco, o que pode ser o responsável pelo aumento do número de vítimas de desastres naturais.

Alguns desastres naturais ocorrem de maneira abrupta e afetam áreas vastas, sendo difícil a sua prevenção, como é o caso de tsunamis, tornados e terremotos. No entanto, desastres tais como deslizamentos e enchentes podem ser mapeados mais facilmente, e o número de pessoas que podem ser atingidas é facilmente quantificado (SORENSEN *et al.*, 2012). Devido à sua vasta aplicabilidade o uso de Sensoriamento Remoto, Geoprocessamento e Sistemas de Posicionamento Globais (GNSS) são preciosas ferramentas para o gerenciamento de riscos e de desastres (THOMAS; ETURĞAY; KEMEÇ, 2007), geralmente associadas à redução da vulnerabilidade da sociedade ao impacto do desastre, ao preparo para a resposta rápida a um evento extremo (MANSOURIAN *et al.*, 2005) e aos esforços de socorro e recuperação da área afetada.

Aplicações de mitigação e preparos estão geralmente associadas à prevenção de eventos como deslizamentos e enchentes, como parte de planos de uso e ocupação do solo e identificação de áreas de risco. Técnicas de geoprocessamento e sensoriamento remoto são comumente utilizadas para analisar informações satelitais e permitir a compreensão de processos e a identificação de padrões e relações entre as variáveis de maior influência para os eventos. Adicionalmente, informações geológicas, geomorfológicas e climatológicas devem ser combinadas para a avaliação da susceptibilidade (MANSOURIAN *et al.*, 2005).

Para avaliar a susceptibilidade a deslizamentos, metodologias que envolvem geoprocessamento e sensoriamento remoto foram propostas nas últimas décadas e geralmente combinam mapas de cobertura do solo com outros mapas como: topográficos, geológicos e geomorfológicos. Excetuando-se as especificidades geográficas locais, a diferença entre os estudos sobre mapeamento de susceptibilidade a deslizamentos está na forma de combinação

dos dados, o método adotado para ponderar cada uma das informações utilizadas, o dado de satélite utilizado e o método de classificação escolhido (MANFRÉ *et al.*, 2012).

Além do mapeamento da susceptibilidade ao deslizamento, a identificação de cicatrizes de deslizamentos é fundamental para o inventário de riscos, para a compreensão dos processos que engatilham os deslizamentos e para intervenções na área afetada (PRADHAN; LEE, 2010). O uso de imagens de satélite tem se mostrado uma alternativa fundamental para as tradicionais medidas *in situ*, sendo uma importante ferramenta que permite análises geoespaciais integradas e resulta em produtos que se coadunam com as demandas por suporte à tomada de decisão (TRALLI *et al.*, 2005).

Eventos de deslizamentos são favorecidos pelas características topográficas da região (PETLEY, 2012) e colocam em risco a população que vive ou transita por essas regiões. Muitas rodovias em regiões montanhosas podem favorecer a ocorrência destes eventos devido a alterações na estrutura do relevo e do solo (DI MARTINO *et al.*, 2014). Alguns autores listam as estradas e rodovias como um dos principais agentes causadores de deslizamentos (DAI; LEE, 2001; JAISWAL; VAN WESTEN; JETTEN, 2011; PENNA *et al.*, 2013).

Larsen e Parks (1997) avaliaram a relação entre rodovias e deslizamentos em uma área montanhosa de clima tropical úmido em Porto Rico. Os autores concluíram que a rodovia aumentou a susceptibilidade ao deslizamento e outros movimentos de massa, sendo que em um trecho de 170 metros, essa frequência aumentou de cinco para oito vezes. Sidle, Ghestem e Stokes (2014) quantificaram os deslizamentos ao longo de sete segmentos de rodovias em terreno declivoso na China. Os autores definem um modelo mais adequado para a implantação de rodovias em regiões montanhosas baseado na susceptibilidade ao deslizamento e em como os limiares para o desencadeamento de deslizamento são alterados com a implantação de rodovias.

As equipes de monitoramento de desastres naturais são em geral pequenas e as áreas a serem monitoradas são vastas, tornando o processo de identificação e monitoramento de locais de deslizamentos muito complicado (GUZZETTI *et al.*, 2012). Mesmo com essas dificuldades, o mapeamento e a mitigação dos danos causados por deslizamentos é essencial para prevenir outros desastres e perda de vidas (MANCONI *et al.*, 2014).

Desta forma, metodologias de processamentos de imagens e sensoriamento remoto representam uma ferramenta com grande potencial para monitorar e gerenciar deslizamentos, sendo uma ótima alternativa para o mapeamento das cicatrizes, uma vez que cobrem grandes regiões e permitem análises rápidas (TOFANI; HONG; SINGHROY, 2014). Entretanto, os deslizamentos geralmente ocorrem em áreas com topografia muito acidentada e terreno

bastante sombreado, que pode encobrir e dificultar a identificação das cicatrizes de deslizamento (MARTHA *et al.*, 2012).

Diversas técnicas de processamento de imagem alteram o número digital do alvo e podem permitir a sua identificação mesmo sob a influência das sombras da topografia (SHAHTAHMASSEBI *et al.*, 2013). Além disso, os algoritmos de classificação de imagens permitem a separação de classes utilizando diversas estratégias com base nas características espectrais dos alvos (LU *et al.*, 2011).

A análise das características do relevo é essencial no processo de mapeamento de deslizamentos (CHEN *et al.*, 2011), e informações detalhadas sobre as principais componentes do relevo podem facilitar muito este processo (DE SY *et al.*, 2013; TAROLLI *et al.*, 2013). O processamento digital de dados de sensoriamento remoto da topografia, tais como os Modelos de Digitais de Elevação (MDE) do SRTM (*Shuttle Radar Topography Mission*) ou do ALOS (*Advanced Land Observing Satellite "Daichi"*) é uma boa alternativa para a obtenção de informação de maior resolução sobre o relevo (ONUMA; ALI; HAMADA, 2012; CARVALHO JUNIOR *et al.*, 2014).

O uso combinado destas duas informações de sensoriamento remoto possui grande eficiência, potencializa o mapeamento de áreas de deslizamento além de permitir análise integrada da susceptibilidade de que outros eventos desta natureza aconteçam (BARLOW; MARTIN; FRANKLIN, 2003).

Sendo assim, o desenvolvimento e a proposição de técnicas de processamento digital de imagens de sensoriamento remoto para a identificação de cicatrizes de deslizamento é fundamental para aumentar a capacidade dos órgãos responsáveis por definir planos de gestão e monitoramento de riscos, sobretudo próximo a rodovias. A escolha das técnicas mais adequadas para o processamento dos dados é importante para a obtenção de resultados com maior acurácia possível. A combinação de informações do relevo com informações de cobertura do solo é fundamental para esse processo e potencializa o mapeamento de deslizamentos.

1.2. Objetivos

1.2.1. Objetivo Geral

Propor técnicas de processamento digital de imagens de sensoriamento remoto com resultados confiáveis para alimentar modelos de identificação de cicatrizes de deslizamentos.

1.2.2. Objetivos Específicos

- Definir uma metodologia de detalhamento do relevo para identificar de áreas potenciais de deslizamentos e de risco para outros desastres naturais.
- Identificar cicatrizes de deslizamentos decorrentes de obras viárias contemplando técnicas e ferramentas de processamento digital de imagens aplicadas à imagem LANDSAT TM, disponíveis na ciência do sensoriamento remoto.
- Identificar algoritmos de classificação supervisionada com melhores desempenhos para a identificação de cicatrizes de deslizamento.

1.3. Apresentação

Esta Tese foi elaborada para atingir os objetivos supracitados e responder a seguinte pergunta científica:

- Existem técnicas de processamento digital de imagens de sensoriamento remoto com resultados confiáveis para alimentar modelos de identificação de cicatrizes de deslizamentos?

Três hipóteses foram elaboradas considerando o referencial teórico relacionado ao processamento digital de imagens para responder a essa pergunta e atingir os objetivos estabelecidos:

1. É possível utilizar dados derivados da missão SRTM para a identificação de feições do relevo mais susceptíveis à deslizamentos
2. O índice de vegetação NDVI contém informação suficiente para identificação de cicatriz de deslizamento em imagem LANDSAT
3. A combinação de diferentes classificações produz resultado com acurácia superior à classificações isoladas

Cada uma das hipóteses foi testada e é apresentada em capítulos separados. Desta forma, o primeiro capítulo apresenta uma introdução, com justificativa e revisão da literatura descrevendo métodos de identificação de cicatrizes de deslizamento e a utilização de dados de sensoriamento remoto aplicados ao mapeamento de deslizamentos.

O segundo capítulo avalia a hipótese 1 e apresenta uma adaptação da metodologia automatizada de identificação global de formas do relevo, proposta por Dragut e Eisank (2012) para o contexto regional e local.

O terceiro capítulo avalia a hipótese 2 e apresenta a utilização do índice de vegetação NDVI combinado ao algoritmo de classificação SVM para a identificação da cicatriz ocorrida às margens da rodovia Anchieta, na bacia hidrográfica do Rio Pilões, na Serra do Mar. Os indicadores de acurácia para classificações realizadas com o SVM para a mesma amostra de cena, variando-se apenas as composições de bandas utilizadas são discutidos de forma aprofundada.

O quarto capítulo avalia a hipótese 3 e apresenta os resultados derivados de diversos classificadores e possibilidades de combinação entre os classificadores para a mesma amostra da cena LANDSAT TM utilizada no capítulo 3. São apresentadas discussões com relação à

importância da diversidade de informações para a composição de fusão entre classificadores e como elas podem melhorar o resultado final da classificação.

O quinto capítulo discute os resultados obtidos no âmbito da pergunta científica do trabalho. A integração e a aplicabilidade dos resultados para a identificação de deslizamentos são avaliadas. No sexto capítulo são apresentadas as conclusões do trabalho, considerando-se aplicações e replicabilidade dos produtos e metodologias apresentados. O sétimo capítulo apresenta as referências bibliográficas do trabalho.

Para contemplar as três hipóteses propostas e responder a pergunta científica elaborada, definiu-se uma estratégia metodológica para a identificação de potenciais cicatrizes de deslizamento. A Figura 1 apresenta um fluxograma que destaca as etapas realizadas. Foi realizada a seleção de uma área de estudo, ou evento de deslizamento, que estivesse associado a uma rodovia com proporções que permitissem a identificação em dados de Sensoriamento Remoto de média resolução. Foram selecionados dados que permitissem a identificação da cobertura do solo e das características do relevo da área de estudo, considerando-se a resolução espacial, confiabilidade do dado, forma de disponibilização do dado e potencial de replicabilidade para outros eventos. Desta forma, definiu-se o uso de dados LANDSAT TM (*Thematic Mapper*) 5 para a aquisição de informações sobre a cobertura do solo e dados SRTM (*Shuttle Radar Topography Mission*) e TOPODATA para as informações sobre o relevo. Todos os dados foram adquiridos de forma gratuita nos sistemas do Serviço Geológico Norte-Americano (dados LANDSAT e SRTM) e do Instituto Nacional de Pesquisas Espaciais (dados TOPODATA).

A avaliação das melhores estratégias de compartimentação do relevo e de classificação da cobertura do solo foi realizada. Foi definida uma metodologia de compartimentação do relevo que permitiu a síntese das informações mais importantes para a ocorrência de deslizamentos e sua veracidade foi validada com relação a referenciais teóricos. Para a identificação de cicatrizes de deslizamentos foram definidas duas metodologias a serem testadas: aplicação do algoritmo de classificação supervisionada *Support Vector Machine* (SVM) ao Índice de Vegetação da Diferença Normalizada (NDVI) e a composição de Sistemas de Múltiplos Classificadores (SMC). A acurácia das classificações foi avaliada e a classificação com mínimo de omissão de feições de deslizamento foi utilizada para a composição do mapa potencial de cicatrizes de deslizamentos, elaborado através da combinação do mapa de cobertura do solo e do mapa de compartimentação do relevo.

Figura 1 – Estratégia metodológica adotada para o desenvolvimento da Tese.

Fonte: Elaboração Própria.

1.4. Revisão Bibliográfica

1.4.1. Sensoriamento remoto no mapeamento geomorfológico e de deslizamentos

Informações sobre o relevo são fundamentais para potencializar o mapeamento de áreas de deslizamento (DE GUIDI; SCUDERO, 2013). O SRTM é um Modelo Digital de Elevação (MDE) global disponível gratuitamente com resolução de 90 metros (exceto para os Estados Unidos que possui resolução 30), tendo sido coletado em Fevereiro de 2000 (FARR *et al.*, 2007). Como os dados são contínuos é possível obter diversas derivações como declividade, orientação e sombreamento da vertente, curvaturas vertical e horizontal e densidade de drenagem. Além disso, é possível aplicar métodos de interpolação para melhorar a resolução do dado, como realizado por Valeriano (2011) para a obtenção de dados com resolução de 30 metros para o Brasil, sendo eles o resultado do projeto TOPODATA.

Os dados do TOPODATA permitem uma análise detalhada das características do relevo, possibilitando integrar dados e estabelecer regras para a identificação de feições de interesse. O uso desse tipo de informação pode facilitar o mapeamento de cicatrizes, uma vez que apresentam de forma detalhada informações fundamentais para a análise de susceptibilidade de uma área (SESTINI, 1999).

Diversos autores citam as relações entre a forma das vertentes, a declividade e outras características geomorfológicas com a ocorrência de deslizamentos (TAROLLI; SOFIA; FONTANA, 2012; DE VITA *et al.*, 2013; PAULIN *et al.*, 2014).

A forma das vertentes está diretamente relacionada com o acúmulo e dispersão de água em bacias hidrográficas, essa dinâmica se relaciona diretamente com o processo de erosão e ocorrência de deslizamentos (CHRISTOFOLETTI, 1974). Vertentes côncavas se relacionam com o acúmulo e convergência de água, enquanto que vertentes convexas se relacionam com o a dispersão de água (SESTINI, 1999). As vertentes côncavas são as mais susceptíveis a movimentos de massa, pois são zonas de convergência de fluxo de água e possuem material disponível para a movimentação (maior quantidade de material depositado) favorecendo o movimento de massa (MCKEAN; BUECHEL; GAYDOS, 1991; FERNANDES; AMARAL, 1996).

A declividade é a medida de inclinação do relevo em relação ao horizonte, sendo que a velocidade de transporte de massa (sólida ou líquida) é diretamente relacionada a declividade (SESTINI, 1999). Declividades superiores a 30° possuem maior susceptibilidade de deslizamento, acima de 60° como o regolito é menos profundo a susceptibilidade diminui (FERNANDES; AMARAL, 1996). No entanto, próximo a áreas de cabeceiras de drenagem

onde a dissecação do relevo é mais elevada a rocha base pode ficar exposta, tornando a região susceptível a deslizamentos (TRICART, 1972; THOMAS, 1979). A combinação de altos índices de dissecação e alta declividade potencializa a ocorrência de deslizamentos (TRICART, op. cit.; THOMAS, op. cit.).

Na literatura (LUCENA, 1998; FERREIRA *et al.*, 2011) são descritas as definições das Unidades Básicas de Compartimentação (UBCs), que correspondem às células básicas para a análise geotécnica e geo-ambiental (VEDOVELLO, 2000). De maneira geral essas células traduzem a dissecação do relevo, ou seja, é uma combinação entre a rugosidade topográfica, declividade e forma das vertentes. Vedovello e Mattos (1993) propuseram uma metodologia utilizando imagens de satélite para a compartimentação fisiográfica e caracterização geotécnica. A metodologia consiste na fotointerpretação sistemática de diferenças de homogeneidade, entropia e assimetria de texturas e de tons em imagens de satélite ou em fotografias aéreas (VEDOVELLO, 2000). O procedimento é abrangente e permite a integração com variáveis ecológicas, socioeconômicas, de cobertura do solo entre outras (SPÖRL; ROSS, 2004).

Recentemente outras metodologias de obtenção das UBCs utilizando dados do SRTM ou outros dados topográficos digitais têm sido propostas na literatura (DRAGUT; EISANK, 2012; CAMARGO *et al.*, 2012). A automatização do processo de delimitação das UBCs, com o uso de técnicas de processamento de imagem favorece a utilização destas compartimentações do terreno, uma vez que é possível integrar diferentes variáveis do relevo em uma única análise. O uso de classificação baseada em objeto (OBIA, do inglês, *Object Based Image Analysis*) aplicada a um MDE e suas derivações permite a segmentação e análise de diversas variáveis para regiões homogêneas do relevo (EISANK; DRĂGUT; BLASCHKE, 2011; DOLEIRE-OLTMANN *et al.*, 2013). Desta forma, é possível a construção de um modelo automatizado de compartimentação do relevo, de acordo com parâmetros pré-definidos para a área a ser avaliada (CAMARGO *et al.*, 2012; DRAGUT; EISANK, 2012).

1.4.2. Processamento digital de imagens e identificação deslizamentos

Diversos trabalhos têm utilizado a grande diversidade de dados e especificidades dos satélites disponíveis e os avanços nas tecnologias de processamento digital de imagens para auxiliar no mapeamento e prevenção de deslizamento (HSIEH *et al.*, 2014, DONG *et al.*, 2014; ROESSNER *et al.*, 2014). No entanto, um dos maiores problemas para o mapeamento de áreas de deslizamento em regiões montanhosas é a aquisição de dados de qualidade que

permitam o processamento e a identificação das cicatrizes (BARLOW; MARTIN; FRANKLIN, 2003). O uso de dados de sensoriamento remoto vem sendo a principal alternativa metodológica para suprir a demanda por informações (MARTIN *et al.*, 2002), sendo que a mais comum é a utilização de fotografias aéreas (MCKEAN; BUECHEL; GAYDOS, 1991). Porém, esta alternativa é geralmente de alto custo, tanto financeiro como de processamento. Por isso o desenvolvimento de metodologias baseadas no uso de satélites gratuitos é de grande importância.

Deslizamentos geralmente ocorrem em regiões de relevo acidentado, com altas declividades, forte dissecação do relevo e abruptas variações nas formas das vertentes que proporcionam sombras que podem omitir cicatrizes de deslizamentos (NICHOL; WONG, 2005). Desta forma, as técnicas de processamento digital de imagem devem ser cuidadosamente avaliadas de maneira a tentar contornar esses problemas.

Existem várias técnicas que permitem a obtenção de informações por imagens de sensoriamento remoto. O realce dos dados pode facilitar a interpretação da imagem com a minimização ou maximização de alguns elementos da imagem (BARRET, 2013), facilitando a identificação de algumas feições (LIU; MASON, 2009). Por outro lado, algoritmos de classificação se baseiam nas estatísticas da resposta espectral dos alvos para separar classes de interesse (LU *et al.*, 2011). Há uma grande diversidade de algoritmos e métodos de classificação de imagens, sendo que a sua aplicabilidade e acurácia varia de acordo com o objetivo da classificação.

Tradicionalmente, técnicas de sensoriamento remoto como interpretação de fotografias aéreas, análise de imagem estereoscópica e estudos de interferometria podem ser utilizadas para identificação, monitoramento e classificação de deslizamentos (ARKSOY; ERCANOGLU, 2012). No entanto, com a alta disponibilidade de dados de sensoriamento remoto satelital, diversos avanços têm ocorrido no sentido de aumentar a acurácia e rapidez dos processos de identificação e análise de deslizamento com imagens de satélite (HÖLBLING *et al.*, 2012).

Lee, Choi e Min. (2004) utilizaram areofotogrametria para a identificação de cicatrizes de deslizamento na Coreia do Sul. Além da cobertura do solo informações sobre o relevo, tipo de solo e geologia foram utilizadas. Os autores encontraram grande similaridade entre os resultados obtidos com o uso de geotecnologias e os dados existentes para cicatrizes de deslizamentos na região.

Nóbrega *et al.* (2006) utilizaram classificação baseada em objeto para mapear solo exposto e identificar potenciais áreas de erosão e deslizamento em uma bacia hidrográfica

urbana. Stumpf e Kerle (2011) utilizaram classificação orientada a objeto associadas a algoritmos de classificação supervisionada para melhorar a escolha de objetos significativos para o mapeamento de cicatrizes de deslizamentos. Xu (2014) realizou um inventário de deslizamentos engatilhados por terremotos na China, por meio de interpretação de imagens de satélite de alta resolução, obtendo resultados para diversos terremotos no país.

No entanto, fotografias aéreas abrangem pequenas áreas e possuem alto custo, bem como imagens de alta resolução, dificultando sua utilização prática para o monitoramento e identificação de cicatrizes (SOETERS; VAN WESTEN, 1996; ALKEVLI; ERCANOGLU, 2011). A missão LANDSAT possui resolução de 30 metros, uma longa série histórica e disponibilização gratuita de imagens de todo o globo a cada oito dias (LOVELAND; DWYER, 2012). Alguns autores utilizaram o dado LANDSAT para o mapeamento de deslizamentos, obtendo resultados interessantes.

Aksoy e Ercanoglu (2012) utilizaram classificação baseada em objeto e lógica Fuzzy para um deslizamento selecionado na Turquia utilizando dados do satélite LANDSAT ETM+. A abordagem classificou 988 objetos como deslizamentos e avaliaram os resultados do trabalho de acordo com a acurácia geral e com os erros de omissão e comissão. A melhor abordagem apresentou acurácia geral de 85,48%, 37,06% de erros de comissão e 16,5% de erros de omissão.

Roessner *et al.* (2014) fizeram o uso combinado da série histórica de LANDSAT TM, LANDSAT ETM+, SPOT 1 e 5, ASTER e RapidEye para a identificação de deslizamentos no Quirguistão. Com uso de trajetórias temporais de NDVI os autores propuseram uma identificação automática de deslizamentos pela avaliação de mudanças nas respostas espectrais da vegetação. Foram identificados 250 deslizamentos, sendo que com a verificação de campo, a vasta maioria deles foi confirmada.

O uso de índices de índices de vegetação tais como o NDVI (Normalized Difference Vegetation Index) ou o EVI (Enhanced Vegetation Index) suavizam o efeito das sombras do relevo e podem ser uma alternativa para a identificação de cicatrizes de deslizamentos. Barlow, Martin e Franklin (2003) utilizaram dados LANDSAT ETM (Enhanced Thematic Mapper) e MDE para a identificação de cicatrizes de deslizamento no Canadá. Os autores utilizaram o índice de vegetação NDVI para suavizar os efeitos de sombras na topografia e facilitar a diferenciação entre vegetação e solo. A técnica empregada produziu acurácia geral de 75% na detecção de deslizamento com área superior a 1 ha.

Behling *et al.* (2014) utilizaram a análise de curvas de NDVI e séries temporais de diversos sensores para a identificação automática de deslizamentos. Com o auxílio de MDE e

com o uso de sensores de alta resolução, a metodologia aplicou classificação baseada em objeto e identificou 612 deslizamentos na região.

Alguns algoritmos de classificação de imagens de sensoriamento remoto têm mostrado bom desempenho para a separação de alvos com respostas espectrais complexas. O SVM (*Support Vector Machine*) é um dos algoritmos cujo uso aumentou muito na última década, sobretudo para o mapeamento de cobertura do solo (LV; XU, 2014). No comparativo com outros algoritmos tradicionais no sensoriamento remoto apresentou resultados superiores em diversos trabalhos (ALEXAKIS *et al.*, 2014; WU; FU REN; NIU, 2014).

Muitos autores têm utilizado o SVM aplicado a imagens LANDSAT para o mapeamento de desastres naturais, como queimadas e deslizamentos. San (2014) avaliou a utilização de SVM e dados ASTER para o mapeamento de deslizamentos na Turquia obtendo bom desempenho para as feições avaliadas. Moosavi, Talebi e Shirmohammadi (2014) produziram um inventário de deslizamentos utilizando SVM, imagens de alta resolução e NDVI, atingindo acurácia geral de 75%.

No entanto o uso de um índice como o NDVI não é suficiente para a identificação de áreas de deslizamento, uma vez que ele amplifica as diferenças da vegetação, o que potencializa a confusão com solo exposto e outras feições com comportamento espectral semelhante. Além disso, a utilização de um único classificador pode não trazer toda a informação que se procura, sendo que, outros classificadores podem ter desempenho pior para um determinado alvo e melhor para outro, dependendo das interações e características do alvo e de seus vizinhos (CHANDRA; YAO, 2006; FOODY, 2009).

A composição de Sistemas de Múltiplos Classificadores (SMC) para a obtenção de melhores resultados de acurácia tem sido utilizada por muitos autores (BIGGIO; FUMERA; ROLI, 2010; DU *et al.*, 2012; WOŹNIAK; GRAÑA; CORCHADO, 2014). De acordo com a literatura (CHANDRA; YAO, 2006), a diversidade de informação resulta em uma classificação mais acurada, pois utiliza as classificações de vários algoritmos com diferentes metodologias de separação de classes para compor uma única classificação final.

Wu e Gao (2012) avaliaram a eficiência da combinação de múltiplos classificadores em imagens LANDSAT ETM+, obtendo melhor acurácia para a combinação do que para os classificadores sozinhos. Mellor *et al.* (2013) utilizaram a combinação de classificadores para a realização de um inventário florestal na Austrália, com base em imagens LANDSAT TM, atingindo acurácia de geral de 96% para a classificação final.

A aplicação de um sistema de classificadores para identificar uma feição que possui características restritas e de difícil classificação pode ser uma alternativa para a obtenção de

um resultado mais acurado. No entanto, de acordo com Abe, Olugbara e Marwala (2014) considerando a vasta quantidade de algoritmos de classificação implementados para o sensoriamento remoto, a escolha dos mais adequados para os dados e os objetivos da classificação é a principal pergunta a ser respondida para a obtenção de bons resultados.

1.5. Área de Estudo

A bacia hidrográfica do Rio Pilões é localizada na divisa entre os municípios de São Bernardo do Campo e São Vicente, no estado de São Paulo, Brasil. Entre os dias 11 e 12 de Dezembro de 1999, um evento severo de deslizamento atingiu a bacia hidrográfica do Rio Pilões (Figura 2). O deslizamento foi consequência de um acumulado de 230 mm de precipitação em quatro dias. O evento se caracterizou como um escorregamento remontante de grande porte, com avalanche de detritos, afetando aproximadamente 700 metros da rodovia Anchieta (OGURA, 2006). A região apresenta altos índices pluviométricos ao longo de todo o ano (acima de 300 mm), porém, os maiores índices são atingidos entre os meses de novembro e março, com médias mensais acima de 1000 mm (WOLLE, 1998).

Figura 2 - Localização da área de estudo e imagem do deslizamento.

Fonte: Manfré *et al.* (2014).

A região onde ocorreu o deslizamento, a Serra do Mar, apresenta diversos elementos sob risco e diferentes eventos pluviométricos extremos (OGURA, *op. cit.*). O relevo da Serra do Mar possui descontinuidades abruptas subsuperficiais ao longo das encostas, que combinados com os altos índices pluviométricos da região formam as condições ideais para a ocorrência de grandes deslizamentos (GUIMARÃES *et al.*, 2009). A figura 3 apresenta o deslizamento sobreposto a um Modelo Digital de Elevação e sua localização com relação aos

limites administrativos municipais e com a Rodovia Anchieta. Observa-se que a bacia hidrográfica do Rio Pilões se localiza em uma área de grande variação altimétrica, muito próxima ao traçado da Rodovia.

Figura 3 - Localização do deslizamento em relação à Rodovia Anchieta e aos limites municipais e sobreposição a Modelo Digital de Elevação .

Fonte: Elaboração Própria.

2. Metodologia de compartimentação do relevo

2.1.1. Introdução

O conceito de paisagem é definido pela combinação dinâmica de componentes homogêneos de cobertura do solo integrados com os ambientes físico, biótico e antrópico (MONTEIRO, 2001). O formato, tamanho, tipo, distribuição e organização desses componentes definem os aspectos básicos da paisagem. Uma paisagem pode ser dividida em unidades homogêneas ou em objetos, baseado nas suas características específicas (LANG; BLASCHKE, 2009).

As bordas de unidades homogêneas da paisagem podem ser mapeadas utilizando diversos critérios para o agrupamento de componentes ou atributos que podem exibir altos graus de correlação (FERREIRA *et al.*, 2011). Atualmente, diversos métodos para a avaliação da estrutura da paisagem estão disponíveis e são principalmente baseados no processamento de informações geográficas e de dados de sensoriamento remoto. A delimitação das unidades da paisagem é fundamental para a qualidade da análise (LANG; BLASCHKE, 2009).

Considerando apenas o aspecto físico da paisagem, o relevo permite o delineamento de áreas homogêneas com um conjunto particular de dinâmicas e restrições no que tange ao uso de solo. Na literatura (LUCENA, 1998; FERREIRA *et al.*, 2011) existe a definição de Unidades Básicas de Compartimentação (UBCs), que correspondem a células básicas adequadas para avaliação geotécnica e geoambiental, permitindo o uso de técnicas de geoprocessamento e sensoriamento remoto (VEDOVELLO, 1999 e 2000). As compartimentações fisiográficas são definidas como áreas de terreno homogêneo que se diferem da vizinhança (VEDOVELLO; MATTOS, 1993; VEDOVELLO, 1999 E 2000).

Vedovello e Mattos (1993) propuseram um procedimento baseado na utilização de imagens de satélite para a compartimentação fisiográfica e caracterização geotécnica. O método proposto é vantajoso quando comparado aos outros métodos previamente propostos (SOARES; FIORI, 1976; VENEZZIANI; ANJOS, 1988). O procedimento é abrangente e os resultados obtidos a partir da análise geotécnica podem ser integrados com variáveis ecológicas, socioeconômicas e outras, como visto nos estudos de Crepani *et al.* (1996), Spörl e Ross (2004) e Manfré *et al.* (2013), que envolveram a análise de fragilidade ambiental e susceptibilidade a erosão. As UBCs nesses estudos foram obtidas por fotointerpretação sistemática de elementos estruturais e de tons em imagens de satélite ou fotografias aéreas. A análise da imagem é baseada nas diferenças de homogeneidade, entropia e assimetria de

elementos texturais e tonais. A análise também leva em consideração outras propriedades da paisagem, tais como o tipo, densidade, arranjo e grau de estruturação dos elementos (SOARES; FIORI, 1976; VEDOVELLO, 1993 e 2000).

No Brasil, alguns estudos têm sido realizados utilizando essas técnicas e UBCs como a unidade de análise. Foram identificados locais para a disposição final de resíduos em uma área urbana densa (IG/SMA, 1999; BROLLO, 2001), um sistema integrado de informação geoambiental para a gestão costeira (SOUZA *et al.*, 2001) e orientações para a restauração socioambiental foram desenvolvidos em áreas de mineração (FERREIRA *et al.*, 2005).

Diversos autores (KEMPER; MACDONALD, 2009; SHARMA, 2009; BROOKES, 2010; PARTRIDGE *et al.*, 2010) utilizaram compartimentações fisiográficas para estudos preliminares. Compartimentações fisiográficas são comumente usados como a unidade de análise, particularmente em estudos ambientais. Outras abordagens de compartimentação do relevo têm sido propostas por autores na literatura (SAADAT *et al.*, 2008; DRAGUT; EISANK, 2012; CAMARGO *et al.*, 2012) e envolvem metodologias analíticas e o uso de dados de *Shuttle Radar Topography Mission* (SRTM) ou outros dados topográficos digitais.

Os dados SRTM são gratuitos e cobrem todo o globo, sendo um conjunto de dados importantes para estudos preliminares e topográficos. São úteis para o planejamento urbano, de transporte e de bacias hidrográficas. O conjunto de dados SRTM foi desenvolvido durante uma missão envolvendo a NASA e as agências espaciais italiana e alemã. Os dados foram coletados em fevereiro de 2000 para fornecer cobertura global de elevação com uma resolução de 90 metros, exceto nos EUA, onde a resolução é de 30 metros e o erro é inferior a 6 metros (WERNER, 2001; RABUS *et al.*, 2003; FARR *et al.*, 2007).

Além do MDE, várias derivações podem ser desenvolvidas utilizando esta informação, tal como a declividade, orientação, sombreamento, curvaturas (vertical e horizontal) e densidade de drenagem. Como o MDE é uma informação contínua, é possível utilizar métodos de interpolação que melhoram a resolução dos dados. Valeriano (2011) utilizou um modelo de interpolação para obter dados de alta resolução para o Brasil (resolução de 30 metros). Este produto e o método para obtê-lo estão disponíveis gratuitamente a partir do site do Departamento de Sensoriamento Remoto do INPE (Instituto Nacional de Pesquisas Espaciais, Brasil).

Saadat *et al.* (2008) propuseram uma abordagem quantitativa para classificação da paisagem com base em MDE e imagens do satélite *Advanced Spaceborne Thermal Emission and Reflectance Radiometer* (ASTER). Gradientes de declividade, relevo e padrões de densidade de drenagem foram utilizados como parâmetros de identificação. As imagens

ASTER foram utilizadas para delinear vários tipos de formas do relevo. Os autores utilizaram uma bacia hidrográfica como área de estudo, e resultados muito precisos foram alcançados. Uma vez que os dados estão disponíveis gratuitamente, esta abordagem pode ser replicada.

Dragut e Eisank (2012) propuseram um método que utiliza dados SRTM global, um detector de fator de escala automática e análise de imagem baseada em objeto (OBIA, do inglês *Object Based Image Analysis*) para classificar a topografia em todo o mundo. Esta abordagem envolve a decomposição da superfície do solo em objetos homogêneos. Dados de elevação são automaticamente segmentados, e o parâmetro de escala ideal é identificado através de uma análise de diferença da variância. Os critérios de classificação são baseados em valores de elevação médios e seus respectivos desvios-padrão. Os resultados incluem limites que correspondem a descontinuidades naturais em escala regional.

No mesmo contexto, Camargo *et al.* (2012) classificaram as formas do relevo com base em vários atributos geomorfométricos e texturais obtidos a partir de dados ASTER/Terra. Os resultados foram avaliados com base em um mapa de referência, e fortes concordâncias entre os dois mapas foram encontradas; assim, a técnica foi eficaz para a extração de formas de relevo.

A técnica OBIA permite a classificação de imagens com base em regiões homogêneas da imagem (objetos). Diversas variáveis e características de imagem, como textura, contexto e estatísticas espectrais, podem ser analisadas (BLASCHKE *et al.*, 2000). De acordo com Farr *et al.* (2007), os dados SRTM podem ser utilizados em áreas urbanas, sendo pouco afetados por construções. A técnica proposta pode substituir interpretações visuais tradicionais em delinear subdivisões fisiográficas. Alguns autores utilizaram a banda 5 do infravermelho médio LANDSAT TM 5 para executar essas interpretações. Nas áreas urbanas, no entanto, a interpretação do terreno pode ser afetada por edifícios.

No que diz respeito à disponibilidade de dados de elevação e a robustez de abordagens baseadas em objeto para delinear compartimentações fisiográficas em grandes áreas, é importante o desenvolvimento de métodos que podem ser replicados em análises regionais ou locais. Além disso, os resultados específicos possam ser gerados com o objetivo de analisar os aspectos fisiográficos característicos de uma região, como susceptibilidade a erosão, perigos, conservação ambiental e hidrologia. Este estudo foi realizado para avaliar a aplicação regional e local do método de análises desenvolvido por Dragut e Eisank (2012) e para desenvolver uma abordagem local, que identifica as áreas de risco, processos erosivos e formas do relevo.

2.1.2. Metodologia

Os dados SRTM que cobrem o Estado de São Paulo, em sua resolução original, foram obtidos no site do Serviço Geológico dos Estados Unidos (USGS, do inglês *United States Geological Survey*). Os dados interpolados do SRTM para a cidade de São Paulo foram obtidos do site do Instituto Nacional de Pesquisas Espaciais (INPE). Os modelos foram desenvolvidos utilizando o programa eCognition Developer 8 (Trimble, 2011). As áreas de validação (Município e Estado de São Paulo) foram selecionadas com base em sua heterogeneidade geomorfológica e na disponibilidade de mapas e descrições do relevo para a validação da análise. As localizações do Município de São e do Estado de São Paulo são apresentadas na figura 4.

Figura 4. - Localização do Município e do Estado de São Paulo.

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

A metodologia para classificar a topografia seguiu a proposta de Dragut e Eisank (2012). Os autores apresentaram um método para definir o fator de escala do processo de segmentação e utilizaram três diferentes fatores de escala para cada nível da classificação: 901 para o nível 1, 181 para o nível 2 e 80 para o nível 3, de acordo com a variabilidade na escala global. Neste trabalho, um método semelhante foi aplicado nas escalas regional (Estado de São Paulo) e local (Município de São Paulo). Os dados SRTM com resolução espacial de 90 metros foram utilizados para analisar o Estado de São Paulo e os dados TOPODATA (INPE, 2011) com resolução de 30 metros foram utilizados para a análise regional do Município de São Paulo.

Para analisar o Estado de São Paulo os fatores de homogeneidade de forma e compacidade foram ajustados para zero. Em relação à metodologia de Dragut e Eisank (2012) a única diferença foi o fator de escala para a segmentação. Dessa maneira, a definição das bordas das regiões topográficas é estabelecida de acordo apenas com as características do relevo. Em uma análise regional, a classificação se torna relativa, dependendo dos limites da área de estudo. No caso do Estado de São Paulo, parte dos limites políticos corresponde a descontinuidades naturais (e.g. grandes rios e o litoral). A aplicação desse método para o Estado de São Paulo, dessa maneira, produzirá resultados condizentes com a realidade. Os resultados foram analisados considerando mapas e descrições geomorfológicas da área. As pesquisas de Martinelli (2009) e Ross e Moroz (1997) foram utilizadas como referência para a avaliação dos resultados em escala regional.

Para a análise local, a topografia do Município de São Paulo foi extraída da análise para todo o Estado. As verificações foram realizadas baseadas nos estudos de Ab'Saber (1957 e 1969), Silveira (2008) e do mapa Geotécnico do Município de São Paulo (PMSP; IPT, 1991), fornecido pela Secretaria do Meio Ambiente do Município de São Paulo. Esse mapa contém informações sobre a geologia, solo e relevo, importantes para avaliar as componentes fisiográficas do relevo. De acordo com Alves e Castro (2003), a geologia e o relevo estão relacionados, primariamente devido às variações climáticas durante o Quaternário (BIGARELLA, 1964; BIGARELLA; MOUSINHO; SILVA, 1965; TRICART, 1972; BÜDEL, 1982).

A metodologia empregada aos dados TOPODATA foi semelhante, porém considerando apenas os limites do Município de São Paulo. Os dados locais resultam em diferentes características do terreno, que são abordados no método com base em parâmetros estatísticos como elevação média e variância. Geralmente, os parâmetros de escala para

segmentação podem ser definidos usando métodos exploratórios subjetivos de tentativa e erro (MEINEL; NEUBERT, 2004). Os parâmetros de escala são muito importantes para o processo de segmentação (*i.e.*, dividir imagens de sensoriamento remoto em regiões discretas ou objetos) e fundamentais para a classificação e precisão estatística (BLASCHKE, 2003; ADDINK; DE JONG; PEBESMA, 2007). O fator de escala para a segmentação da imagem foi ajustado para 52, *i.e.*, valor que não produz nenhuma mudança na variância local (Figura 5).

Figura 5. - Fator de escala e variância local para o recorte do Município de São Paulo.

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

A definição do subconjunto espacial é importante porque os limites do Município de São Paulo não correspondem totalmente às características naturais, como vales e divisores de bacias hidrográficas, por exemplo. Portanto, uma definição razoável da área analisada deve considerar as discontinuidades naturais para além dos limites da cidade. Esta etapa é importante, porque o primeiro critério de classificação requer a utilização da média de elevação no subconjunto analisados. O mapa resultante foi novamente comparado com o mapa geotécnico e as descrições geomorfológicas do Município de São Paulo (AB'SABER, 1957 e 1969; SILVEIRA, 2008).

Uma abordagem diferente, que inclui a utilização dos dados derivados do MDE foi desenvolvida. O objetivo foi melhorar os resultados de segmentação e facilitar a definição dos critérios de classificação. De acordo com Valeriano (2003a), a geração de produtos derivados do SRTM possui várias restrições e deve ser realizada com cuidado, principalmente em regiões onde os dados têm uma resolução mais baixa. Os produtos TOPODATA que foram

gerados seguindo o método de Valeriano (2002, 2003a e 2003b) e Valeriano e Carvalho Junior (2003) foram utilizados neste estudo.

Além disso, as classes definidas por Dragut e Eisank (2012) foram propostas para a classificação de formas de relevo em uma escala global; portanto, eles não eram apropriados para aplicações locais. A especificação das classes de paisagem neste estudo é baseada na necessidade de um mapa multiuso que possa ser usado para vários propósitos de planejamento e para outras áreas.

Consequentemente, com base em métodos apresentados na literatura, tais como o de Saadat *et al.* (2008), outras variáveis além da elevação podem ser utilizadas para delinear regiões homogêneas do relevo. A nova abordagem proposta neste trabalho visa diminuir a relatividade da análise. Devido às características do terreno, os valores são localmente extraídos e variam de uma área de estudo para outra. Com este objetivo em mente, o segundo nível dos critérios de classificação foi definido com base em limites de referência geomorfológicos (CHRISTOFOLETTI 1974 e 1979; MOREIRA; PIRES NETO, 1998), que são valores particulares da declividade e elevação. Terrenos levemente inclinados e mais íngremes são definidos usando limiares de declividade de 6.5° e 11° e feições elevadas e baixas são definidas pelo limiar de altitude de 760 metros. As classes de forma do relevo resultantes foram rampas, colinas baixas, colinas altas, montanhas e planaltos. Estas classes foram subdivididas em classes alta e baixa com base nas elevações médias dos objetos de imagem, como mostrado na Figura 6.

Figura 6. - Exemplo de objetos da imagem e seus valores médios de elevação.

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

A segmentação nesta nova abordagem foi definida utilizando outras variáveis além da elevação numérica (ZN): a densidade de drenagem (DD), curvatura horizontal (HN), de curvatura vertical (VN) e a declividade (SN). Todos estes dados foram obtidos a partir dos dados SRTM interpolados que estão disponíveis no conjunto de dados TOPODATA (INPE, 2011). O uso destes dados auxiliares é consistente com a hipótese de compartimentação do relevo e é uma tentativa de tornar mais evidentes características topográficas (VALERIANO, 2003^a; VALERIANO; CARVALHO JÚNIOR, 2003).

A segmentação é um passo importante no processo de classificação OBIA. Para produzir bons resultados, é importante identificar o melhor conjunto de variáveis para a definição das regiões homogêneas da imagem (objetos). Assim, a todas as variáveis selecionadas foram atribuídos o mesmo peso para o processo de segmentação, visando equalizar as características topográficas. Seguindo Dragut e Eisank (2012), os fatores de forma e de compacidade foram ajustados para zero, eliminando, assim, os efeitos de quaisquer formas definidas sobre os objetos de imagem. Além disso, para preservar os parâmetros de análise, um fator de escala de 52 foi usado, ou seja, o mesmo fator usado na outra abordagem que não apresenta diferença na variância local.

Em conformidade com as definições geomorfológicas apresentadas por Christofolletti (1974), um sistema de classificação de árvore de decisão foi desenvolvido, como mostrado na Figura 2.11. O limiar de primeiro nível foi mantido, pois a elevação representa um critério de classificação do relevo que foi apresentado por vários autores (CAMARGO *et al.*, 2009). Assim, a relatividade da análise foi mantida porque a elevação média varia de acordo com o subconjunto selecionado. O critério seguinte, no entanto, reduz a relatividade local, ao fundir classes do nível 3 – colinas altas e colinas baixas. No segundo nível de classificação, os limiares de Christofolletti (1974 e 1979) e Moreira e Pires Neto (1998) foram utilizados para definir as subdivisões do relevo, o que resultou nas seguintes classes:

- Rampas
- Colinas Baixas
- Colinas Altas
- Planalto
- Montanhas

Para a classificação do segundo nível, Dragut e Eisank (2012) propuseram o uso do desvio padrão da elevação. A média e o desvio-padrão calculado servem como os limiares

para a definição das classes. O desvio padrão da elevação representa a gradiente de inclinação de cada objeto. Portanto, a utilização da declividade é uma característica intrínseca deste método. O uso direto da declividade do terreno permite a aplicação de valores de referência para extrair a fisionomia do relevo.

Para aplicar uma abordagem baseada em formas do relevo e para produzir um mapa com aplicações diretas no planejamento do uso da terra, as curvaturas do relevo devem ser consideradas. Portanto, as áreas côncavas e convexas das montanhas e colinas (baixo e alto) foram delineadas com base nos valores médios da curvatura vertical. Para as rampas, os valores médios da curvatura horizontal foram utilizados para delinear os terraços e planícies de inundação. Os planaltos definidos no nível 2 não foram subdivididos porque eles já constituem uma importante classe de relevo. Os valores negativos ou positivos das curvaturas verticais e horizontais foram os critérios utilizados para determinar se uma vertente era côncava ou convexa. Maiores detalhes e melhor delimitação de áreas de risco podem ser produzidas através da definição de classes, de acordo com os mais altos valores dessas variáveis.

Para o terceiro nível da classificação do relevo, os métodos descritos por Ross (1994) e Crepani *et al.* (1996) foram utilizados porque podem dividir a paisagem em áreas com potencial de erosão. Um dos objetivos principais da compartimentação do relevo foi desenvolver unidades de análise de potencial de erosão e de outras áreas de atuação, tais como zoneamento ecológico-econômico, planejamento residencial, gestão de emergência, proteção ambiental e drenagem urbana. Portanto, curvaturas horizontais e verticais foram utilizadas como critérios para definir classes particulares. Para este efeito, classes de declividade côncavas e convexas foram definidas, além de áreas de erosão e planícies de inundação. Os resultados foram validados com base nas descrições do relevo e em mapas.

A Tabela 1 apresenta um resumo dos critérios metodológicos e dos dados utilizados em cada abordagem.

Tabela 1. - Resumo dos dados utilizados em cada método.

Escala	Dados	Estratégia metodológica	Variáveis para Segmentação	Variáveis para Classificação	Resolução do dado
Regional (Estado de São Paulo)	SRTM	Dragut and Eisank (2011)	ZN	Level 2, Level 3 Desvio-Padrão de ZN	90 m
Local (Município de São Paulo)	TOPO DATA	Dragut and Eisank (2011)	ZN, SN, DD, HN and VN	Level 2, Level 3 Desvio-Padrão de ZN	30 m
Local (Município de São Paulo)	TOPO DATA	Nova metodologia	ZN, SN, DD, HN and VN	Level 2 Média de SN, Level 3 Média de HN e VN	30 m

ZN – Elevação Numérica; SN – Declividade Numérica; DD – Densidade de Drenagem, HN – Curvatura Horizontal Numérica; VN – Curvatura Vertical Numérica

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

2.1.3. Resultados

O mapa das compartimentações do relevo do Estado de São Paulo é apresentado na Figura 7; foi desenvolvido utilizando uma aplicação regional do método de Dragut e Eisank (2012). O mapa mostra uma grande área de planícies e planaltos homogêneos que dividem as partes do Centro-Leste e Leste do estado. As bordas de várias características fisiográficas conhecidas, como as Cuestas na região Central, os Vales do Ribeira (Sul) e do Paraíba (Leste), e as Serras da Mantiqueira (Leste) e do Mar (Litoral), são aparentes.

Figura 7. - Mapa da Compartimentação do relevo para o Estado de São Paulo. As seguintes regiões são destacadas: A) Vale do Paraíba; B) Serra do Mar; C) Vale do Ribeira; D) Cuesta Central; E) Vale do Tietê; F) Vale do Paranapanema; e G) Serra da Mantiqueira.

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

A Figura 8 apresenta o mapa de relevo Estado de São Paulo, com uma classificação topográfica mais refinada. Algumas particularidades do relevo que aparecem na Figura 7 são enfatizadas pelo refinamento classes neste mapa, e outras feições também estão representadas. As bordas das planícies fluviais e algumas das represas e açudes do estado são mostradas. A maior parte do estado é classificada como planícies irregulares.

Figura 8. - Mapa das formas do relevo para o Estado de São Paulo. As seguintes regiões são destacadas: A) Vale do Paraíba; B) Serra do Mar; C) Vale do Ribeira; D) Cuesta Central; E) Vale do Tietê; F) Vale do Paranapanema; e G) Serra da Mantiqueira.

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

O mapa da compartimentação topográfica resultante de forma geral representa o relevo do Estado de São Paulo. Em uma comparação com os mapas geomorfológicos (ALMEIDA, 1964; IPT, 1981, ROSS; MOROZ, 1997; IBGE, 2000), vários limites e formas do relevo são consistentes, e as classificações dos dois mapas são semelhantes. Os componentes mais evidentes são as seguintes: Vale do Paraíba, que está localizado no lado oriental extremo do estado; Vale do Ribeira de Iguape, que está localizado na parte sul do Estado; Planícies costeiras (limites Sudeste); Serras da Mantiqueira e do Mar (localizado no extremo leste do Estado) e as Cuestas na parte Centro-Sul do Estado.

O mapa de formas do relevo Estado de São Paulo mostra o relevo em maior detalhe, *i.e.*, subdividindo cada uma das classes apresentadas na Figura 7 em duas classes. Planícies fluviais e represas são definidas neste nível. As planícies dos rios Tietê e Paranapanema e outros grandes rios são identificados. O Vale do Rio Paraíba é dividido em planícies irregulares e planícies; as Serras da Mantiqueira e do Mar adjacentes a este vale são subdivididas em colinas rugosas e montanhas baixas e montanhas altas. A mesma divisão é

apresentada para as Cuestas e outras formações montanhosas na parte Centro-Sul do estado. A maior parte do Estado é classificada como planícies irregulares.

Em geral, o resultado da classificação fornece um mapa altamente detalhado do relevo do Estado de São Paulo. Quando comparado com os mapas de Ross e Moroz (1997) e IBGE (2000), *i.e.*, os mais recentes mapas geomorfológicos da região, esta classificação fornece um mapa preciso de forma eficiente com um alto nível de detalhe e limites refinados. Quando comparados com os resultados de Martinelli (2009), o mapa também mostra vários recursos com elevado nível de detalhe.

A Figura 9 apresenta o mapa do relevo do Município de São Paulo, que foi extraído a partir do mapa na Figura 7. A fisiografia é essencialmente dividida em planaltos e colinas e montanhas. As bordas das Serras da Cantareira (Norte) e do Mar (Sul) são as únicas discontinuidades naturais mostradas no mapa. A Figura 10 apresenta o mapa de formas do relevo do Município de São Paulo, que foi extraído a partir do mapa na Figura 8. O relevo predominante na cidade é de planaltos, embora suas bordas neste mapa sejam mais refinadas do que as apresentadas na Figura 9.

Figura 9. - Mapa da compartimentação do relevo para o Município de São Paulo, recorte do Mapa para o Estado de São Paulo. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

Figura 10. - Mapa das formas do relevo para o Município de São Paulo, recorte do Mapa para o Estado de São Paulo. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

Os resultados da abordagem local, utilizando o método de Dragut e Eisanck e (2012) são apresentados nas Figuras 11 e 12. A Figura 11 apresenta a compartimentação do relevo para o Município de São Paulo, e a Figura 12 apresenta o as formas do relevo para a mesma localidade. Na Figura 11, quatro classes são representadas dentro dos limites do Município de São Paulo. A Serra da Cantareira (Norte) é classificada como montanhas e planícies fluviais proeminentes são delineadas. O mapa da Figura 12 mostra sete classes dentro dos limites da cidade de São Paulo. As bordas da Serra da Cantareira são mais evidentes, embora a maior parte da cidade ainda seja classificada como planaltos.

Figura 11. - Mapa da compartimentação do relevo para o Município de São Paulo utilizando abordagem local. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

Figura 12. - Mapa de formas do relevo para o Município de São Paulo utilizando a abordagem local. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

A Figura 13 apresenta um novo método no qual OBIA é usado para classificar compartimentações e formas de relevo em escala local. Devido ao potencial para o

crescimento urbano, a dinâmica de erosão e da alta densidade urbana da cidade de São Paulo, as classes definidas dos acidentes geográficos foram baseadas na topografia de encostas e planícies para delinear áreas que são suscetíveis a inundações, erosão, deslizamentos de terra, problemas de drenagem, questões ambientais e vários tipos de uso da terra. As classes definidas foram planícies de inundação, terraços, planaltos, colinas côncavas, colinas convexas, montanhas côncavas e montanhas convexas.

Figura 13 - Metodologia proposta para a compartimentação e identificação de formas do relevo.

Fonte: Adaptado de Manfré, Nobrega e Quintanilha (2014)..

O mapa da Figura 14 apresenta as compartimentações do relevo para o Município de São Paulo; os compartimentos foram gerados utilizando o novo método proposto. As classes definidas foram rampas, colinas baixas, colinas altas, montanhas, planaltos e montanhas. Os limites e formas das Serras da Cantareira e do Mar e do planalto central são aparentes.

O mapa de formas do relevo do Município de São Paulo com base no novo método é apresentado na Figura 15. Além de corpos d'água, sete classes foram obtidas. As feições de relevo são subdivididas, e as barragens que atravessam as bacias hidrográficas são bem definidas. As planícies de inundação e terraços ao longo dos principais rios da cidade (Tietê, Pinheiros e Tamanduateí) são delineadas.

Figura 14 - Mapa da compartimentação do relevo para o Município de São Paulo utilizando a nova metodologia proposta. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

Figura 15. - Mapa das formas do relevo para o Município de São Paulo utilizando a nova metodologia proposta. As seguintes regiões são destacadas: A) Rio Tietê; B) Rio Pinheiros; C) Serra da Cantareira; e D) Serra do Mar.

Fonte: traduzido de Manfré, Nóbrega e Quintanilha (2014).

2.1.4. Discussão

Este capítulo apresenta uma adaptação do método de Dragut e Eisanck (2012) para definição de compartimentações e formas de relevo regional e local. O método adaptado, quando aplicado ao Estado de São Paulo como uma abordagem regional, forneceu resultados razoáveis. Foram definidos os limites do relevo, e foram encontradas características semelhantes às descritas na literatura geomorfológica (ALMEIDA, 1964; IPT, 1981; ROSS; MOROZ, 1997; IBGE, 2000; MARTINELLI, 2009). A abordagem local proposta neste trabalho utiliza dados derivados de MDE para a segmentação e classificação. Esta abordagem forneceu um mapa refinado que mostra, em detalhe considerável, as características topográficas descritas na literatura.

Os resultados satisfatórios obtidos para a análise do Estado de São Paulo podem ser atribuídos aos limites políticos do estado, que correspondem a limites naturais. Essa característica facilita a análise, porque a avaliação é baseada em estatísticas da área total analisada. Além disso, o Estado de São Paulo tem uma geomorfologia heterogênea que é classificada em termos de elevação e gradientes de declividade, sendo bem representada pelas oito classes propostas.

Portanto, o método proposto pode ser aplicado à escala regional obtendo-se resultados satisfatórios. Este desempenho favorável é o mais provável devido ao tamanho da região, que contém um conjunto muito variado de objetos que melhoram os critérios de classificação, que se baseiam nas estatísticas dos objetos. Assim, a elevação média e o desvio padrão são úteis para a classificação das formas de relevo.

A análise pode ser mais elaborada para produzir um mapa de formas do relevo mais detalhado. A definição de critérios mais refinados iria depender da finalidade da análise. A importância do estudo de caso da abordagem regional é demonstrar o potencial e adequação deste método para a análise regional.

A taxonomia apresentada para as formas de relevo encontradas não é a mais adequada para as características do Estado de São Paulo. Ajustes devem ser feitos para melhorar este trabalho e desenvolver uma nomenclatura adequada para o mapa de relevo.

Quando utilizado num contexto local, o método proposto de maneira geral define bem os compartimentos e formas do relevo, como mostrado nas Figuras 9 e 10. Algumas características fisiográficas são definidas na Figura 10. No entanto, o Município de São Paulo foi essencialmente classificado como planalto e colinas altas, omitindo detalhes de sua

topografia heterogênea. Essa deficiência é claramente devido à escala de análise, adequada para uma área muito maior com maiores variações de altitude e inclinação.

A mesma falta de detalhe está presente na Figura 11, embora novos limites apareçam neste mapa. Colinas altas são delineadas nas partes Sudeste e Oeste do município. O resultado também não representa o relevo diverso da área de estudo, especialmente nas regiões Central e Sul da cidade (AB'SABER, 1957 e 1969; SILVEIRA 2008, PMSP; IPT, 1991).

Estes produtos indicam que o método proporciona bons resultados em uma escala regional, e ele pode ser usado com restrições particulares em uma escala local. Uma extração desta análise regional deve ser cuidadosamente analisada; o método pode ser utilizado, dependendo do tamanho da extração e da finalidade da análise.

Portanto, essa abordagem é eficiente para apoiar o planejamento do uso do solo, bacias hidrográficas, e de redes de transporte, entre outros usos. A abordagem pode ser replicada em qualquer análise regional e exige apenas a verificação e ajustes particulares (fatores de escala, regras de classificação e tamanho da área), dependendo das especificações geomorfológicas e dos objetivos da classificação.

O mapa da Figura 12 apresenta uma área classificada como planícies, e os limites das principais Serras não coincidem com as descrições publicadas ou com o mapa geotécnico (AB'SABER, 1957 e 1969; PMSP; IPT, 1991). Esta área é seccionada pela Serra do Mar, que foi delineada bem nas Figuras 9 e 10. Esse erro de classificação pode ser atribuído ao tamanho da área de análise ou aos critérios de classificação (a média dos desvios-padrão dos objetos era muito baixa).

No entanto, a análise abrangeu uma área que se estendia muito além dos limites do Município de São Paulo, ou seja, as quatro classes são representadas dentro dos limites da cidade. Esta situação indica que a área tem uma geomorfologia muito heterogênea. Portanto, o uso de dados de resolução mais alta pode ser uma abordagem melhor para esta região.

O mapa de formas do relevo da Figura 12, que foi derivado do mapa da Figura 11, não fornece uma caracterização superior do Município de São Paulo, quando comparado com as descrições de Ab'Saber (1957), Silveira (2008) e PMSP e IPT (1991). O único refinamento representado por este mapa com relação ao da Figura 10 é a delimitação das principais planícies fluviais.

A utilização dos dados interpolados não se justifica, uma vez que não trouxe melhora considerável. A aplicação direta do método de análise em escala local não fornece os resultados esperados. Este desempenho não deve ser atribuído aos dados, uma vez que está essencialmente relacionado com o método que utiliza todo o subconjunto estatístico para

definir os limiares de classificação. Esta análise é relativa; assim, a classificação varia dependendo do subconjunto. Portanto, a aplicação regional do método global proposto é razoável e dá bons resultados, mas a sua aplicação local é limitada e deve ser cuidadosamente analisada.

A densidade de drenagem e as curvaturas horizontal e vertical são variáveis altamente dependentes das formas topográficas; essas variáveis melhoram a segmentação gerando objetos mais homogêneos. As curvaturas horizontal e vertical e a declividade numérica influenciaram de forma semelhante nos resultados da classificação de formas do relevo, uma vez que foram adicionadas à análise outras variáveis topográficas. Essas melhorias são preconizadas na literatura (VALERIANO, 2003^a; TUCKER *et al.*, 2001; SPÖRL; ROSS, 2004; CREPANI *et al.*, 1996,).

A nova abordagem forneceu um mapa muito semelhante ao mapa geotécnico (PMSP; IPT, 1991) e às descrições de AB'SABER (1957) e SILVEIRA (2008). A Serra da Cantareira e o Pico do Jaraguá são delineados na Figura 14, assim como as características de montanha nas regiões Leste, Oeste e Sul da cidade. Além disso, a área elevada na parte Central da cidade (Espigão Central), entre as duas principais planícies fluviais é delineada e é classificada como montanha. No entanto, a diferença mais importante deste produto é a classificação dos planaltos, que são restritos a áreas muito pequenas. O mapa também é consistente com o mapa geotécnico pela PMSP e IPT (1991) e as descrições por Ab'Saber (1957).

O mapa da Figura 15 representa a aplicação da nova abordagem para a classificação de formas do relevo e é um produto muito mais refinado do que os outros mapas apresentados neste trabalho. Terraços são separados e planícies de inundação foram delineadas nas áreas de rampa. Esta subdivisão permite a análises que subsidiam problemas de drenagem urbana, importantes quando se considera a alta densidade populacional da cidade de São Paulo. Fluxos de águas pluviais, erosão e dinâmicas de inundação podem ser analisados e planos de prioridade podem ser desenvolvidos. Além disso, o desenvolvimento em terraços deve ser analisado, pois alterações nessas regiões podem produzir graves problemas na dinâmica de erosão e impactar negativamente no ecossistema do rio. Este mesmo cuidado deve ser tomado em qualquer intervenção em planícies de inundação.

Colinas altas e baixas foram ambas delineadas entre as encostas côncavas e convexas. O mesmo critério foi adotado para as montanhas. Esta abordagem permite a identificação das áreas mais suscetíveis à erosão, deslizamentos de terra e problemas de drenagem. A abordagem também pode ser útil no planejamento de uso da terra em planícies urbanas em

outras regiões, pois indica as áreas em que a intervenção deve ser realizada com maior cautela. Notavelmente, as classes de vertentes côncavas caracterizam a continuidade da drenagem, que é um parâmetro importante na abordagem de questões ambientais, particularmente aqueles associados com a erosão e preservação dos ecossistemas de água. A conservação da vegetação nessas áreas é fundamental para vários processos, incluindo a conservação do solo e manutenção do ciclo hidrológico (COROMINAS, 2005).

No entanto, um melhor estudo da drenagem urbana pode resultar do uso de alta resolução informação topográfica, como mostrado por Sreedevi *et al.* (2013). Segundo esses autores, uso de dados SRTM e análises de geoprocessamento da drenagem urbana são mais apropriadas do que os métodos convencionais. Essas análises podem ser muito úteis para a implantação de aproveitamento de águas pluviais e manejo de bacias hidrográficas.

Um exemplo de erosão em áreas côncavas é a grande cicatriz de deslizamento de terra próxima à Rodovia Anchieta, em São Paulo. O deslizamento de terra ocorreu em dezembro de 1999 durante a estação chuvosa, e a cicatriz é ainda visível. A Figura 16 mostra a localização da cicatriz e a sobreposição do mapa de formas do relevo e uma imagem de satélite de alta resolução. A cicatriz do deslizamento de terra corresponde exatamente a uma área classificada como uma vertente côncava. Assim, a nova abordagem pode ajudar a mapear a susceptibilidade a deslizamentos de terra e a realizar investigações geotécnicas preliminares.

Figura 16. - Sobreposição do mapa de formas do relevo ao deslizamento de terra próximo à Rodovia Anchieta.

Fonte: adaptado de Manfré, Nóbrega e Quintanilha (2014).

As feições convexas representam, principalmente, os topos de montanhas e colinas, que são importantes no planejamento de bacias hidrográficas. Esses recursos correspondem a várias características topográficas descritas por Ab'Saber (1957 e 1969) e Silveira (2008). Os contornos das feições também correspondem aos indicados no mapa geotécnico (PMSP e IPT 1991).

Com base numa comparação com o método de Nobre *et al.* (2011), que se baseia na abordagem HAND (altura acima da drenagem mais próxima), o mapa da Figura 15 indica que a nova abordagem dá bons resultados. Nobre *et al.* (2011) mapeou as áreas de risco na região metropolitana de São Paulo, e seu mapa mostra limites e áreas que correspondem aos apresentados na Figura 15. As principais áreas de risco estão localizadas nas áreas classificadas como encostas côncavas. Além disso, as planícies de inundação coincidem com as mapeados neste estudo, e os terraços correspondem a áreas altamente erodidas mapeadas neste estudo.

Este produto é superior porque as derivações do SRTM são utilizadas para a segmentação e limites teóricos são utilizados na classificação. Além disso, os elementos relacionados com a topografia foram usados para delinear novos limites. Estas medidas

resultaram em um mapa multifuncional que pode ser subdividido em classes que agregam outras informações do relevo.

As áreas urbanas apresentam relevo alterado devido à drenagem, transporte e desenvolvimento de habitação. Uma análise altamente detalhada usando dados obtidos do SRTM pode não ser muito precisa ou atualizada. O fator de escala adotado não afeta esses aspectos da análise, exceto quando há grandes alterações nas bacias de drenagem, como é evidente nas planícies do rio Tietê e Pinheiros; esses cursos d'água foram retificados e provocaram mudanças substanciais na topografia (SILVEIRA, 2008).

As informações fornecidas pelos mapas neste estudo são muito importantes para a definição de áreas de relevo homogêneo e para o gerenciamento do uso da terra. Neste estudo de caso do Município de São Paulo, que é uma megacidade altamente urbanizada, tal mapeamento é importante não apenas para áreas subdesenvolvidas e planejamento urbano, mas também para projetos de drenagem, mitigação dos riscos, projetos habitacionais, mapeamento de serviços de gestão de emergências, questões ambientais e de planejamento de transporte. Recentemente, autores têm utilizado informações geomorfológicas para delinear áreas de erosão severa (BESKOW *et al.*, 2009; Jorge, 2009; FURLAN, BONOTTO; GUMIERE, 2011), inundações (GAO; NICKUM; PAN, 2007) e os riscos de deslizamento de terra (NICOLL, 2010). Este último autor avaliou os riscos de deslizamento de terra para empreendimentos residenciais recentes nos EUA com base em variáveis geomorfológicas.

Várias estradas principais e ruas da cidade estão localizadas na área classificada como planícies de inundação. Além disso, ferrovias estão localizadas no mesmo plano (em toda a área metropolitana de São Paulo) e são drasticamente afetadas por inundações durante a estação chuvosa. Notavelmente, os mapas apresentados neste trabalho podem servir de orientação para as áreas que merecem atenção especial para a mitigação. Da mesma forma, vários projetos habitacionais foram construídos em áreas de risco.

Além disso, uma combinação de mapas de relevo com imagens de satélite, informações e dados geológicos podem fornecer a base para uma análise das áreas suscetíveis a enchentes, inundações e deslizamentos de terra. Youssef, Pradhan e Hassan (2011) utilizaram dados SRTM para desenvolver parâmetros morfométricos e avaliar as áreas suscetíveis a inundações repentinas no Egito. Um estudo semelhante foi realizado na Turquia por Demirkesen (2012) para identificar áreas de riscos de inundação que utilizam dados SRTM. Oh e Lee (2011) usaram imagens SRTM para obtenção de parâmetros que indicam susceptibilidade a deslizamento de terra na China. Parâmetros morfométricos foram utilizados de forma semelhante neste estudo para classificar o relevo, sendo que o conjunto de

parâmetros possa ser ajustado de acordo com um objetivo específico, tal como a identificação de potenciais regiões de inundações repentinas.

Considerando-se a atual expansão de ferrovias, estradas e outras instalações de transporte em São Paulo e a implantação de planos de mobilidade urbana, estes produtos podem tornar-se essenciais para os planejadores urbanos e tomadores de decisão. As informações sobre o relevo são fundamentais no planejamento de mobilidade e transporte urbano, e a delimitação de áreas topográficas homogêneas é importante para a otimização da mobilidade urbana.

Os mapas apresentados podem ser usados para compreender a expansão urbana, pois a geomorfologia molda naturalmente o desenvolvimento urbano. É importante compreender a expansão urbana, como demonstrado por Jacquin, Misakova e Gay (2008). Dinâmica de uso da terra com base em unidades homogêneas, ou Unidades Territoriais Básicas (UTBs) de acordo com Crepani *et al.* (1996) e Manfré *et al.* (2013), devem ser consideradas.

UTBs são as células elementares de informação e análise ambiental. Essas unidades possuem atributos que permitem a diferenciação dentro de um bairro (SPÖRL; ROSS, 2004). Cada uma dessas unidades é dinamicamente ligada com as outras, permitindo, assim, a sua articulação em uma complexa rede de unidades (LUCENA, 1998). UTBs permitem a integração de vários atributos ou variáveis ambientais, dependendo dos processos que estão a ser avaliados (FERREIRA *et al.*, 2011). As unidades fisiográficas definem os limites fundamentais na análise da dinâmica de uso da terra.

2.1.5. Conclusões

O método proposto fornece uma abordagem adequada para a compartimentação do relevo. Qualquer um dos produtos do método pode ser utilizado, dependendo do objetivo final da análise. O método de Dragut e Eisanck (2012) serviu como uma diretriz, embora as classes de interesse e seus critérios de classificação devam ser mais bem definidos quando se realiza análises locais.

A principal contribuição deste trabalho é o desenvolvimento de um método para análises locais, e a erosão foi a principal questão abordada no delineamento das subdivisões de relevo e de suas formas. A escolha das classes e métodos pode variar, dependendo dos objetivos do estudo. O método de compartimentação fisiográficas e seus critérios podem ser amplamente replicados, pois se baseia em pressupostos teóricos e definições de feições fisiográficas.

O resultado é um produto que pode ser usado para diversos fins, tais como planejamento urbano, planejamento de bacias hidrográficas e de zoneamento ecológico-econômico. O produto pode ser obtido rapidamente utilizando ferramentas analíticas simples, e que fornecem delimitação detalhada de áreas que são geomorfologicamente homogêneas.

No contexto do Município de São Paulo, o produto fornece informações básicas relevantes para o desenvolvimento de habitação e planejamento de risco, a expansão da rede de transporte, áreas de preservação ambiental, coleta de lixo, centros de tratamento de resíduos e infraestruturas semelhantes e outras questões ambientais. Devido a seu status de megacidade, um espaço vazio dentro e perto de São Paulo é raro e valioso. As relações entre os valores da terra e as formas do relevo não são estreitamente correlacionados porque muitas variáveis dentro de uma megacidade devem ser consideradas. No entanto, as compartimentações do relevo são características fisiográficas importantes na definição de áreas de risco e nas implicações dos usos da terra, que impactam diretamente em seu valor. Estas subdivisões são informações fundamentais para a política pública.

Este estudo propõe um método para a compartimentação fisiográficas e mapeamento de relevo usando dados obtidos do SRTM, e outros critérios podem ser utilizados para outros fins. Cada região tem seu próprio conjunto de características e classes que podem ser incluídos na análise. Talvez a contribuição mais importante deste método seja sua replicabilidade, uma vez que, baseia-se nos dados que estão disponíveis em todo o mundo.

3. Identificação de cicatrizes utilizando *Support Vector Machine* aplicado ao Índice de Vegetação da Diferença Normalizada

3.1. Verificação da empregabilidade do NDVI para identificação de deslizamentos

3.1.1. Introdução

O algoritmo *Support Vector Machine* (SVM) consiste em uma técnica de classificação binária, gerando uma separação em duas classes. Este algoritmo utiliza apenas os vetores de suporte, delimitados pelas amostras mais externas de cada classe, para executar a classificação (VAPNIK, 1995). O classificador descreve um hiperplano ótimo para a separação com base nas maiores distâncias da margem delineadas pelos vetores de suporte (BURGES, 1998). Contudo, os dados frequentemente se distribuem de maneira não linear, restringindo a aplicação do algoritmo SVM. Para resolver este problema, Boser, Guyon e Vapnik (1992) propuseram o uso de funções Kernel para projetar os dados em um espaço dimensional maior e permitir a descrição de hiperplanos de separação mais precisos.

O emprego deste algoritmo na classificação da cobertura do solo utilizando imagens de sensoriamento remoto orbital tem se intensificado na última década. Vários autores têm adotado esta técnica para identificar e monitorar mudanças na cobertura e uso do solo. Bons resultados foram demonstrados em sua utilização em imagens de alta e média resolução espacial. Empregando imagens ASTER de 15 metros de resolução, Szuster, Chen, Borger (2011), compararam os resultados da classificação de áreas costeiras obtidas por meio dos algoritmos SVM, Máxima Verossimilhança (MV) e Redes Neurais (RN). O algoritmo SVM gerou melhores resultados, pois sua classificação apresentou maior acurácia que os outros algoritmos supracitados.

Por sua vez, Zhao e Liu (2010) utilizaram imagens Landsat e CBERS (*China-Brazil Earth Research Satellite*) para monitorar mudanças no uso do solo em Hanói (Vietnã) por meio do classificador SVM. Similarmente, Lizarazo (2008) também empregou o algoritmo SVM para classificar o uso do solo urbano, obtendo resultados significativos. Segundo Yao, Tham e Dai (2008) o algoritmo SVM corresponde ao mais acurado para a classificação de imagens.

Foody e Mather (2006) e Pal e Mather (2006) destacam dentre as vantagens do classificador SVM o menor esforço amostral em relação aos outros algoritmos. Os autores testaram esta hipótese em uma área agrícola no Reino Unido. Os resultados demonstraram

que se os vetores de suporte de cada classe são bem amostrados não há necessidade de extensas áreas de treinamento.

Além disso, a aplicação do algoritmo na identificação de áreas de desastres foi testada e teve sua viabilidade comprovada. Petropoulos *et al.* (2010) e Petropoulos, Kontoes e Keramitsoglou (2011) avaliaram áreas incendiadas na Grécia, utilizando imagens ASTER e LANDSAT, de 15 e 30 metros de resolução espacial, respectivamente. Os resultados demonstraram boa acurácia para o método SVM. Yilmaz (2010) comparou os métodos SVM, RN, regressão logística e probabilidade condicional na identificação de deslizamentos na Turquia. Os melhores resultados foram obtidos por meio dos métodos SVM e RN, os quais, conforme os autores são os modelos mais suscetíveis à variabilidade de pixels.

Desta forma, este artigo busca avaliar o algoritmo SVM e propor uma metodologia para sua aplicação na identificação de deslizamentos adjacentes a uma importante rodovia costeira do estado do Estado de São Paulo, Brasil, utilizando imagens LANDSAT *Thematic Mapper* (TM) 5.

3.1.2. Metodologia

Imagens LANDSAT TM 5 (30m) de junho de 2000 foram utilizadas neste estudo. Esta cena foi escolhida em função dos menores índices de precipitação na área neste período, uma vez que em outras cenas altos valores foram observados. Na maior parte dos meses chuvosos as cenas apresentaram muitas nuvens e sombras que geram ruído na qualidade da imagem e na eficiência da classificação. O ano de 2000 foi selecionado devido a ocorrência de uma série eventos de deslizamentos no mês de dezembro de 1999 no km 42 da Rodovia Anchieta.

A classificação SVM foi realizada no software ENVI versão 4.8 (EXELIS, 2009). Conforme Keuchel *et al.*, (2003) e Li e Liu, (2010), o sucesso na classificação utilizando o algoritmo SVM depende da escolha da função kernel apropriada. Para a realização do presente estudo, selecionou-se a função kernel denominada *Radial Basis Function* (RBF) para a classificação da cobertura do solo e detecção de mudança, com base nas recomendações da literatura (*e.g.*, KEUCHEL *et al.*, 2003; CARRAO *et al.*, 2008; KNORN *et al.*, 2009; HUANG *et.al.*, 2008; KUEMMERLE *et al.*, 2009) e pressupostos teóricos.

Neste estudo, para a identificação das cicatrizes de deslizamento foi utilizado o índice da diferença normalizada da vegetação (NDVI, do inglês *Normalized Difference Vegetation Index*) como forma de realce nas cenas Landsat TM 5. O índice realça as diferenças entre o solo e a vegetação e é dado pela fórmula abaixo (HALL *et al.* 1995):

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Onde,

NDVI é o índice da diferença normalizada da vegetação;

NIR é a banda do infravermelho próximo;

RED é a banda do vermelho.

As amostras de pixels de cada classe foram coletadas com base na interpretação conjunta do NDVI e composição cor verdadeira, compondo, assim, as áreas de treinamento. De acordo com a literatura (*e.g.*, FOODY; MATHUR, 2006; GILES *et al.*, 2006) o procedimento de amostragem para classificação com SVM deve priorizar as amostras de pixels das áreas fronteiriças de cada classe. Uma vez que, o algoritmo, identifica os melhores vetores de suporte para cada classe e a amostragem de áreas fronteiriças implicando em menor esforço amostral.

O algoritmo SVM foi empregado para distinguir as classes: evento de desastre, água, vegetação e área urbana. Em função dos resultados alcançados por Lizarazo (2008), que comparou diretamente a classificação SVM com a classificação orientada à segmentação, obtendo resultados semelhantes entre si, desta forma optou-se aqui por não aplicar o método de segmentação previamente à classificação.

Além disso, para efeitos comparativos, as mesmas áreas de treinamento foram classificadas pelo algoritmo de Máxima Verossimilhança (MV), o qual avalia quantitativamente tanto a variância quanto a covariância do padrão de resposta da categoria espectral (LILLESAND; KIEFER, 2002) assumindo que a distribuição dos pontos amostrais segue uma tendência gaussiana (BAYARSAIKHAN *et al.*, 2009), descrita pela média do vetor e pela matriz de covariância.

Como o algoritmo MV não pode ser aplicado em uma única banda, inviabilizando a aplicação exclusiva ao NDVI, as bandas 3 e 4 do instrumento TM foram selecionadas, e a partir delas os algoritmos SVM e MV foram aplicados. O algoritmo SVM também foi empregado exclusivamente ao NDVI.

Em todos os casos, a acurácia de cada classe foi avaliada, *i.e.*, matriz de confusão, índice Kappa e coeficiente de acurácia geral (%). O índice Kappa é calculado por meio da interpretação de imagens para definir as áreas de confirmação. Pixels foram selecionados

aleatoriamente. A acurácia geral, erros de comissão e omissão foram comparados para cada metodologia proposta.

3.1.3. Resultados e Discussão

Os resultados obtidos pela classificação com SVM e MV utilizando as bandas 3 e 4 e SVM aplicado ao NDVI são apresentados nas Figuras 17, 18 e 19, respectivamente. Por meio de sua análise é possível observar que a combinação SVM/NDVI classificou uma menor quantidade de áreas de deslizamento em relação aos outros dois algoritmos. Com base em informações prévias da área, sobrepôs-se o resultado da classificação, *i.e.*, SVM/NDVI, a uma imagem de alta resolução espacial, de modo a avaliar o evento de deslizamento do rio Pilões, próximo a Rodovia Anchieta. A sobreposição da classificação gerada por meio do algoritmo SVM/NDVI e a imagem GeoEye (2000) é apresentada na Figura 20 e, em perspectiva na Figura 21. Foi observada boa qualidade de ajuste entre a imagem de alta resolução do deslizamento e a classificação. Todavia, os resultados obtidos através dos outros dois algoritmos, *i.e.*, MV e SVM utilizando as bandas 3 e 4, não apresentaram bom ajuste, pois, apesar dos deslizamentos terem sido classificados corretamente, outras categorias de cobertura do solo foram equivocadamente classificadas como deslizamentos.

Figura 17. - Resultado do classificador MV baseado na imagem LANDSAT TM 5 de 2000.

Fonte: Traduzido de Manfré *et al.* (2014).

Figura 18. - Resultado do classificador SVM baseado na imagem LANDSAT TM 5 de 2000 utilizando as bandas 3 e 4.

Fonte: Traduzido de Manfré *et al.* (2014).

Figura 19. - Resultado do classificador SVM baseado na imagem LANDSAT TM 5 de 2000 utilizando NDVI.

Fonte: Traduzido de Manfré *et al.* (2014).

Figura 20. - Sobreposição do resultado da classificação SVM/NDVI com imagem de alta resolução.

Fonte: Traduzido de Manfré *et al.* (2014).

Figura 21. - Visão em perspectiva da classificação SVM/NDVI sobreposto ao modelo de elevação digital do terreno.

Fonte: Traduzido de Manfré *et al.* (2014).

As performances do algoritmo SVM utilizando as bandas 3 e 4, SVM utilizando NDVI e MV utilizando as bandas 3 e 4 foram analisadas por meio do coeficiente de acurácia geral e índice kappa, indicando maior vantagem na utilização do algoritmo SVM/NDVI. Os resultados estão resumidos na tabela 2.

Tabela 2. - Valores do índice e acurácia geral para cada algoritmo utilizado.

Método	Acurácia Geral	Índice Kappa
MLC(bandas 3, 4)	84.25	0.78
SVM(bandas 3, 4)	82.88	0.76
SVM (NDVI)	92.47	0.90

Fonte: Traduzido de Manfré *et al.* (2014).

Utilizando as mesmas bandas o algoritmo MV gera melhores resultados quando comparado ao SVM, porém quando este é aplicado ao NDVI, o último algoritmo apresenta os melhores resultados dentre as técnicas de classificação supracitada. Isto é consequência da aplicação do índice NDVI, que neutraliza os efeitos de sombra da topografia, aumentando a eficiência da separação das classes (BARLOW; MARTIN; FRANKLIN, 2003). Desta forma, o algoritmo SVM pode ser considerado o melhor método para identificar áreas de deslizamento, uma vez que ele permite a classificação com base em uma única banda, que neste caso permite melhor diferenciação entre a classe de interesse e as demais.

As matrizes de confusão são apresentadas nas tabelas 3, 5 e 7. Ao comparar as três tabelas, observava-se resultados muito similares para a classe de deslizamentos. Isto pode ser consequência da amostragem dos pontos de verificação. Resultados similares também podem ser observados em relação aos erros de comissão e omissão, apresentados nas tabelas 4, 6 e 8.

Tabela 3 - Matriz de confusão para a classificação MV para a cena de 2000.

Classe	Verdade (Percentual %)				
	Urbana	Água	Vegetação	Deslizamento	TOTAL
Urbana	92,50%	9,30%	16,33%	7,14%	34,25%
Água	0,00%	81,40%	0,00%	14,29%	25,34%
Vegetação	7,50%	0,00%	81,63%	0,00%	29,45%
Deslizamento	0,00%	9,30%	2,04%	78,57%	10,96%
TOTAL	100,00%	100,00%	100,00%	100,00%	100,00%

Fonte: Traduzido de Manfré *et al.* (2014).

Tabela 4 - Erros de comissão e omissão para classificação MV para a cena de 2000.

Classes	%		Número de Pixels	
	Comissão	Omissão	Comissão	Omissão
Urbana	26,00%	7,50%	13/50	3/40
Água	5,41%	18,60%	2/37	8/43
Vegetação	6,98%	18,37%	3/43	9/49
Deslizamento	31,25%	21,43%	5/16	3/14

Fonte: Traduzido de Manfré *et al.* (2014).

Tabela 5 - Matriz de Confusão da Classificação SVM (Bandas 3 e 4)

Classes	Verdade (Percentual)				
	Urbana	Água	Vegetação	Deslizamento	TOTAL
Urbana	70,00%	2,33%	10,20%	0,00%	23,29%
Água	7,50%	93,02%	0,00%	21,43%	31,51%
Vegetação	7,50%	0,00%	85,71%	0,00%	30,82%
Deslizamento	15,00%	4,65%	4,08%	78,57%	14,38%
TOTAL	100,00%	100,00%	100,00%	100,00%	100,00%

Fonte: Traduzido de Manfré *et al.* (2014).

Tabela 6 - Erros de Comissão e Omissão da Classificação SVM (bandas 3 e 4).

Classes	%		Números de Pixels	
	Comissão	Omissão	Comissão	Omissão
Urbana	17,65%	30,00%	6/34	12/40
Água	13,04%	6,98%	6/46	3/43
Vegetação	6,67%	14,29%	3/45	7/49
Deslizamento	47,62%	21,43%	10/21	3/14

Fonte: Traduzido de Manfré *et al.* (2014).

Tabela 7 - Matriz de Confusão da Classificação SVM (NDVI)

Classes	Verdade (Percentual)				
	Urbana	Água	Vegetação	Deslizamento	TOTAL
Urbana	95,00%	4,65%	2,04%	29,63%	28,08%
Água	0,00%	88,37%	0,00%	21,43%	28,08%
Vegetação	0,00%	0,00%	97,96%	0,00%	32,88%
Deslizamento	5,00%	6,98%	0,00%	78,57%	10,96%
TOTAL	100,00%	100,00%	100,00%	100,00%	100,00%

Fonte: Traduzido de Manfré *et al.* (2014).

Tabela 8 - Erros de Comissão e Omissão da Classificação SVM (NDVI).

Classes	%		Número de Pixels	
	Comissão	Omissão	Comissão	Omissão
Urbana	7,31%	5,00%	3/41	2/40
Água	7,34%	11,63%	3/41	5/43
Vegetação	0,00%	2,04%	0/48	1/49
Deslizamento	31,25%	21,43%	5/16	3/14

Fonte: Traduzido de Manfré *et al.* (2014).

Apesar da similaridade nos resultados avaliados, apenas o algoritmo SVM/NDVI conseguiu distinguir o evento de deslizamento no km 42 da Rodovia Anchieta (Figuras 19). As diferenças obtidas na classificação provavelmente podem ter resultado do efeito de diminuição do ruído pelo NDVI combinado ao classificador SVM. Considerando que a área de estudo possui encostas íngremes e alta taxa de umidade, o algoritmo de classificação deve

ser aplicado em bandas ou fazer uso de ferramentas, *e.g.*, NDVI, que minimizem os efeitos da neblina e nuvens que geram ruído no desempenho (HSIEH *et al.*, 2011). Além disso, o uso do NDVI suaviza o efeito das sombras da topografia (BARLOW; MARTIN; FRANKLIN, 2003), que no caso deste deslizamento implicam em grande alteração na resposta espectral do alvo.

Além disso, a combinação da classificação produzida por SVM/NDVI ao modelo de elevação digital do terreno (Figura 20) permite a análise de áreas mais suscetíveis a eventos de deslizamentos (KANUNGO; SARKAR, 2011). Ressalta-se que a maioria dos pixels classificados como deslizamento ocorreu em áreas de encosta, desta forma, estes podem ser utilizados para guiar o mapeamento de ocorrências de deslizamentos, permitindo a tomada mais rápida de ações mitigatórias, como citado por Bai *et al.* (2011).

Portanto, o uso do NDVI consiste em boa alternativa para a classificação em cenas com alta incidência de ruído. Como o algoritmo MV requer no mínimo duas bandas para ser executado, pode-se dizer que o algoritmo SVM é mais vantajoso neste aspecto, pois, pode ser executado com base em apenas uma única banda e em índices que realçam a classe de interesse, ou melhoram a informação omitida por sombras da topografia. Soma-se a isso, o fato do mecanismo de classificação do algoritmo SVM consistir em buscar os limites de cada classe, por meio de uma função kernel que eleva as dimensões dos dados em busca da melhor hiperplano de separação para as classes (MOUNTRAKIS; IM; OGOLE, 2011), representando, assim um bom algoritmo para separar classes de configuração semelhante, enquanto o algoritmo MV busca por similaridade entre os membros das classes (LILLESAND; KIEFER, 2002), o que ocasiona confusão no caso do presente estudo. Alguns autores (MOUNTRAKIS; IM; OGOLE, *op cit*; MONDAL *et al.*, 2012) citam que o MV pode ocasionar maior confusão entre classes que o SVM.

Neste sentido, no que diz respeito à aplicação de classificadores para mapear áreas susceptíveis, indica-se, com base nos resultados obtidos, que a combinação de técnicas SVM/NDVI com dados hipsométricos de maneira a se identificar com maior acurácia áreas de deslizamento.

3.1.4. Conclusão

Ao comparar os dois algoritmos nota-se que o SVM permite detectar mudanças nas classes, criando polígonos homogêneos, enquanto o MV identifica pixels similares, criando um efeito “*salt and pepper*” na classificação, *i.e.*, confundindo as classes alvo.

Todavia, o algoritmo SVM por si só não foi capaz de identificar as áreas de deslizamentos devido à presença de neblina, nuvens e principalmente sombras da topografia na área de estudo. Para minimizar o ruído destes efeitos utilizou-se o algoritmo SVM aplicado ao NDVI. A combinação de técnicas permitiu a identificação e separação de classes, evidenciando áreas de deslizamentos com maior acurácia e demonstrando grande potencial para aplicação no mapeamento de áreas de encosta com risco de deslizamentos.

3.2. Avaliação comparativa dos indicadores de acurácia na identificação de deslizamentos

3.2.1. Introdução

Segundo o pressuposto teórico deste algoritmo, a qualidade dos resultados aumenta com a utilização de mais bandas (VAPNIK, 1995). Porém, algumas áreas apresentam certos aspectos que podem prejudicar a classificação da cobertura do solo, como neblina e nuvens. Para minimizar estes efeitos, existem alguns tipos de realce que permitem facilitar a classificação pelos algoritmos.

Este estudo objetivou comparar a acurácia do algoritmo SVM aplicado a diferentes composições de banda para a identificação de deslizamentos próximos a uma importante rodovia da costa do estado de São Paulo.

3.2.2. Metodologia

O severo evento de deslizamento que acometeu a bacia hidrográfica do rio Pilões ocorreu em 11 de dezembro de 1999. Em função dos altos níveis de pluviosidade, típicos do clima tropical, as primeiras cenas da área, sem a presença de nuvens, somente foram obtidas para o mês de junho de 2000. Desta maneira, o algoritmo SVM foi aplicado em imagens LANDSAT TM 5 do ano 2000. Para minimizar os efeitos das sombras e neblinas, o índice da diferença normalizada da vegetação (NDVI) foi empregado, conforme discutido no artigo anterior 3.2. As áreas de treinamento foram definidas e utilizadas para todas as composições.

Neste sentido, utilizou-se o algoritmo SVM aplicado ao NDVI e para as seguintes composições de bandas: 1 e 2; 3 e 4; 1, 2 e 3; e 1, 2, 3 e 4. As classificações foram avaliadas conforme a acurácia geral, índice kappa, matriz de confusão, erros de omissão e comissão e acurácia do usuário e produtor.

3.2.3. Resultados e Discussão

A acurácia geral e o índice kappa obtidos para cada classificação foram: 82.54% e 0.76; 55.56% e 0.395; 77.78% e 0.7; 53.97% e 0.37; 79.89% e 0.73 (NDVI, bandas 1 e 2, bandas 3 e 4, bandas 1,2 e 3 e bandas 1, 2, 3 e 4, respectivamente). Os resultados para a classificação aplicada ao NDVI foram melhores, todavia, estes números não traduzem a

grande diferença entre as classificações. Esta diferença fica evidente ao se comparar a área total classificada como deslizamento. A Tabela 9 apresenta as áreas e porcentagem de cada classe de cobertura para cada classificação.

Tabela 9 - Área das classes para cada uma das classificações.

Classes	NDVI		1 e 2		3 e 4		1, 2 e 3		1, 2, 3 e 4	
	%	km ²	%	km ²	%	km ²	%	km ²	%	km ²
Deslizamento	0.4	0.17	10.4	4.8	13.0	6.00	5.3	2.47	13.3	6.16
Água	1.5	0.68	0.0	0.0	1.6	0.71	0.2	0.08	1.7	0.78
Urbana	21.2	9.80	12.2	5.6	14.5	6.70	15.6	7.18	14.7	6.78
Vegetação	76.9	35.51	77.4	35.7	70.9	32.75	78.9	36.44	70.3	32.44

Fonte: Traduzido de Manfré *et al.* (2012).

A classificação aplicada ao NDVI classificou 0.37% da imagem como deslizamento, a das bandas 1 e 2 classificou 10.45%, a das bandas 3 e 4 classificou 12.99%, a das bandas 1, 2 and 3 classificou 5.34% e, por sua vez, as bandas 1, 2, 3 e 4 classificou 13.34%.

As matrizes de confusão para cada classificação são apresentadas na tabela 10 (NDVI), Tabela 11 (1 e 2), Tabela 12 (3 e 4), Tabela 13 (1, 2 e 3) e Tabela 14 (1, 2, 3 e 4).

Tabela 10 - Matriz de Confusão para a Classificação baseada no NDVI.

Classes	Deslizamento	Água	Urbana	Vegetação	Total
Deslizamento	50	8	0	0	11.6
Água	13.89	74	2	0	22.8
Urbana	36.11	18	98	1.89	38.1
Vegetação	0	0	0	98.11	27.5
Total	100	100	100	100	100

Fonte: Traduzido de Manfré *et al.* (2012).

Tabela 11 - Matriz de Confusão para a Classificação baseada nas bandas 1 e 2.

Classes	Deslizamento	Água	Urbana	Vegetação	Total
Deslizamento	50	2	0	7.55	12.2
Água	0	0	0	0	0
Urbana	30.56	0	76	0	25.9
Vegetação	19.44	98	24	92.45	61.9
Total	100	100	100	100	100

Fonte: Traduzido de Manfré *et al.* (2012).

Tabela 12 - Matriz de confusão para a classificação baseada nas bandas 3 e 4.

Classes	Deslizamento	Água	Urbana	Vegetação	Total
Deslizamento	66.67	18	16	3.77	22.8
Água	11.11	72	2	0	21.7
Urbana	16.67	0	76	3.77	24.3
Vegetação	5.56	10	6	92.45	31.2
Total	100	100	100	100	100

Fonte: Traduzido de Manfré *et al.* (2012).

Tabela 13 - Matriz de confusão para a Classificação baseada nas bandas 1, 2 e 3.

Classes	Deslizamento	Água	Urbana	Vegetação	Total
Deslizamento	19.44	2	0	3.77	5.29
Água	0	0	0	0	0
Urbana	33.33	0	88	0	29.6
Vegetação	47.22	98	12	96.23	65.1
Total	100	100	100	100	100

Fonte: Traduzido de Manfré *et al.* (2012).

Tabela 14 - Matriz de confusão para a classificação baseada nas bandas 1, 2, 3 e 4.

Classes	Deslizamento	Água	Urbana	Vegetação	Total
Deslizamento	63.89	14	18	3.77	21.7
Água	11.11	78	0	0	22.8
Urbana	19.44	0	78	1.89	24.9
Vegetação	5.56	8	4	94.34	30.7
Total	100	100	100	100	100

Fonte: Traduzido de Manfré *et al.* (2012).

Os dados apresentados nas tabelas 10 até a 14 indicam que apesar da alta acurácia da classificação aplicada à NDVI, a classe de deslizamento teve menor acurácia que a gerada com base nas bandas 3 e 4, e bandas 1, 2, 3 e 4.

Este resultado pode indicar que a classificação aplicada ao NDVI gerou resultados piores para a detecção de cicatrizes de deslizamentos. Entretanto, os erros de omissão e comissão, resumidos na Tabela 15 complementam a informação e contradiz esta hipótese.

Tabela 15 - Porcentagem dos erros de comissão e omissão para cada uma das classificações.

Classes	NDVI		1 e 2		3 e 4		1, 2 e 3		1, 2, 3 e 4	
	Com.	Om.	Com.	Om.	Com.	Om.	Com.	Om.	Com.	Om.
Deslizamento	18.2	50	21.7	50	44.2	33.3	30	80.6	43.9	36.1
Água	14	26	0	100	12.2	28	0	100	9.3	22
Urbana	31.9	2	22.5	24	17.4	24	21.4	12	17	22
Vegetação	0	1.89	58.1	7.55	17	7.55	58.2	3.77	13.8	5.66

Fonte: Traduzido de Manfré *et al.* (2012).

A análise dos erros de comissão para a classe de deslizamento indicam altos percentuais para três dos processos de classificação. O menor erro de comissão desta classe foi produzido pela classificação aplicada ao NDVI. Além disso, a análise da tabela 15 induz que as classificações baseadas nas bandas 1 e 2, 3 e 4, 1, 2 e 3 e 1, 2, 3 e 4 superestimaram a classe de deslizamentos. A alta média de erros associados à classificação provavelmente está relacionada à rugosidade do terreno e presença de sombras (BARLOW; MARTIN; FRANKLIN, 2003). Neste sentido, como o NDVI minimiza estes efeitos, sua aplicação facilita o processo de classificação.

Os resultados da acurácia do usuário e produtor (tabela 16) incrementa a avaliação do processo de classificação.

Tabela 16 - Porcentagem das acurácias do produtor e do usuário para cada uma das classificações.

Classes	NDVI		1 e 2		3 e 4		1, 2 e 3		1, 2, 3 e 4	
	Prod.	Usu.	Prod.	Usu.	Prod.	Usu.	Prod.	Usu.	Prod.	Usu.
Deslizamento	50	81.8	50	78.3	66.7	55.8	19.4	70	63.9	56.1
Água	74	86.1	0	0	72	87.8	0	0	78	90.7
Urbana	98	68.1	76	77.6	76	82.6	88	78.6	78	83
Vegetação	98.1	100	92.5	41.9	92.5	83.1	96.2	41.5	94.3	86.2

Fonte: Traduzido de Manfré *et al.* (2012).

A análise da tabela 16 confirma que a classificação aplicada ao NDVI fornece os melhores resultados para mapear os deslizamentos, uma vez que a acurácia do usuário foi a maior. A acurácia do usuário representa a probabilidade de uma amostra do mapa da cobertura do solo realmente equivaler aos dados de referência (STORY; CONGALTON, 1986). Contudo, é importante discutir que a classificação aplicada ao NDVI gerou baixos erros de acurácia do produtor, os quais descrevem a probabilidade de uma amostra de referência ser corretamente mapeada e mede os erros de omissão (STORY; CONGALTON, 1986). Portanto, isto confirma que algumas áreas de deslizamentos foram omitidas.

Estas omissões, de acordo com a tabela 10, foram basicamente convertidas para as classes de área urbana/rodovias e água. A explicação para este enquadramento depende do comportamento espectral de áreas não vegetadas em relação ao NDVI, o qual mede a refletância da superfície e fornece a quantidade estimada de crescimento vegetal e biomassa (HALL *et al.*, 1995).

3.2.4. Conclusão

Desta maneira, este artigo demonstra que dependendo das condições naturais da área, existem fatores que são mais importantes que o número de bandas para o processo de classificação com o algoritmo SVM. Conclui-se que o uso de índices, como o NDVI, pode facilitar o processo de classificação e gerar resultados melhores do que o uso de grandes quantidades de bandas. Além disso, destaca-se que as características do alvo devem ser consideradas no processo de classificação, pois se houver comportamentos espectrais similares, a separação em classes pode se tornar mais complexa.

Pode-se concluir também que para avaliar um processo de classificação e discriminar o melhor resultado, uma análise completa de sua estatística deve ser realizada. Vários trabalhos avaliam a acurácia de classificações empregando apenas o índice Kappa. Porém, dependendo do objetivo da classificação, análises complementares devem ser desenvolvidas. Neste sentido, a avaliação da acurácia do usuário e do produtor e dos erros de omissão e comissão corresponde uma importante ferramenta que pode auxiliar na identificação de fragilidade dos resultados.

4. Sistemas de Múltiplos Classificadores para a identificação de deslizamentos

4.1. Avaliação de Sistemas de Múltiplos Classificadores para a identificação de deslizamentos em imagens LANDSAT Thematic Mapper (TM)

4.1.1. Introdução

Diversas regiões no mundo são acometidas por elevados índices pluviométricos em um curto período de tempo, favorecendo a ocorrência de desastres naturais (BORGHA *et al.* 2014). Em regiões montanhosas, estes eventos favorecem a ocorrência de deslizamentos (PETLEY, 2012; WANG; ZHANG; HU, 2012), colocando em risco a população que vive ou transita por essas regiões. Devido à obras e alterações na estrutura do solo, o entorno de rodovias propicia a ocorrência destes eventos (DI MARTINO *et al.*, 2014, KUMAR; JANGPANGI; GANGOPADHYAY, 2014). Guthrie (2002) analisou a frequência e a distribuição de deslizamentos em três bacias hidrográficas e identificou que as estradas são o maior agente causador dos deslizamentos. O monitoramento e a identificação de locais de deslizamentos é complicado, uma vez que, na maioria dos casos, as equipes de monitoramento de desastres naturais são pequenas e as áreas a serem monitoradas, vastas (GUZZETTI *et al.*, 2012). Apesar dessas dificuldades, o mapeamento e a mitigação dos danos causados pelos deslizamentos são fundamentais para a manutenção da segurança da população (MANCONI *et al.*, 2014).

O uso de dados de sensoriamento remoto representa uma ferramenta de grande potencial para monitorar e gerenciar os deslizamentos. Corresponde a uma alternativa para o mapeamento destas cicatrizes, uma vez que cobrem extensas regiões e permitem análises rápidas (TOFANI *et al.*, 2014). Entretanto, os deslizamentos geralmente ocorrem em regiões montanhosas onde o efeito da topografia, combinado às sombras do relevo e da vegetação, pode omitir cicatrizes de deslizamentos (NICHOL; WONG, 2005). Desta forma, o uso de técnicas de sensoriamento remoto deve ser bastante criterioso, de maneira a tentar contornar esses problemas.

Diversos artifícios podem ser utilizados para a obtenção de informações de imagens de satélite. Técnicas de realce podem facilitar a identificação de objetos (LIU e MASON, 2009), enquanto algoritmos de classificação utilizam informações estatísticas das imagens para separar classes de interesse (DENGSHENG *et al.*, 2011). No entanto, os critérios a serem utilizados devem ser bem definidos e adequados à classe/objeto de interesse a ser identificado,

de maneira a minimizar a possibilidade de erro no resultado (RICHARDS, 1999). Além disso, todos os algoritmos demandam ajustes de parâmetros de acordo com o objetivo principal da classificação, de maneira a obter o melhor desempenho (SCHOTT, 2007). Porém, mesmo com estes cuidados a divergência entre o resultado de cada algoritmo pode ser muito grande.

Por este motivo, a busca por alternativas que combinem as classificações de maneira a se obter um resultado final mais próximo da realidade tem sido discutida na literatura (STEELE, 2000; SMITS, 2002; BRIEM *et al.*, 2002; BENEDIKTSSON *et al.*, 2007; DOAN e FOODY, 2007; FOODY; BOYD; SANCHEZ-HERNANDEZ, 2007; WASKE *et al.*, 2010). Conhecido na literatura como Sistemas de Múltiplos Classificadores (SMC) (GIACINTO, 2001) ou Conjunto de Classificações (KUNCHEVA; WHITAKER, 2003), esse método pode ser realizado de diversas maneiras, existindo ao menos três grandes categorias para a composição de classificações: algoritmos baseados na manipulação de amostras de treinamento (BREIMAN, 1996), combinação concatenada (XU; KRZYZAK; SUEN, 1992) e combinação paralela (RAHMAN; FAIRHURST, 1999).

Du *et al.* (2012) fizeram uma revisão da literatura sobre o uso de SMC e apresentaram a eficiência do uso de conjunto de classificações, sempre melhorando a acurácia dos resultados. Os autores salientam que a seleção da estratégia de composição mais adequada ao objetivo da classificação é fundamental para o uso de SMC. Segundo Abe *et al.* (2014) a composição entre algoritmos deve ser feita de forma criteriosa, sendo que a etapa mais importante para a obtenção de bons resultados é a escolha dos algoritmos mais adequados para a solução do problema em questão.

A avaliação prévia dos classificadores a serem utilizados é fundamental para a compreensão de seu desempenho na obtenção do resultado desejado. De acordo com Pontius Junior e Millones (2011) e Iames, Congalton e Lunetta (2013) a análise integrada entre os diversos indicadores de acurácia é importante para se compreender melhor os resultados obtidos com uma classificação.

Este capítulo tem por objetivo identificar a melhor combinação de classificadores para o mapeamento de cicatrizes de deslizamentos para regiões montanhosas em imagens satelitais de média resolução espacial (30 metros). Além disso, este artigo avalia a contribuição da diversidade de classificações no resultado final da acurácia da combinação entre algoritmos.

4.1.2. Metodologia

A figura 22 resume as etapas metodológicas empregadas neste trabalho. Primeiramente uma amostra de 399x399 pixels da cena LANDSAT TM 5 (Órbita-Ponto 219-077) de 25 de Junho de 2000, onde se localiza o deslizamento ocorrido no Km 42 da Rodovia Anchieta, passou por pré-processamento para facilitar a identificação visual das cicatrizes, garantindo maior qualidade às áreas de treinamento. A amostra da cena foi classificada por 10 diferentes algoritmos de classificação. Os resultados das classificações foram avaliados quanto à sua acurácia e em consequência disso foram definidas 9 composições entre os 10 classificadores, visando utilizar um número menor de algoritmos com maior acurácia. As composições entre as classificações foram elaboradas pelo método de votação ou maioria, utilizando para os casos de empate a análise do contexto dos pixels e o método de sorteio. A acurácia de cada uma das composições foi avaliada e uma análise da evolução da acurácia foi realizada.

Figura 22. - Fluxograma das etapas metodológicas empregadas neste trabalho.

Fonte: Elaboração própria.

Áreas de treinamento foram definidas de acordo com o conhecimento prévio do usuário sobre a área, principalmente considerando a localização do deslizamento. Técnicas de realce foram utilizadas para ressaltar a área do deslizamento e facilitar a coleta de amostras. Foi aplicada a transformação de cores RGB (*Red, Green e Blue*, ou Vermelho, Verde e Azul) para HSV (*Hue, Saturation e Value*, ou Matiz, Saturação e Valor), tendo sido utilizadas as bandas 3 (Vermelho), 4 (Infravermelho próximo) e 5 (Infravermelho médio). A escolha da composição aumenta as diferenças entre solo e vegetação, de acordo com Toledo (2008). Já a transformação para o espaço de cores HSV foi escolhida para amenizar o efeito das sombras da topografia (MA; QIN; SHEN, 2008). A amostra da cena no espaço de cores HSV é mostrada na figura 23, com destaque para a área do deslizamento.

Figura 23. - Amostra da cena LANDSAT 219-077 de 25 de junho de 2000 no espaço de cores HSV.

Fonte: Elaboração própria.

Utilizou-se as 6 bandas do satélite LANDSAT 5 de maneira a não excluir nenhuma informação disponível.

No presente trabalho utilizou-se 10 algoritmos de classificação supervisionada mais empregados pela literatura (SMITS; DELLEPIANE; SCHOWENGERDT, 1999; KANUNGO *et al.*, 2002; LO; CHOI, 2004; NEMMOUR; CHIBANI, 2006; OTUKEI; BLASCHKE, 2010; PETROPOULOS *et al.*, 2010) para classificações de cenas LANDSAT. Estes algoritmos são todos já implementados no programa ENVI 5.0, utilizado para a execução das classificações deste trabalho, o que os torna de fácil aplicação à imagens de satélite. Além disso, buscou-se utilizar o maior número de algoritmos que trouxessem diversidade ao resultado das classificações, uma vez que de acordo com o pressuposto teórico da composição de Sistemas de Classificadores, quanto maior diversidade melhor será o resultado final (RANAWANA; PALADE, 2006; DU *et al.*, 2012).

Todos os algoritmos requerem o ajuste de parâmetros para atingirem o máximo de seu desempenho (TESTUD *et al.*, 2001), desta forma buscaram-se os melhores ajustes considerando o objetivo de separar a classe de cicatrizes de deslizamentos. Estes parâmetros foram definidos de acordo com as características de cada algoritmo, bem como com a

característica da classe a ser identificada. A classe deslizamento possui característica bastante específica, porém, se confunde com outras classes em algumas das bandas do LANDSAT 5. Por isso, os parâmetros para essa classe foram bastante restritivos, ou seja, permitindo o mínimo de variação dentro da classe.

Para os algoritmos de classificação supervisionada os parâmetros foram ajustados de acordo com a sua resposta para a classificação da área de deslizamento no Rio Pilões. O algoritmo árvore de decisão foi executado com base nas regras estabelecidas pelo minerador de dados J48 do programa WEKA 3.6. O minerador de dados J48, é o mais popular e poderoso dos mineradores de dados utilizados no sensoriamento remoto (TSO; YAU, 2007; GHOSE; PRADHAN; GHOSE, 2010; WU *et al.*, 2013). Os algoritmos utilizados e suas respectivas características são descritos na tabela 17.

Tabela 17 – Algoritmos de classificação utilizados e suas respectivas descrições.

Classificadores	Descrição
Binary Encoding	Codifica o dado e classifica os pixels em 0 e 1 de acordo com a sua posição com relação à média espectral. Utiliza Função OU para comparar cada um dos pixels com as classes em questão e produz uma classificação.
Distância de Mahalanobis	Agrupar as classes de acordo com a similaridade de distribuição no espaço de atributos. Utiliza limiar de distância definido pelo usuário para delimitação máxima da classe.
Mínima Distância	Utiliza os vetores intermediários das classes e calcula a distância euclidiana dos pixels com relação a eles. O pixel é classificado a sua classe mais próxima, a não ser que haja um limiar definido pelo usuário.
Spectral Information Divergence	Utiliza medidas de divergência para incluir um pixel a uma classe.
Spectral Angle Mapper	Utiliza um ângulo n-dimensional para incluir pixels em uma classe.
Paralelepípedo	Limiares de decisão formam um paralelepípedo em n-dimensões. Definido pelo desvio-padrão da média de cada classe selecionada.
Máxima Verossimilhança	Assume que as estatísticas de uma classe obedecem a uma distribuição normal e calcula a probabilidade de um pixel pertencer a uma classe.
Redes Neurais	Utiliza propagação reversa para aprendizado supervisionado. O erro é propagado de forma reversa ajustando os pesos.
Support Vector Machine	Define um hiperplano ótimo para separação das classes de acordo com os membros mais externos desta classe
Árvore de Decisão – J48	Várias iterações com cálculo da entropia. Seleciona a opção de menor entropia e calcula a separação das classes de acordo com os atributos disponíveis.

Fonte: Elaboração Própria.

Todos os resultados das classificações foram avaliados quanto ao seu desempenho com base em regiões de verdade previamente definidas. Foram utilizados os seguintes indicadores de acurácia: índice kappa, acurácia geral, percentual de acerto para a classe deslizamento e erros de comissão e omissão para a classe deslizamento (BLASCHKE, 2010; CONGALTON, 1999).

Com base na avaliação da acurácia dos resultados das classificações foi possível definir os classificadores com melhor desempenho e definir as composições entre os algoritmos de forma progressiva, eliminando os piores resultados da composição. Foram definidas 9 composições entre os classificadores, uma composta pelos 10 algoritmos utilizados e as demais com a exclusão progressiva dos algoritmos com piores desempenhos, de acordo com os indicadores de acurácia. A tabela 18 ilustra os algoritmos utilizados em cada uma das composições.

Tabela 18 – Classificadores utilizados em cada uma das composições realizadas.

Número de Classificadores	Classificadores Utilizados
10	BE, AD, MHD, MD, MV, RN, PAR, SAM, SID e SVM
9	AD, MHD, MD, MV, RN, PAR, SAM, SID e SVM
8	MHD, MD, MV, RN, PAR, SAM, SID e SVM
7	MHD, MV, RN, PAR, SAM, SID e SVM
6	MHD, MV, RN, PAR, SAM, e SVM
5	MHD, MV, RN, SAM, e SVM
4	MD, MV, RN, e SVM
3	MV, SVM e RN
2	SVM e RN

Fonte: Elaboração Própria.

A escolha das composições buscou a utilização dos melhores níveis de acurácia entre os classificadores utilizados, uma vez que, de acordo com Abe *et al.* (2014) a escolha dos algoritmos é fundamental para a melhoria da acurácia em um sistema de múltiplos classificadores. Assim, a composição deixa de utilizar as maiores fontes de erro e possui maior potencial para melhoria do resultado final.

Para a realização destas composições, todas as classificações foram exportadas para o formato de tabela e as matrizes foram convertidas para uma única coluna de 159201 linhas, uma linha para cada pixel. Foi realizada uma análise de votação, que contabiliza a classificação atribuída por cada algoritmo i e confere ao pixel j a classe k mais recorrente (XU; KRZYZAK; SUEN, 1992, KUNCHEVA, 2007, FOODY; BOYD; SANCHEZ-HERNANDEZ, 2007). Em caso de empate entre duas ou mais classes k foram adotadas duas estratégias de desempate: sorteio (HO; HULL; SRIHARI, 1992) e análise da vizinhança (BEN ADBALLAH *et al.*, 2012). Desta forma, obteve-se o valor F_{ij} como resultado final para cada uma das estratégias de desempate.

O método de sorteio utilizou-se do recurso de sorteio do Microsoft Excel 2010 para realizar o desempate entre as classes k de cada pixel i . Já o método de análise da vizinhança foi realizado com a reconstrução da matriz da imagem e análise de seu contexto foi executada no ambiente do programa eCognition Developer 8 (TRIMBLE, 2011). Assim, foi definida a regra de desempate de acordo com a vizinhança de i . A classe dominante na vizinhança de i empatado entre duas ou mais classes k foi atribuído no resultado de Fij .

As composições entre os classificadores tiveram sua acurácia avaliada, da mesma maneira que os algoritmos de classificação. Por fim, comparou-se o resultado dos indicadores de acurácia para os classificadores isolados e para as 18 composições executadas (9 com desempate por sorteio e 9 com desempate por análise do contexto).

4.1.3. Resultados

O resultado obtido das classificações por cada um dos 10 algoritmos é apresentado na Figura 24. Nota-se uma grande variação nos resultados das classificações, sobretudo para a classe de deslizamentos. As outras classes se misturaram entre si para os resultados de alguns classificadores, o que se deve à prioridade para a classe de deslizamento no ajuste dos parâmetros dos algoritmos.

A avaliação da acurácia dos classificadores utilizados é apresentada de maneira resumida na Tabela 19. Os erros de comissão e omissão e o percentual de acerto são apresentados apenas para a classe deslizamento. Nota-se que os classificadores SVM, RN e MV tiveram os melhores desempenhos.

Tabela 19 – Avaliação da acurácia para os 10 algoritmos de classificação utilizados.

Classificadores	Kappa	Acurácia Geral %	Classe Deslizamento		
			Erros de Comissão %	Erros de Omissão %	Acerto %
Binary Encoding	0.3424	48.5433	93.81	48.77	61.23
Árvore de Decisão (J48)	0.8081	89.4852	82.22	77.78	22.22
Mahalanobis Distance	0.7527	85.6517	94.14	54.94	43.06
Mínima Distância	0.5561	71.7515	80.85	62.5	37.5
Máxima Verossimilhança	0.9359	96.6484	59.3	48.61	51.39
Redes Neurais	0.9441	97.0865	59.09	25.00	75.00
Paralelepípedo	0.638	79.759	82.81	69.44	30.56
Spectral Angle Mapper	0.3002	37.678	60.00	55.56	44.44
Spectral Information Divergence	0.4673	62.322	70.11	63.89	36.11
Support Vector Machine	0.9325	96.4513	66.49	13.89	86.11

Fonte: Elaboração Própria.

Figura 24. - Mapas das classificações de cada algoritmo utilizado. A – Binary Encoding, B – Árvore de Decisão, C – Mahalanobis Distance, D – Mínima Distância, E – Máxima Verossimilhança, F – Redes Neurais, G – Paralelepípedo, H – SAM, I – SID, J – SVM.

Fonte: Elaboração própria.

Para a avaliação do índice kappa e acurácia geral, destaca-se os resultados obtidos pelos algoritmos MV, RN e SVM. Já para a avaliação dos erros de comissão e omissão nota-se que os erros de comissão foram sempre muito altos acima de 0,6 e que os menores erros de omissão foram apresentados pelos algoritmos MV e RN. Essa característica deve-se à grande semelhança espectral da classe deslizamento com as classes vegetação e água (principalmente devido às sombras da topografia). Os melhores percentuais de acerto combinados com os

menores erros de comissão na classe deslizamento foram obtidos pelos algoritmos RN, SVM e MV. Outros algoritmos como o Binary Encoding apresentaram bom percentual de acerto para a classe deslizamento, no entanto, alto erro de comissão. Outros algoritmos como o *Spectral Angle Mapper* apresentaram baixos índices kappa, porém, o percentual de acerto e os erros de comissão para a classe deslizamento foram melhores.

A avaliação dos resultados das diferentes combinações entre os classificadores é apresentada na Tabela 20. As figuras 25 a 26 mostram os gráficos com a evolução dos indicadores de acurácia para as composições entre os classificadores e a comparação com o resultado do melhor classificador (índice kappa, acurácia geral, erro de comissão, erro de omissão e percentual de acerto, respectivamente).

Tabela 20 – Avaliação da acurácia dos resultados das composições entre os classificadores.

Desempate	nº de classificadores	Kappa	Acurácia Geral %	Classe Deslizamento		
				Erros de Comissão %	Erros de Omissão %	Acerto %
Sorteio	10	0.8692	93.404	61.18	35.29	64.71
	9	0.93	96.6313	59.21	39.22	60.78
	8	0.9523	97.7385	59.77	31.37	68.63
	7	0.9441	97.338	52.63	29.41	70.59
	6	0.963	98.2568	52.56	27.45	72.55
	5	0.9689	98.5395	50.6	19.61	80.39
	4	0.9704	98.6101	49.35	23.53	76.47
	3	0.9694	98.563	50.6	11.11	88.89
	2	0.9584	98.0448	60.4	21.57	78.43
Análise do Contexto	10	0.9147	95.8539	57.14	29.41	70.59
	9	0.9558	97.8998	59.26	26.67	73.33
	8	0.9659	98.3966	50	24	76
	7	0.9622	98.2097	53.49	21.47	78.43
	6	0.9622	98.2097	53.49	21.57	78.43
	5	0.9719	98.6805	48.15	17.65	82.35
	4	0.9709	98.6337	48.75	19.61	80.39
	3	0.9704	98.6101	50.59	9.52	90.48
	2	0.9664	98.4217	53.68	13.73	86.27

Fonte: Elaboração Própria.

Nota-se que os melhores resultados para a classe deslizamento foram obtidos para a composição de 3 classificadores (SVM, RN e MV). No entanto, para a classificação geral, os melhores resultados foram obtidos para a composição entre cinco classificadores. Além disso,

para todas as composições observa-se que o método de desempate por análise do contexto apresentou melhores resultados que o método de sorteio.

Figura 25 – Evolução do índice Kappa para os resultados das composições entre os classificadores.

Fonte: Elaboração própria.

Para o gráfico de evolução do índice Kappa com relação às composições entre os classificadores, da figura 25 observa-se que nas três primeiras eliminações de algoritmos há uma grande melhora no desempenho da composição, que atinge um patamar após a composição entre cinco algoritmos e uma pequena queda com a composição entre dois algoritmos. Além disso, os resultados das composições apenas superam o índice kappa mais elevado entre os classificadores isolados (neste caso RN) após a composição com nove classificadores. O mesmo processo é observado na figura 26, para a Acurácia Geral.

Pela análise dos erros de comissão para a classe deslizamento (Figura 27) observa-se que o melhor resultado é obtido pela abordagem de análise do contexto composta por 5 algoritmos. Nota-se um padrão de decréscimo nos erros de comissão até a utilização dos 5 melhores algoritmos, para as próximas composições os valores começam a subir (4, 3 e 2 algoritmos). Na comparação com o melhor resultado obtido pelos algoritmos isoladamente, o de melhor desempenho foi o Redes Neurais, porém apenas as classificações compostas por 10 e 2 algoritmos na abordagem de sorteio apresentaram resultados inferiores a ele.

Figura 26 – Evolução da acurácia geral para as combinações entre os classificadores.

Fonte: Elaboração própria.

Figura 27 – Evolução dos erros de comissão para as combinações entre os classificadores.

Fonte: Elaboração própria.

Na análise dos erros de omissão para a classe deslizamento (Figura 28), o melhor resultado entre os algoritmos foi apresentado pelo SVM, que foi superado apenas pelas composições de três algoritmos. Neste indicador de acurácia, no entanto, observa-se que a composição de 10 algoritmos não apresentou os piores resultados, sendo que na abordagem de desempate por sorteio, o resultado desta composição é superado apenas após a utilização de sete algoritmos. Este fato pode estar ligado à utilização de um algoritmo que apresentou elevados valores de erros de comissão e baixos valores de erros de omissão, *Binary Encoding*. Isto apenas é compensado quando se elimina alguns classificadores, que apesar de

apresentarem erros de comissão menores, apresentam erros de omissão mais elevados, associando outras classes às áreas de deslizamento.

Figura 28. Evolução dos erros de omissão para as combinações entre os classificadores.

Fonte: Elaboração própria.

Na análise do percentual de acerto (Figura 29) para a classe de deslizamento nota-se uma clara tendência de melhora da acurácia à medida que se elimina os algoritmos de pior desempenho. Observa-se que o melhor resultado é apresentado pela composição de três algoritmos com abordagem de análise de contexto para o desempate. Além disso, as combinações com três algoritmos (SVM, RN e MV) são as únicas que apresentam resultado superior ao obtido pelo algoritmo SVM, isoladamente.

A tabela 21 apresenta a matriz de confusão elaborada entre os 10 classificadores, considerando o resultado final da votação como “verdade”. Observa-se grande confusão entre as classes “deslizamento”, “água” e “vegetação”.

Figura 29 – Evolução do percentual de acerto para as combinações entre os classificadores.

Fonte: Elaboração própria.

Tabela 21 – Matriz de confusão com as probabilidades de classificar e confundir as classes, utilizando a combinação de 10 algoritmos.

Resultado da Combinação dos Classificadores						
Resultado dos classificadores		Não-classificado	Deslizamento	Urbano	Água	Vegetação
	Não-classificado	0.4123	0.1727	0.2705	0.0663	0.2779
	Deslizamento	0.0141	0.4408	0.0033	0.014	0.0082
	Urbano	0.2466	0.029	0.6	0.0037	0.0948
	Água	0.015	0.1811	0.0033	0.9076	0.0094
	Vegetação	0.3121	0.1764	0.1229	0.0083	0.6097

Fonte: Elaboração própria.

Sendo assim, a composição elaborada com três classificadores (SVM, RN e MV) e utilizando a abordagem de desempate por análise do contexto apresentou os melhores indicadores de acurácia entre todas as realizadas. A Figura 30 apresenta o mapa da classificação final, evidenciando as áreas classificadas como deslizamento.

Figura 30 – Classificação final composta de três algoritmos (SVM, RN e MV) e abordagem de desempate por análise do contexto.

Fonte: Elaboração própria.

4.1.4. Discussões

O uso das técnicas de combinação de classificadores foi eficiente para a produção de um resultado de melhor qualidade, considerando-se uma avaliação conjunta da Acurácia Geral, Índice Kappa, Erros de Omissão e Comissão e percentual de acerto para a classe deslizamento. A classificação com alta acurácia em áreas de topografia acidentada é um grande problema do Sensoriamento Remoto óptico (TIAN *et al.*, 2005), sobretudo quando o alvo de maior interesse pode estar localizado nas sombras do relevo. Alternativas como o uso de realces como transformações de cor ou uso de índices de vegetação (LORENZI; MELGANI; MERCIER, 2012) facilitam a identificação visual destas áreas, no entanto, podem não propiciar um resultado satisfatório para toda a cena estudada. Na comparação com Manfré *et al.* (2014) o uso da combinação de classificadores obteve indicadores de acurácia melhores, produzindo menores erros de comissão e omissão, tendo maior potencialidade para identificação de outras cicatrizes na cena estudada.

A avaliação dos resultados das classificações isoladas de cada um dos algoritmos demonstrou que alguns possuem bom desempenho para a solução do problema em questão. Outros algoritmos apresentaram acurácias muito baixas, demonstrando-se ineficientes para a identificação de deslizamentos. Para o resultado geral das classificações, os algoritmos AD, SVM, RN e MV apresentaram índices kappa superiores a 0,8. Outros classificadores apresentaram índice kappa e acurácia geral intermediários ou baixos, porém resultados razoáveis para a classe de deslizamento, como é o caso do SAM e do MHD.

A matriz de confusão entre as 10 classificações (Tabela 19) mostra as confusões entre os classificadores para cada uma das classes. Nota-se que a classe deslizamento se confunde principalmente com as classes “não-classificado”, “água” e “vegetação”. Essa mistura entre os classificadores evidencia que a classe deslizamento possui características que se sobrepõem às demais classes, demandando maior elaboração na estratégia de classificação. De acordo com a literatura (DU *et al.*, 2012; WOŹNIAK; GRAÑA; CORCHADO, 2014) a utilização de maior diversidade entre os classificadores contribui para melhorar o desempenho da combinação, no entanto, os resultados mostraram que alguns algoritmos contribuem de forma negativa, aumentando as fontes de erro para a classificação final.

Ao avaliar os resultados obtidos pelas combinações observa-se que elas se tornam mais eficientes com a eliminação dos algoritmos de pior desempenho. Esses resultados se coadunam com Kittler *et al.* (2006) e com Lysiak, Kurzynski e Woloszynski (2014) que afirma que a principal etapa para o uso de classificações combinadas é a escolha dos algoritmos. O erro de omissão para a classe deslizamento foi o único indicador de acurácia que todas as combinações apresentaram resultado melhor que o classificador isolado de melhor desempenho, que neste caso foi o SVM. Esse resultado está vinculado à alta inclusão de pixels na classe deslizamento por vários algoritmos e resulta em alto erro de comissão. Além disso, o percentual de acerto na classe deslizamento para a combinação com 10 classificadores é inferior ao desempenho isolado do algoritmo SVM.

De maneira geral, nota-se que a utilização de alguns algoritmos de classificação contribui negativamente para a obtenção de melhores resultados, sobretudo para a classe deslizamento. Para a classificação geral da amostra da cena LANDSAT, os melhores resultados estão entre as combinações de cinco, quatro e três algoritmos, apesar de a escolha entre os algoritmos ter sido focada na melhora do desempenho para a classe deslizamento, a acurácia de toda a classificação aumenta com a eliminação de alguns algoritmos.

De acordo com Ranawana e Palade (2006) e Du *et al.* (2012) incorporar diversidade entre os classificadores é de grande importância para o resultado da classificação e combinar

classificações semelhantes não agrega melhora ao resultado. No entanto, para o presente estudo não é o que se observa, considerando-se os indicadores de acurácia, principalmente para a classe deslizamento. O uso de alguns algoritmos adiciona erro à combinação das classificações e proporciona a diminuição da acurácia para a classe em questão (MORENO-SECO 2006). Neste caso é importante avaliar o desempenho individual de cada classificador para a classe de interesse, uma vez que o intuito é aumentar a acurácia para esta classe específica. Os classificadores SVM, RN e MV tiveram desempenhos mais adequados para o objetivo deste artigo, com erros de comissão e omissão menores e percentuais elevados de classificação para a classe de deslizamento. O desenvolvimento da combinação de classificadores a partir dos resultados destes três algoritmos permitiu a obtenção de um resultado com maior acurácia para o mapeamento de deslizamentos.

No entanto, para a combinação entre dois algoritmos, todos os indicadores de acurácia apresentaram resultados inferiores à combinação de três algoritmos. Este fator é muito importante, pois evidencia que a escolha dos classificadores e adição de diversidade é importante para a melhora do resultado final da classificação, no entanto, a informação a ser utilizada para a classificação deve possuir acurácia adequada, de maneira a não influenciar negativamente no resultado final da combinação.

Desta forma, a avaliação da classificação deve ser feita com base em vários indicadores de acurácia e não apenas baseada no índice kappa ou na acurácia geral (FOODY, 2002), principalmente para este artigo que possui como objetivo o melhor desempenho para uma classe específica. Para o estudo em questão a análise dos resultados dos erros de comissão e omissão é muito importante, uma vez que se busca um resultado que primordialmente omita o mínimo possível de áreas de deslizamento e não superestime o mapeamento dessas áreas. Os resultados desses indicadores de acurácia para as composições de classificações foram os melhores encontrados entre todos os classificadores, sobretudo os encontrados para o SMC composto pelos três melhores algoritmos (SVM, MV e RN).

O uso de sorteio como mecanismo de decisão em caso de empate é pertinente, no entanto, as ferramentas estatísticas não são mais eficientes do que a utilização de informações espaciais complementares para realizar o desempate. A utilização da análise de contexto resultou em classificações com maior acurácia, ou seja, mais representativas para a solução do problema em questão. Este resultado era esperado, uma vez que a utilização de informações espaciais agrega conhecimento à decisão evitando a aleatoriedade.

4.1.5. Conclusões

Comparando os resultados obtidos com o uso da combinação de três algoritmos com os obtidos por Manfré *et al.* (2014) observa-se grande diferença, sobretudo para o erro de omissão e para percentual de classificação na classe deslizamento. O uso combinado de três algoritmos com bons indicadores de acurácia proporcionou bom desempenho da classificação para a classe deslizamento. Diferentemente do que aponta a literatura (KROGH; VEDELSBY, 1995; BROWN *et al.*, 2005; MICHAIL; BENEDIKTSSON; IOANNIS, 2005; CHANDRA; YAO, 2006; FOODY, 2009) a inclusão de diversidade neste caso prejudicou o resultado da classificação, tanto para a classificação de toda a cena como para a classe de deslizamento. Conforme Giacinto, Roli e Fumera (2000) cada classificador resulta em melhor desempenho para casos específicos, desta forma o uso da combinação dos três melhores classificadores para a classe deslizamento produziu melhor resultado para esta classe.

Conforme já destacado por diversos autores (WASKE *et al.*, 2012, KOC-SAN, 2013; LIU *et al.*, 2014) o uso de SMC de maneira geral, melhorou a qualidade da classificação, resultando em menores erros de omissão e melhor percentual de classificação para a classe de deslizamento. No entanto, a estratégia de utilização dos algoritmos para a composição do SMC deve ser analisada e adaptada ao objetivo da classificação. A avaliação individual dos indicadores de acurácia de cada algoritmo é importante para se identificar quais possuem desempenho que se coadune com o resultado final.

A inclusão de diversidade para a composição entre classificadores é importante para melhorar a classificação, no entanto, os classificadores a serem utilizados devem ser avaliados, evitando-se a inclusão de fontes de erro na combinação.

5. Análise Integrada dos Resultados

Esta Tese apresenta três contribuições de processamento digital de imagens de sensoriamento remoto para a identificação de deslizamentos e mapeamento de áreas de risco. Um método de mapeamento do relevo, com dados detalhados e contínuos, que automatiza a compartimentação e facilita a identificação de áreas de risco de deslizamento e inundações, além de facilitar ações de planejamento urbano e ambiental e servir de base para outras análises que dependam da avaliação do relevo.

A região de ocorrência do deslizamento, na bacia hidrográfica do Rio Pilões, possui características geomorfológicas que favorecem o desencadeamento de eventos severos de movimentos de massa. A figura 31 mostra as características do relevo da região, de acordo com a metodologia apresentada no capítulo 2 desta Tese. Observa-se que a região apresenta grande quantidade de feições côncavas e convexas em áreas de declividade acentuada. Considerando os altos níveis pluviométricos da região, qualquer intervenção geotécnica deve ser cuidadosamente planejada, uma vez que pode desencadear grandes processos de movimento de massa (GRÉ, 2013).

Figura 31 – Feições do relevo na região do Rio Pilões, Serra do Mar, Estado de São Paulo.

Fonte: Elaboração Própria.

Além disso, são apresentadas duas metodologias de processamento digital de imagens LANDSAT para a obtenção de mapeamento de cicatrizes de deslizamento. A primeira metodologia apresentada utiliza o algoritmo SVM aplicada ao NDVI, obtendo boa acurácia para o mapeamento do deslizamento do Rio Pilões. A segunda metodologia avalia a aplicação de combinações de classificadores para a identificação de cicatrizes na região do Rio Pilões utilizando imagens LANDSAT. Apesar de os pressupostos teóricos (DU *et al.*, 2012; WOŹNIAK; GRAÑA; CORCHADO, 2014) afirmarem que quanto maior a diversidade de classificadores melhor seria o resultado da composição, os resultados obtidos mostram que a escolha dos algoritmos é fundamental para a obtenção de uma classificação final com boa acurácia.

O algoritmo SVM apresentou resultados muito bons em ambas as metodologias propostas, sendo uma ferramenta eficiente para o mapeamento de cicatrizes de deslizamentos. A utilização de NDVI é muito difundida no mapeamento de deslizamentos, no entanto, geralmente se realiza uma análise de série histórica do NDVI para a identificação de alterações bruscas nos índices de vegetação (SEZER; PRADHAN; GOKCEOGLU, 2011; YANG; WANG; SHI, 2013). Os dados LANDSAT TM 5 apresentam problemas de georreferenciamento, demandando grande esforço para o co-registro eficiente entre cenas de uma série histórica. No entanto, em região de grande variação topográfica, o registro é mais complicado e demanda a ortorretificação das cenas para possibilitar uma análise eficiente da série histórica (HUANG *et al.*, 2010). Desta forma, a possibilidade de utilizar a amenização das sombras do relevo proporcionadas pelo NDVI e a sua classificação direta utilizando um algoritmo de bom desempenho como o SVM mostrou-se uma alternativa viável e apresentou bons resultados, com metodologia que pode ser amplamente replicável.

Já a metodologia de combinação de algoritmos apresentou resultados ainda mais relevantes para a combinação entre os classificadores SVM, RN e MV. Os resultados atingiram valores superiores a 90% de acerto para a classe deslizamento. A utilização de combinações entre classificadores tem sido amplamente utilizada para diversas finalidades de mapeamento, sempre apresentando resultados superiores ao uso dos classificadores isolados. Diversos métodos são empregados para a combinação entre as classificações, buscando utilizar o melhor de cada classificação no resultado final. No entanto, alguns autores (KITTLER *et al.*, 2006; LYSIAK; KURZYNSKI; WOLOSZYNSKI, 2014) ressaltam que a escolha dos algoritmos é mais importante que o método de combinação. Neste sentido, a metodologia empregada contribui para a escolha dos melhores algoritmos a serem utilizados, sendo que a avaliação integrada dos indicadores de acurácia foi fundamental para a

identificação de uma combinação com bons resultados. A combinação entre os algoritmos SVM, RN e MV possui grande potencial para replicação em outras regiões.

Além disso, com o advento das imagens LANDSAT OLI 8, a potencialidade das duas metodologias apresentadas é amplificada, uma vez que, o sensor *Operational Land Imager* (OLI) opera com faixa espectral mais estreita para a banda do infravermelho próximo (utilizada na composição do NDVI), além de melhora na qualidade dos dados das outras bandas e maior qualidade de co-registro entre as cenas (ROY *et al.*, 2014).

Diversos autores na literatura (REIS *et al.*, 2012; KUNDU *et al.*, 2013) aplicam o uso integrado de informações do relevo com imagens de satélite para a identificação de deslizamentos. Desta forma, a integração entre os resultados apresentados nesta Tese podem potencializar o mapeamento de cicatrizes do mapeamento de cicatrizes de deslizamentos com o uso de informações relativas ao relevo, componente espacial fundamental para a ocorrência deste tipo de evento (PRADHAN; LEE, 2010). A compartimentação do relevo apresentado foi utilizada para excluir regiões com baixo potencial de eventos de escorregamentos, como planícies de inundação, planícies elevadas e planaltos. Desta forma, foram verificadas as regiões com base em imagens de alta resolução disponíveis para consulta online. O resultado final da classificação com a combinação utilizando os algoritmos RN, SVM e MV cobriu totalmente a área do deslizamento do rio Pilões, conforme mostrado na figura 32.

Figura 32 – Sobreposição do resultado final da classificação com a imagem de alta resolução que permite a visualização do deslizamento do rio Pilões.

Fonte: Elaboração Própria.

A análise integrada entre o resultado final da classificação por votação com as feições do relevo permitiu a eliminação de áreas mapeadas como deslizamento e a definição de áreas

com maiores ou menores potenciais de serem cicatrizes. Esse resultado é apresentado na figura 33, bem como algumas áreas que na sobreposição com imagem de satélite de alta resolução evidência outras áreas com características semelhantes a cicatrizes e cortes em taludes.

O uso de uma informação complementar a classificação possibilitou a utilização prática da classificação para identificar outras áreas com características de deslizamento ou corridas de lama na região estudada. No caso de deslizamentos o uso de informações do relevo é fundamental para auxiliar na análise da potencialidade de ocorrer ou já ter ocorrido um evento dessa natureza (NICOLL, 2010), sendo que a forma das vertentes e a dissecação do relevo contribuem para se obter um resultado ainda mais refinado (SESTINI; FLORENZANO, 2004; VANACÔR; ROLIM, 2012). Intersecção entre os dois produtos selecionou apenas as áreas com potencial para deslizamento e facilitou a análise visual com apoio de imagens de alta resolução. Foram encontradas, além da cicatriz já conhecida outras quatro áreas com características semelhantes a cicatrizes. Dentre as áreas é possível observar um grande corte no talude na base de um morro e três outras áreas próximas à Rodovia Imigrantes, que na imagem de satélite utilizada pode-se interpretar a ocorrência de alguma intervenção para conter algum tipo de movimento de massa. Além disso, áreas de solo exposto próximas a dutos também foram identificadas pelo mapeamento.

6. Conclusões

A utilização de técnicas de processamento digital de imagens de sensoriamento remoto possuiu ampla aplicabilidade para o mapeamento de deslizamentos e áreas de risco, sobretudo para a identificação de feições do relevo favoráveis à ocorrência de deslizamento e para o mapeamento de cicatrizes. Com os resultados obtidos neste trabalho pode-se concluir que a utilização de dados como SRTM e LANDSAT potencializa o mapeamento de deslizamentos e são fundamentais para o levantamento de áreas de risco e definição de planos de mitigação.

A análise de feições do relevo é fundamental no processo de mapeamento de risco e a definição de um processo automatizado de interpretação de suas características é fundamental para acelerar o processo de mapeamento e facilitar ações de identificação e planejamento de intervenções em áreas susceptíveis ou de risco, orientar planejamentos urbanos e ambientais, integrar projetos preliminares de análise do traçado de vias entre outras aplicações. A metodologia proposta neste trabalho mostrou-se adequada para a área de estudo e apresenta grande potencial de replicação para demais regiões, demandando ajustes às especificidades locais. Além disso, a utilização dos dados TOPODATA foi fundamental para a construção de uma análise refinada com maior detalhamento das feições do relevo, fundamental no processo de identificação de áreas com potencial de deslizamento.

No mapeamento de deslizamentos, os dados LANDSAT permitiram a identificação do deslizamento ocorrido na bacia hidrográfica do Rio Pilões, possuem grande potencial para a identificação de deslizamentos de iguais proporções, ou até menores. No entanto, a utilização de dados de alta resolução, ou a visita aos locais é fundamental para a confirmação da existência de algum evento de movimento de massa.

As técnicas de processamento digital de imagem produzem bons resultados e permitem a manipulação do dado de sensoriamento e a evidenciação de feições muitas vezes escondidas sob as sombras do relevo. A utilização do NDVI é uma boa alternativa para a atenuação dos efeitos da topografia nas imagens de satélite, potencializando o desempenho de algoritmos de classificação. No entanto, os erros de comissão tendem a ser grandes, uma vez que feições como solo exposto possuem características semelhantes.

A transformação de espaço de cores também se mostrou capaz de facilitar a identificação visual de cicatrizes, melhorando a qualidade das áreas de treinamento selecionadas para a classificação supervisionada. Assim como o NDVI, a transformação do espaço de cores atenua o efeito da topografia e permite a identificação de feições escondidas sob as sombras.

O algoritmo de classificação supervisionada SVM pode ser executado com a utilização de apenas uma variação, podendo ser aplicado a índices como o NDVI. Os resultados dessa metodologia se mostraram eficientes e de fácil aplicação.

Os algoritmos de melhor desempenho para o mapeamento de deslizamento em imagens LANDSAT foram o SVM, RN e a Máxima Verossimilhança.

A combinação de algoritmos é uma técnica que melhora o desempenho da classificação, porém, a escolha dos algoritmos é fundamental. Desta forma, a avaliação integrada dos indicadores de acurácia de cada um dos algoritmos deve ser realizada antes da execução da composição. A utilização de algoritmos com indicadores de acurácia insatisfatórios pode causar a propagação do erro, interferindo diretamente no resultado final da composição.

A combinação dos resultados apresentados nesta Tese permite a execução de uma análise detalhada e forma rápida baseada em imagens de alta resolução, facilitando a identificação de cicatrizes e feições semelhantes. A técnica utilizada é replicável podendo ser utilizada em outras regiões para a identificação de áreas que necessitem intervenção.

7. Referências

- AB'SABER, A.N. Geomorfologia do sítio urbano de São Paulo. 1957. 360 p. **Tese** (Doutorado). Faculdade de Filosofia, Letras e Ciências Humanas da Universidade de São Paulo, São Paulo, 1957.
- AB'SABER, A.N. Um conceito de Geomorfologia a serviço das pesquisas sobre o quaternário: São Paulo. **Geomorfologia**, n. 18, p. 1-23, 1969.
- ABE, B.T.; OLUGBARA, O.O.; MARWALA, T. Classification of Hyperspectral Images Using Machine Learning Methods. In **IAENG Transactions on Engineering Technologies**, p. 555-569. Springer Netherlands, 2014.
- ABE, B.T.; OLUGBARA, O.O.; MARWALA, T. Classification of hyperspectral images using machine learning methods. In: Haeng-Kon, K.; Sio-Iong, A.; Burghard B., R. **IAENG Transactions on Engineering Technologies**. Netherlands: Springer, 2011. p. 555-569.
- ADDINK, E.; DE JONG, S.; PEBESMA, E. The importance of scale in object-based mapping of vegetation parameters with hyperspectral imagery. **Photogrammetric Engineering and Remote Sensing**, 73, 905–912, 2007.
- AKSOY, B.; ERCANOGLU, M. Landslide identification and classification by object-based image analysis and fuzzy logic: An example from the Azdavay region (Kastamonu, Turkey). **Computers & Geosciences**, v. 38, n.1, p. 87-98. 2012.
- ALEXAKIS, D.D.; AGAPIOU, A.; TZOUVARAS, M.; THEMISTOCLEOUS, K.; NEOCLEOUS, K.; MICHAELIDES, S.; HADJIMITSIS, D.G. Integrated use of GIS and remote sensing for monitoring landslides in transportation pavements: the case study of Paphos area in Cyprus. **Natural Hazards**, v. 72, n. 1, p. 119-141. 2014.
- ALKEVLI, T.; ERCANOGLU, M. Assessment of ASTER satellite images in landslide inventory mapping: Yenice-Gökçebey (Western Black Sea Region, Turkey). **Bulletin of Engineering Geology and the Environment**, v. 70, n. 4, p. 607-617. 2011.
- ALMEIDA, F.F.M. Fundamentos geológicos do relevo paulista. **Boletim do IGG**, v. 42, p. 169-263, 1964.
- ALVES, J.M.P.; CASTRO, P.T.A. Influência de feições geológicas na morfologia da bacia do Rio Tanque (MG) baseada no estudo de parâmetros morfométricos e análise de padrões de lineamentos. **Revista Brasileira de Geociências**, v. 33, n. 2, p. 117-124, 2003.
- BAI, S.; LÜ, G.; WANG, J.; ZHOU, O.; DING, L. GIS-based rare events logistic regression for landslide-susceptibility mapping of Lianyungang, China. **Environmental Earth Sciences**, v. 62, n. 1, p. 139-149, 2011.
- BARLOW, J.; MARTIN, Y.; FRANKLIN, S.E. Detecting translational landslide scars using segmentation of Landsat ETM+ and DEM data in the northern Cascade Mountains, British Columbia. **Canadian Journal of Remote Sensing**, v. 29, n. 4, p. 510-517. 2003.
- BARRETT, E.C. **Introduction to environmental remote sensing**. 4. ed. Londres:Chapman and Hal, 2013. 480 p.

BAVARSAIKHAN, U.; BOLDGIV, B.; KIM, K.R.; PARK, K.A.; LEE, D. Change detection and classification of land cover at Hustai National Park in Mongolia. **International Journal of Applied Earth Observation and Geoinformation**, v. 11, pp. 273-280, 2009.

BEHLING, R.; ROESSNER, S.; SEGL, K.; KLEINSCHMIT, B.; KAUFMANN, H. Automated landslide identification based on temporal NDVI-trajectories using long-term optical multi-sensor time-series data. In: European Geosciences Union General Assembly, 2014, Viena. **Anais...**, Göttingen: Copernicus Publications, 2014. Paginação irregular.

BEHLING, R.; ROESSNER, S.; SEGL, K.; KLEINSCHMIT, B.; KAUFMANN, H. Robust Automated Image Co-Registration of Optical Multi-Sensor Time Series Data: Database Generation for Multi-Temporal Landslide Detection. **Remote Sensing**, v. 6, n. 3, p. 2572-2600. 2014.

BEN ABDALLAH, A. C.; FRIGUI, H.; GADER, P. Adaptive local fusion with fuzzy integrals. **IEEE Transactions on Fuzzy Systems**, v. 20, n. 5, p. 849-864. 2012.

BENEDIKTSSON, J.A.; CHANUSSOT, J.; FAUVEL, M. Multiple classifier systems in remote sensing: From basics to recent developments. **Multiple Classifiers Systems**, 4472, p. 501-512. 2007.

BESKOW, S., MELLO, C. R., NORTON, L.D. CURI, N., VIOLA, M.R., AVANZI, J.C. Soil erosion prediction in the Grande River Basin, Brazil using distributed modeling. **Catena**, 79, 49-59, 2009.

BIGARELLA, J.J. Variações climáticas no Quaternário e suas implicações no revestimento florístico do Paraná. **Boletim Paranaense de Geografia**, n. 10/15, p. 211-231, 1964.

BIGARELLA, J.J.; MOUSINHO, M.R.; SILVA, J.X. Considerações a respeito dos terraços fluviais, rampas, colúvios e várzeas. **Boletim Paranaense de Geografia**, n. 16/17, p. 153-197, 1965.

BIGGIO, B.; FUMERA, G.; ROLI, F. Multiple classifier systems for robust classifier design in adversarial environments. **Journal of Machine Learning Cybernetics**, v. 1, p. 27-41. 2010.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS journal of photogrammetry and remote sensing**, v. 65, n. 1, p. 2-16. 2010.

BLASCHKE, T. Object-based contextual image classification built on image segmentation. **Advances in Techniques for Analysis of Remotely Sensed Data, 2003 IEEE Workshop**, 113-119, 2003.

BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL, P. Object-oriented image processing in an integrated GIS/Remote Sensing environment and perspective for environmental applications. In: CREMERS, A.; GREVE, K. (Eds). **Environmental Information for planning, Politics and public**. Marburg, Germany: Metropolis-Verlag. 2000. p. 555-570.

BORGA, M.; STOFFEL, M.; MARRA, F.; JAKOB, M. Hydrogeomorphic response to extreme rainfall in headwater systems: flash floods and debris flow. **Journal of Hydrology**, v. 516, part B, p. 194-206. 2014.

BOSER, B.; GUYON, I.; VAPNIK, V. A training algorithm for optimal margin classifiers. In: Annual Workshop on Computational Learning Theory, 5., 1992, Pittsburg. **Anais...** New York: ACM Press, 1992. p. 144-152.

BREIMAN, L. Bagging predictors. **Machine Learning**, v. 24, p. 123–140. 1996.

BRIEM, G.; BENEDIKTSSON, J.; SVEINSSON, J. Multiple classifiers applied to multisource remote sensing data. **IEEE Transactions on Geosciences Remote Sensing**, v. 40, p. 2291–2299. 2002.

BROLLO, M.J. Metodologia automatizada para seleção de áreas para disposição de resíduos sólidos: aplicação na Região Metropolitana de Campinas (SP). 2001. 200 p. **Tese** (Doutorado) – Universidade de São Paulo, São Paulo, 2001.

BROOKES, I.A. Spatially variable sedimentary responses to orbitally driven pluvial climate during Marine Oxygen Isotope Stage 5.1, Dakhla Oasis region, Egypt. **Quaternary Research**, v. 74, n. 2, p. 252–264, 2010.

BROWN, G.; WYATT, J.; HARRIS, R.; YAO, X. Diversity creation methods: A survey and categorisation. **Information Fusion**, v. 6, p. 5–20. 2005.

BÜDEL, J. **Climatic geomorphology**. New Jersey: Princeton University Press, 1982. 443p.

BURGES, C. J. C. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, v. 3, n. 2, 1998.

CAMARGO, F. F.; ALMEIDA, C. M.; FLORENZANO, T. G.; HEIPKE, C.; FEITOSA, R. Q.; COSTA, G. A. O. P. ASTER/Terra imagery and a multilevel semantic network for semi-automated classification of landforms in a subtropical area. **Photogrammetric Engineering & Remote Sensing**, v. 77, n. 6, p. 619-629. 2011.

CAMARGO, F.F.; ALMEIDA, C.M.; COSTA, G.A.O.P.; FEITOSA, R.Q.; OLIVEIRA, D.A.B.; HEIPKE, C.; FERREIRA, R.S. An open source object-based framework to extract landform classes. **Expert Systems with Applications**, v. 39, p. 541-554, 2012.

CAMARGO, F.F.; FLORENZANO, T.G.; ALMEIDA, C.M.; OLIVEIRA, C.G.; FEITOSA, R.Q. Análise orientada a objeto e dados Aster/Terra na classificação do relevo. **Boletim de Ciências Geodésicas**, v. 15, n. 1, p. 81-102, 2009.

CARVALHO JÚNIOR, O. A.; GUIMARÃES, R. F.; MONTGOMERY, D. R.; GILLESPIE, A. R.; GOMES, R. A. T.; MARTINS, E. S.; SILVA, N. C. Karst depression detection using ASTER, ALOS/PRISM and SRTM-Derived digital elevation models in the Bambuí group, Brasil. **Remote Sensing**, v. 6, p. 330-351. 2014.

CHANDRA, A.; YAO, X. Evolving hybrid ensembles of learning machines for better generalisation. **Neurocomputing**, v. 69, p. 686–700. 2006.

CHEN, H.; LIN, G.; LU, M.; SHIH, T.; HORNG, M.; WU, S.; CHUANG, B. Effects of topography, lithology, rainfall and earthquake on landslide and sediment discharge in mountain catchments of southeastern Taiwan. **Geomorphology**, v. 133, n. 3, p. 132-142. 2011.

CHRISTOFOLETTI, A. A análise da densidade de drenagem e suas implicações geomorfológicas. **Geografia**, v. 4, n. 8, p. 23-41, 1979.

CHRISTOFOLETTI, A. **Geomorfologia**. São Paulo: Edgard Blücher. 1974. 149 p.

CONGALTON, R.G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote sensing of environment**, v. 37, n. 1, p. 35-46. 1999.

COROMINAS, J. **Impacto sobre los riesgos naturales de origen climático**: inestabilidad de laderas. In: Moreno, JM ed. Proyecto ECCE – Evaluación Preliminar de los impactos en España por efecto del Cambio Climático. Madrid, Spain. Ministerio de Medio Ambiente de España. p. 549-579, 2005.

CREPANI, E.; MEDEIROS, J.S.; AZEVEDO, L.G.; HERNADEZ FILHO, P.; FLORENZANO, T.G.; DUARTE, V. **Curso de Sensoriamento Remoto Aplicado ao Zoneamento Ecológico-Econômico**. São José dos Campos: INPE, 1996. 18 p.

DAI, F.C.; LEE, C.F. Frequency–volume relation and prediction of rainfall-induced landslides. **Engineernig Geology**, v. 59, p. 253–266, 2001.

DE GUIDI, G.; SCUDERO, S. Landslide susceptibility assessment in the Peloritani Mts.(Sicily, Italy) and clues for tectonic control of relief processes. **Natural Hazards and Earth System Sciences**, v. 13, p. 949-963.2013.

DE SY, V.; SCHOORL, J.M.; KEESSTRA, S.D.; JONES, K.E.; CLAESSENS, L. Landslide model performance in a high resolution small-scale landscape. **Geomorphology**, v. 190, p. 73-81. 2013.

DE VITA, P.; NAPOLITANO, E.; GODT, J.W.; BAUM, R.L. Deterministic estimation of hydrological thresholds for shallow landslide initiation and slope stability models: case study from the Somma-Vesuvius area of southern Italy. **Landslides**, v. 10, n. 6, p. 713-728. 2013.

DEMERKISEN, A.C. Multi-risk interpretation of natural hazard of settlements of the Hatay province in the east Mediterranean region, Turkey using SRTM DEM. **Environmental Earth Sciences**, v. 65, n. 6, pp. 1895-1907, 2012.

DENGSHENG, L.; WENG, Q.; MORAN E, L.I.G.; HETRICK, S. Remote sensing image classification. **Advances in environmental remote sensing: sensors, algorithms, and applications**. Boca Raton, FL: CRC Press/Taylor & Francis Group Publishers Part II p. 219-240. 2011.

DI MARTINO, L.; MASCIOTTO, L.; RICCA, G.; TOJA, M. Relationships between landslides phenomena and road network: An example from hilly region of Asti Province

(North-Western Italy). **Engineering Geology for Society and Territory**, v. 2, p. 1049-1053. 2014.

DOAN, H.T.X.; FOODY, G.M. Increasing soft classification accuracy through the use of an ensemble of classifiers. **International Journal Remote Sensing**, v. 28, p. 4609–4623. 2007.

DOLEIRE-OLTMANN, S.; EISANK, C.; DRAGUT, L.; BLASCHKE, T. An object-based workflow to extract landforms at multiple scales from two distinct data types. **IEEE Geoscience and Remote Sensing Letters**, v. 10, n. 4, p. 947-951. 2013.

DONG, J.; LAI, P.; CHANG, C.; YANG, S.; YEH, K.; LIAO, J.; PAN, Y. Deriving landslide dam geometry from remote sensing images for the rapid assessment of critical parameters related to dam-breach hazards. **Landslides**, v.11, n. 1, p. 93-105. 2014.

DRĂGUȚ, L.; EISANK, C. Automated object-based classification of topography from SRTM data. **Geomorphology**, v. 141, p. 21-33. 2012.

DU, P.; XIA, J.; ZHANG, W.; TAN, K.; LIU, Y.; LIU, S. Multiple Classifier System for Remote Sensing Image Classification: A Review. **Sensors**, v. 12, n. 4, p. 4764-4792, 2012.

EISANK, C.; DRĂGUȚ, L.; BLASCHKE, T. A generic procedure for semantics-oriented landform classification using object-based image analysis. **Geomorphometry**, 2011, p. 125-128. 2011.

FARR, T. G.; ROSEN, P. A.; CARO, E.; CRIPPEN, R.; DUREN, R.; HENSLEY, S.; KOBRICK, M.; PALLER, M.; RODRIGUEZ, E.; ROLER, L.; SEAL, D. Shaffer, S.; SHIMADA, J. The Shuttle Radar Topography Mission. **Reviews of Geophysics**, v. 45, n. 2. 2007.

FERNANDES, N. F.; AMARAL, C. P. Movimentos de massa: uma abordagem geológico-geomorfológica. In: GUERRA A.J.T.; CUNHA, S. **Geomorfologia e meio ambiente**. 1 ed. Rio de Janeiro: Bertrand Brasil, 1996. cap. 3. p. 123-194.

FERREIRA, C. J; ROSSINI-PENTEADO, D. Mapeamento de risco a escorregamento e inundação por meio da abordagem quantitativa da paisagem em escala regional. In: 13º CONGRESSO BRASILEIRO DE GEOLOGIA DE ENGENHARIA, 11, 2011 São Paulo. **Anais...**, São Paulo: ABGE, 2011. p. 1 – 36. CD-ROM.

FERREIRA, C.J.; SILVA, P.C.F.; FURLAN, S. A.; BROLLO, M.J.; TOMINAGA, L.K.; VEDOVELLO, R.; GUEDES, A.C.M.; FERREIRA, D.F.; EDUARDO, A.S.; AZEVEDO SOBRINHO, J.M. Devising strategies for reclamation of derelict sites due to mining of residual soil (saibro) at Ubatuba, north coast of São Paulo State, Brazil: the views and roles of the stakeholders. **Sociedade e Natureza**, edição especial, p. 643-660, 2005.

FOODY, G. M. Classification accuracy comparison: Hypothesis tests and the use of confidence intervals in evaluations of difference, equivalence and non-inferiority. **Remote Sensing of Environment**, v. 113, p, 1658–1663. 2009.

FOODY, G.M. Status of land cover classification accuracy assessment. **Remote sensing of environment**, v. 80, n. 1, p. 185-201, 2002.

FOODY, G.M.; BOYD, D.S.; SANCHEZ-HERNANDEZ, C. Mapping a specific class with an ensemble of classifiers. **International Journal Remote Sensing**, 28, 1733–1746, 2007.

FOODY, G.M.; MATHUR, A. The use of small sets of containing mixed pixels for accurate hard image classification: Training on mixed spectral responses for classification by SVM. **Remote Sensing of Environment**, v. 103, p. 179-189, 2006.

FURLAN, A., BONOTTO, D.M., GUMIERE, S. J. Development of environmental and natural vulnerability maps for Brazilian coastal at São Sebastião in São Paulo State. **Environmental Earth Sciences**, v. 64, n. 3, p. 659-669, 2011.

GAO, J.; NICKUM, J.E., PAN, Y. An assessment of flood hazard vulnerability in the Dongting Lake Region of China. **Lakes and Reservoirs: research and management**, v. 12, p. 27 – 34, 2007.

GHOSE, M.K.; PRADHAN, R.; GHOSE, S.S. Decision tree classification of remotely sensed satellite data using spectral separability matrix. **International Journal of Advanced Computer Science and Applications**, v. 1, n. 5, p. 93–101, 2010.

GIACINTO, G. An approach to the automatic design of multiple classifier systems. **Pattern Recognition Letters**, v. 22, p. 25–33, 2001.

GIACINTO, G.; ROLI, F.; FUMERA, G. Selection of image classifiers. **Electronic Letters**, v. 36, p. 420–422, 2000.

GRÉ, J.C.R. **Estudo geotécnico para a avaliação da aptidão física de terrenos de planície costeira à urbanização**. 2013. 286 p. Dissertação (mestrado) - Centro de Filosofia e Ciências Humanas, Universidade Federal de Santa Catarina, Florianópolis, 2013.

GUIMARÃES, R. F.; GOMES, R. A. T.; CARVALHO JÚNIOR, O. A.; MARTINS, E. S.; OLIVEIRA, S. N.; FERNANDES, N. F. Análise temporal das áreas susceptíveis a escorregamentos rasos no Parque Nacional da Serra dos Órgãos (RJ) a partir de dados pluviométricos. **Revista Brasileira de Geociências**, v. 39, n. 1, p. 190-198. 2009.

GUTHRIE, R.H. The effects of logging on frequency and distribution of landslides in three watersheds on Vancouver Island, British Columbia. **Geomorphology**, v. 43, n. 3-4, p. 273-292, 2002.

GUZZETTI, F.; MONDINI, A. C. CARDINALI, M.; FIORUCCI, F.; SANTANGELO, M.; CHANG, K-T. Landslide inventory maps: new tools for an old problem. **Earth Science Reviews**, v. 112, p. 42-66. 2012.

HO, T.K.; HULL, J.J.; SRIHARI, S.N. On multiple classifier systems for pattern recognition. In: IEEE International Conference on Pattern Recognition, 11., 1992, Hague. **Anais...** Washington D.C.: IEEE Computer Society Press. 1992. p. 84-84.

HÖBLING, D.; FÜREDER, P.; ANTOLINI, F.; CIGNA, F.; CASAGLI, N.; LANG, S. A Semi-Automated Object-Based Approach for Landslide Detection Validated by Persistent

Scatterer Interferometry Measures and Landslide Inventories, **Remote Sensing**, v. 4, p. 1310-1336. 2012.

HSIEH, Y.; HOU, C.; CHAN, Y.; HU, J.; FEI, L.; CHEN, H.; CHIU, C. Detection and Volume Estimation of Large Landslides by Using Multi-temporal Remote Sensing Data. In: EGU General Assembly Conference, 2014, Viena. **Anais...** Gottingen: EGU, 2014. v. 16, p. 5725.

HUANG, C.; GOWARD, S.N.; MASEK, J.G.; THOMAS, N.; ZHU, Z.; VOGELMANN, J.E. An automated approach for reconstructing recent forest disturbance history using dense Landsat time series stacks. **Remote Sensing of Environment**, v. 114, n. 1, p. 183-198, 2010.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Compartmentos do Relevo**, Rio de Janeiro, IBGE, 2000.

IG – INSTITUTO GEOLÓGICO DO ESTADO DE SÃO PAULO; SMA – SECRETARIA DE MEIO AMBIENTE DO ESTADO DE SÃO PAULO. Metodologia para Seleção de Áreas para Tratamento e Disposição Final de Resíduos Sólidos. In: BROLLO, M.J.; SILVA, P.C.F. (Coord.) **Relatório Técnico**. São Paulo: IG / SMA. 1999.

IIAMES, J.S.; CONGALTON, R.G.; LUNETTA, R.S. Analyst variation associated with land cover image classification of Landsat ETM+ data for the assessment of coarse spatial resolution regional/global land cover products. **GIScience & Remote Sensing**, v. 50, n. 6, p. 604-622, 2013.

INPE – Instituto de Pesquisa Espaciais. **TOPODATA – Banco de Dados Geomorfométricos do Brasil**. 2011. Disponível em: <<http://www.dsr.inpe.br/topodata>>. Acesso em: 26 dez 2011. INTERNATIONAL FEDERATION OF RED CROSS AND RED CRESCENT SOCIETIES - IFRC. **World Disaster Report**. Genebra: IFRC, 2011. p. 1 – 251 (Special Report).

IPT – Instituto de Pesquisas Tecnológicas. **Divisão Geomorfológica do Estado de São Paulo**, São Paulo: IPT. 1981.

JACQUIN, A.; MISAKOVA, L.; GAY, M. A hybrid object-based classification approach for mapping urban sprawl in periurban environment. **Landscape and Urban Planning**, v. 84, n. 2, p. 152-165, 2008.

JAISWAL, P.; VAN WESTEN, C. J.; JETTEN, V. Quantitative assessment of landslide hazard along transportation lines using historical records. **Landslides**, v. 8, n. 3, p. 279-291, 2011.

JORGE, L.A.B. Soil erosion fragility assessment using an impact model and geographic information system. **Scientia. agricola**, 66, p. 658-666, 2009.

KANUNGO, D.P.; SARKAR, S. Use of multi-source data sets for land use/land cover classification in a hilly terrain for landslide study. **Disaster and Development**, v. 5, n. 1, p. 35-51, 2011.

KANUNGO, T.; MOUNT, D.M.; NETANYAHU, N.S.; PIATKO, C.D.; SILVERMAN, R.; WU, A.Y. An efficient k-means clustering algorithm: Analysis and implementation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 7, p. 881-892, 2002.

KEMPER, J. T.; MACDONALD, S. E. Directional change in upland tundra plant communities 20-30 years after seismic exploration in the Canadian low-arctic. **Journal of Vegetation Science**, v. 20, n. 3, p. 557-567, 2009.

KEUCHEL, J.; NAUMANN, S.; HEILER, M.; SIEGMUND, A. Automatic land cover analysis for Tenerife by supervised classification using remotely sensed data. **Remote Sensing of the Environment**, v. 86, p. 53-541, 2003.

KITTLER, J.; HATEF, M.; DUIN, R.; MATAS, J. On combining classifiers. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 20, pp. 226-239, 2006.

KOBIYAMA, M.; MENDONÇA, M.; MORENO, D.A.; MARCELINO, I. P. V. O.; MARCELINO, E. V.; GONÇALVES, E. F.; BRAZETTI, L. L. P.; GOERL, R. F.; MOLLERI, G. S. F.; RUDORFF, F. M. **Prevenção de Desastres Naturais: Conceitos Básicos**, 1. ed. Curitiba: Organic Trading, 2006. 109 p.

KOC-SAN D Evaluation of different classification techniques for the detection of glass and plastic greenhouses from WorldView-2 satellite imagery. **Journal of Applied Remote Sensing**, v. 7, n. 1, p. 73553-73553, 2013.

KROGH, A.; VEDELSBY, J. Neural network ensembles, cross validation, and active learning. **Advanced Neural Information Processing Systems**, v. 7, p. 231-238, 1995.

KUMAR, K.; JANGPANGI, L.; GANGOPADHYAY, S. Highway vs. landslides and their consequences in Himalaya. **Landslide Science for Safer Geoenvironment**, p. 389-395, 2014.

KUNCHEVA, L.I. **Combining Pattern Classifiers: Methods and Algorithms**; **IEEE Transactions on Neural Networks**, v. 18, n. 3, p. 964-964. 2007.

KUNCHEVA, L.I.; WHITAKER, C.J. Measures of diversity in classifier ensembles and their relationship with the ensemble accuracy. **Machine Learning**, v. 51, p. 181-207, 2003.

KUNDU, S.; SAHA, A.K.; SHARMA, D.C.; PANT, C.C. Remote sensing and GIS based landslide susceptibility assessment using binary logistic regression model: a case study in the Ganeshganga Watershed, Himalayas. **Journal of the Indian Society of Remote Sensing**, v. 41, n. 3, p. 697-709, 2013.

LANG, S.; BLASCHKE, T. **Análise da paisagem com SIG**. São Paulo: Oficina de Textos. 2009. 424 p.

LARSEN, M.C.; PARKS, J.E. How wide is a road? The association of roads and mass-wasting in a forested montane environment. **Earth Surface Processes and Landforms**, v. 22, n. 9, p. 835-848. 1997.

LEE, S.; CHOI, J.; MIN, K. Probabilistic landslide hazard mapping using GIS and remote sensing data at Boun, Korea. **International Journal of Remote Sensing**, v. 25, n. 11, p. 2037-2052. 2004.

LI, D.C.; LIU, C.W. A class possibility based kernel to increase classification accuracy for small data sets using support vector machines, **Expert Systems with Applications**, v. 37, p. 3104–3110, 2010.

LILLESAND, T.M.; KIEFER, R.W. Remote Sensing and Image Interpretation, 4. ed., New Jersey: John Willey and Sons. 2002. 768 p.

LIU J.G.; MASON P. **Essential image processing and GIS for Remote Sensing**. Hoboken: Wiley, 2009. Páginação irregular.

LIU, J.; PAN, Y.; ZHU, X.; ZHU, W. Using phenological metrics and the multiple classifier fusion method to map land cover types. **Journal of Applied Remote Sensing**, v. 8, n. 1, p. 83691-83691. 2014.

LIU, J.G.; MASON, P. **Essential image processing and GIS for Remote Sensing**. New York: Wiley-Blackwell, 2009. 450 p.

LIZARAZO, I. SVM-based segmentation and classification of remotely sensed data. **International Journal of Remote Sensing**, v. 29, n. 24, p. 7277-7283, 2008.

LO, C.P.; CHOI, J. A hybrid approach to urban land use/cover mapping using Landsat 7 Enhanced Thematic Mapper Plus (ETM+) images. **International Journal of Remote Sensing**, v. 25, n. 14, p. 2687-2700, 2004.

LORENZI, L.; MELGANI, F.; MERCIER, G. A complete processing chain for shadow detection and reconstruction in VHR images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 50, n. 9, p. 3440-3452, 2012.

LOVELAND, T.R.; DWYER, J.L. Landsat: Building a strong future. **Remote Sensing of Environment**, v. 122, p. 22-29. 2012.

LU, D.; WENG, Q.; MORAN, E.; LI, G.; HETRICK, S. Remote sensing image classification. In: WENG, Q. (ed.). **Advances in Environmental Remote Sensing: Sensors, Algorithms, and Applications**. Boca Raton: Taylor & Francis, 2011. cap. 9. p. 219-240.

LUCENA I. S. Projeto de Interfaces para Álgebra de Mapas em Geoprocessamento no Ambiente SPRING. 1998. 108 f. **Dissertação** (Mestrado) - Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos. 1998.

LV, B. B.; XU, J. Effect of kernels and their parameters of SVM on classification accuracy of Landsat TM data. In: LORENZ, P. (ed.). **Advances in Communication Technology and Application**, Southampton: WIT Press, 2014. v. 60, p. 103-109.

LYSIAK, R.; KURZYNSKI, M.; WOLOSZYNSKI, T. Optimal selection of ensemble classifiers using measures of competence and diversity of base classifiers. **Neurocomputing**, v. 126, p. 29-35, 2014.

MA, H.; QIN, Q.; SHEN, X. Shadow segmentation and compensation in high resolution satellite images In: International Geoscience and Remote Sensing Symposium, Massachussets, 2008. **Anais...** Washington D.C.: IEEE Computer Society, 2008. v. 2, p. 1036–1039.

MANCONI, A.; CASU, F.; ARDIZZONE, F.; BONANO, M.; CARDINALI, M.; DE LUCA, C.; GUEGUEN, E.; MARCHESINI, I.; PARISE, M.; VENNARI, C.; LANARI R.; GUZZETTI, F. BRIEF Communication: Rapid mapping of landslide events: the 3 December 2013 Montescaglioso landslide, Italy. **Natural Hazards and Earth System Science**, v. 14, n. 7, p. 1835-1841, 2014.

MANCONI, A.; CASU, F.; ARDIZZONE, F.; BONANO, M.; CARDINALI, M.; DE LUCA, C.; GUEGUEN, E.; MARCHESINI, I.; PARISE, M.; VENNARI, C.; LANARI R.; GUZZETTI, F. BRIEF Communication: Rapid mapping of landslide events: the 3 December 2013 Montescaglioso landslide, Italy. **Natural Hazards and Earth System Science**, v. 14, n. 7, p. 1835-1841. 2014.

MANFRÉ, L.A.; NÓBREGA, R.A.A.N.; QUINTANILHA, J.A. Regional and local topography subdivision and landform mapping using SRTM-derived data: a case study in southeastern Brazil. **Environmental Earth Sciences**, v. Online, p. 1-19, 2014.

MANFRÉ, L.A.; SHINOHARA, E.J.; SILVA, J.B.; SIQUEIRA, R.N.P. GIANNOTTI, M.A.; QUINTANILHA, J.A. Method for landslides identification at the sao paulo state coast, brazil. **Geociências** (São Paulo. Online), v. 33, p. 172-180, 2014.

MANFRÉ, L.A.; SHINOHARA, E.D.; SILVA, J.B.; SIQUEIRA, R.N.D.P.; QUINTANILHA, J.A. Assessment of SVM classification process for landslides identification. In: 10th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences, 2012, Florianópolis. **Anais...** 10th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences, 2012. v. 1.

MANFRÉ, L.A.; SILVA, A.M.; URBAN, R.C.; RODGERS, J. Environmental fragility evaluation and guidelines for environmental zoning: a study case on Ibiuna, (southeastern Brazilian region), **Environmental Earth Sciences**, v. 69, n. 3, pp. 947-957, 2013.

MANSOURIAN, A.; RAJABIFARD, A.; ZOEJ, V. M. J. SDI conceptual modeling for disaster management. In: ISPRS WORKSHOP ON SERVICE AND APPLICATION OF SPATIAL DATA INFRASTRUCTURE, XXXVI, 2005, Hangzhou. **Anais...**, Göttingen: Copernicus Publications, 2005. p. 125 – 130.

MARTHA, T. R.; KERLE, N.; VAN WESTEN, C. J.; JETTEN, V.; KUMAR, K. V. Object-oriented analysis of multi-temporal panchromatic images for creation of historical landslide inventories. **ISPRS journal of photogrammetry and remote sensing**, v.67, p. 105-119. 2012.

MARTIN, Y.; ROOD, K.; SCHWAB, J. W.; CHURCH, M. Sediment transfer by shallow landsliding in the Queen Charlotte Islands, British Columbia. **Canadian Journal of Earth Sciences**, v. 39, n. 2, p. 189–205. 2002.

MARTINELLI, M. Relevô do Estado de São Paulo. **Confins: Revue franco-brésilienne de géographie**, v. 7, n. 7, 2009.

MCKEAN, J.; BUECHEL, S.; GAYDOS, L. Remote sensing and landslide hazard assessment. **Photogrammetric Engineering & Remote Sensing**, v. 57, n. 9, p. 1185–1193. 1991.

MEINEL, G.; NEUBERT, M. A comparison of segmentation programs for high resolution remote sensing data. ISPRS Congress, 20., 2004, Istanbul. **Anais...** Veina: ISPRS, 2004.

MELLOR, A.; HAYWOOD, A.; STONE, C.; JONES, S. The performance of random forests in an operational setting for large area sclerophyll forest classification. **Remote Sensing**, v. 5, n. 6, p. 2838-2856. 2013.

MICHAIL, P.; BENEDIKTSSON, J.A.; IOANNIS, K. The effect of classifier agreement on the accuracy of the combined classifier in decision level fusion. **IEEE Transactions on Geoscience Remote Sensing**, v. 39, p. 2539–2546. 2005.

MONDAL, A.; KUNDU, S.; CHANDNIHA, S.K.; SHUKLA, R.; MISHRA, P.K. Comparison of Support Vector Machine and Maximum Likelihood Classification Technique using Satellite Imagery. **International Journal of Remote Sensing and GIS**, v. 1, n. 2, p. 116-123, 2012.

MONTEIRO, C.A. **Geossistema**: a história de uma procura. São Paulo: Contexto. 2001.
MOOSAVI, V.; TALEBI, A.; SHIRMOHAMMADI, B. Producing a landslide inventory map using pixel-based and object-oriented approaches optimized by Taguchi method. **Geomorphology**, v. 204, p. 646-656. 2014.

MOREIRA, C.V.R.; PIRES NETO, A.G. Clima e Relevô. In: OLIVEIRA, A.M.S.; BRITO, S.N.A. **Geologia da Engenharia**. São Paulo: Associação Brasileira de Geologia de Engenharia. 1998. p. 69-85.

MORENO-SECO, F.; INESTA, J.; DE LEON, P.; MICO, L. Comparison of classifier fusion methods for classification in pattern recognition tasks. **Structuring Syntactic Statistics Pattern Recognition**, 4109, p. 705–713, 2006.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 66, n. 3, p. 247-259, 2011.

NEMMOUR, H.; CHIBANI, Y. Multiple support vector machines for land cover change detection: An application for mapping urban extensions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 61, n. 2, p. 125-133, 2006.

NICHOL J.; WONG, M.S. Satellite remote sensing for detailed landslide inventories using change detection and image fusion. **International Journal of Remote Sensing**, v. 26, n. 9, p. 1913-1926. 2005.

NICOLL, K. Geomorphic and hazard vulnerability assessment of recent residential developments on landslide-prone terrain: The case of the Traverse Mountains, Utah, USA. **Journal of Geography and Regional Planning**, v. 3, p. 126 – 141, 2010.

NOBRE, C.A.; YOUNG, A.F.; SALDIVA, P.H.N.; ORSINI, J.A.M.; NOBRE, A.D.; OGURA, A.T.; THOMAZ, O.; PÁRRAGA, G.O.O.; SILVA, G.C.M.; VALVERDE, M.; SILVEIRA, A.C.; RODRIGUES, G.O. Vulnerability of Brazilian Megacities to climate change: The São Paulo Metropolitan Region (RMSP). In: MOTTA, R.S.; HARGRAVE, J.; LUEDEMANN, G.; GUTIERREZ, M.B.S. **Climate Change in Brazil: economic, social and regulatory aspects**. Brasilia: Institute for Applied Economic Research. 2011.

NÓBREGA, R. A. A.; OHARA, C. G.; VIJAYARAJ, V.; KIM, S.; OLSON, G.; QUINTANILHA, J. A.; BARROS, M.T.L. Extracting and classifying bare soil erosion risk in a urban basin using object-oriented technologies, high resolution imagery and elevation data. In: GEOGRAPHIC INFORMATION SYSTEMS AND WATER RESOURCES IV - AWRA SPRING SPECIALTY CONFERENCE, 2006, Houston. **Anais...**, Middleburg: AWRA, 2006.

OGURA, A.T. **Desastres Naturais no Brasil: vulnerabilidades Sociais e Econômicas e Adaptação às Mudanças Climáticas**, IPT: São Paulo. 2009.

OGURA, A.T. **Relação e Previsibilidade de Eventos Meteorológicos Extremos Deflagadores de Acidentes de Movimentos de Massa na Serra do Mar**, IPT: São Paulo. 2006.

OH, H.J.; LEE, S. Landslide Susceptibility mapping in Panaon Island, Philippines using geographic information systems. **Environmental Earth Sciences**, v. 62, n. 5, p. 935-951, 2011.

ONUMA, T.; ALI, M. Y.; HAMADA, H. Quality Assessment of Digital Elevation Model Derived from ALOS PALSAR Interferometry. In: Remote Sensing Workshop, 2012, Paris. **Anais...**, Standerdmolen: EAGE, 2012. Paginação irregular.

OTUKEI, J.R.; BLASCHKE, T. Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. **International Journal of Applied Earth Observation and Geoinformation**, v. 12, p. S27-S31, 2010.

PAL, M.; MATHER, P.M. Some issues in the classification of DAIS hyperspectral data. **International Journal of Remote Sensing**, v. 27, p. 2895–2916, 2006.

PARTRIDGE, T.C.; DOLLAR, E. S.J.; MOOLMAN, J.; DOLLAR, L.H. The geomorphic provinces of South Africa, Lesotho and Swaziland: A physiographic subdivision for earth and environmental scientists. **Transactions of the Royal Society of South Africa**, v. 65, n.1, p.1 – 47, 2010.

PAULÍN, G. L., HUBP, J. L.; QUESADA, J. F. A. Assessing Landslide Frequency for Landform Hazard Zoning Purposes. In: Sassa, K.; Canuti, P.; Yin, Y. **Landslide Science for a Safer Geoenvironment**. Netherlands: Springer, 2014. v. 2. p. 129-134.

PENNA, D.; BORGA, M.; ARONICA, G. T.; BRIGANDÌ, G.; TAROLLI, P. Predictive power of a shallow landslide model in a high resolution landscape: dissecting the effects of

forest roads. **Hydrology and Earth System Sciences Discussions**, v. 10, n. 7, p. 9761-9798. 2013.

PETLEY, D. Global pattern of loss of life from landslides. **Geology**, v. 40, p. 927-930, 2012.

PETROPOULOS, G.P.; KNORR, W.; SCHOLZE, M.; BOSCHETTI, L.; KARANTOUNIAS, G. Combining ASTER multispectral imagery analysis and support vector machines for rapid and cost-effective post-fire assessment: a case study from the Greek wildland fires of 2007. **Natural Hazards and Earth System Sciences**, v. 10, p. 305-317, 2010.

PETROPOULOS, G.P.; KONTOES, C.; KERAMITSOGLOU, I. Burnt area delineation from a uni-lateral perspective based on Landsat TM imagery classification using Support Vector Machine. **International Journal of Applied Earth Observation and Geoinformation**, v. 13, p. 70-80, 2011.

PETROPOULOS, G.P.; VADREVU, K.P.; XANTHOPOULOS, G.; KARANTOUNIAS, G.; SCHOLZE, M. A comparison of spectral angle mapper and artificial neural network classifiers combined with Landsat TM imagery analysis for obtaining burnt area mapping. **Sensors**, v. 10, n.3, p. 1967-1985, 2010.

PMSP – Prefeitura Municipal de São Paulo; IPT – Instituto de Pesquisas Tecnológicas. **Mapa Geotécnico do Município de São Paulo, 1:10.000**, São Paulo: IPT, 1991.

PONTIUS JUNIOR, R.G.; MILLONES, M. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4407-4429, 2011.

PRADHAN, B.; LEE, S. Delineation of landslide hazard areas on Penang Island, Malaysia, by using frequency ratio, logistic regression, and artificial neural network models. **Environmental Earth Sciences**, v. 60, n. 5, p. 1037-1054. 2010.

RABUS, B.; EINEDER, A.; ROTH, R.; BAMLER, R. The Shuttle radar topography mission – a new class of digital elevation model acquired by spaceborne radar, **Photogrammetry and Remote Sensing**, v. 57, p. 241-262, 2003.

RAHMAN, A.F.R.; FAIRHURST, M.C. Serial combination of multiple experts: A unified evaluation. **Pattern Analysis Applications**, v. 2, p. 292–311, 1999.

RANAWANA, R.; PALADE, V. Multi-classifier systems: Review and a roadmap for developers. **International Journal of Hybrid Intelligence System**, v. 3, p. 1–41, 2006.

REIS, S.; YALCIN, A.; ATASOY, M.; NISANCI, R.; BAYRAK, T.; ERDURAN, M.; SANCAR, M.; EKERCIN, S. Remote sensing and GIS-based landslide susceptibility mapping using frequency ratio and analytical hierarchy methods in Rize province (NE Turkey). **Environmental Earth Sciences**, v. 66, n. 7, p. 2063-2073, 2012.

RICHARDS, J.A. **Remote sensing digital image analysis**. v. 3. Berlin: Springer. 1999.

ROESSNER, S.; BEHLING, R.; SEGL, K.; GOLOVKO, D.; WETZEL, H.; KAUFMANN, H. Automated Remote Sensing Based Landslide Detection for Dynamic Landslide Inventories. In: Sassa, K.; Canuti, P.; Yin, Y. **Landslide Science for a Safer Geoenvironment**. Netherlands: Springer, 2014. v. 2. p. 345-350.

ROSS, J.L.S. Análise empírica da fragilidade dos ambientes naturais e antropizados. **Revista do Departamento de Geografia**, n. 8, FFLCH-USP, São Paulo, 1994.

ROSS, J.L.S.; MOROZ, I.C. **Mapa Geomorfológico do Estado de São Paulo**. São Paulo: DG-FFLCH-USP, IPT, FAPESP, 1997.

ROY, D.P.; WULDER, M.A.; LOVELAND, T.R.; WOODCOCK, C.E.; ALLEN, R.G.; ANDERSON, M.C.; HELDER, D. Landsat-8: Science and product vision for terrestrial global change research. **Remote Sensing of Environment**, v.145, p. 154-172, 2014.

SAADAT, H.; BONNELL, R.; SHARIFI, R.; MEHUYS, G.; NAMDAR, M.; ALE-EBHARIM, S. Landform Classification from a digital elevation model and satellite imagery, **Geomorphology**, v. 100, p. 453-464, 2008.

SAN, B.T. An evaluation of SVM using polygon-based random sampling in landslide susceptibility mapping: The Candir catchment area (western Antalya, Turkey). **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 399-412. 2014.

SCHOTT, J.R. **Remote sensing**. Oxford: Oxford University Press. 2007. 513 p.

SESTINI, M. F. **Variáveis geomorfológico no estudo de deslizamentos em Caraguatatuba-SP utilizando imagens TM-LANDSAT e SIG**. 1999. 140 p. Dissertação (Mestrado) - Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos. 1999.

SESTINI, M.F.; FLORENZANO, T.G. Caracterização de cicatrizes de deslizamentos por processamento de dados TM Landsat em Caraguatatuba-SP. **Geologia USP - Série Científica**, v. 4, n. 2, p. 57-69, 2004.

SEZER, E.A.; PRADHAN, B.; GOKCEOGLU, C. Manifestation of an adaptive neuro-fuzzy model on landslide susceptibility mapping: Klang valley, Malaysia. **Expert Systems with Applications**, v. 38, n. 7, p. 8208-8219, 2011.

SHAHTAHMASSEBI, A.; YANG, N.; WANG, K.; MOORE, N.; SHEN, Z. Review of shadow detection and de-shadowing methods in remote sensing. **Chinese Geographical Science**, v. 23, n. 4, p. 403-420. 2013.

SHARMA, A.R. **Community Vulnerabilities to Climate Change and Local Coping Mechanisms in Khudi Watershed**. 2009. 130 p. Dissertação (Mestrado) - Central Department do Environmental Sciecnecns, Tribhuvan University, Kritipur, Kathmandu, Nepal, 2009.

SIDLE, R. C.; GHESTEM, M.; STOKES, A. Epic landslide erosion from mountain roads in Yunnan, China-challenges for sustainable development. **Natural Hazards and Earth System Sciences Discussions**, v. 2, p. 3887-3917. 2014.

SILVEIRA, A. Uma tentativa de compreensão da dinâmica paisagística sob a ótica da fisiologia da paisagem na obras de Aziz Ab'Saber (1957 e 1969): o caso do sítio urbano de São Paulo In: Simpósio de Pós-graduação em Geografia do Estado de São Paulo, 8., Rio Claro, 2008. **Anais...** Rio Claro: Unesp, 2008. p. 562-577.

SMITS, P.C. Multiple classifier systems for supervised remote sensing image classification based on dynamic classifier selection. **IEEE Transactions on Geosciences and Remote Sensing**, v. 40, p. 801–813, 2002.

SMITS, P.C.; DELLEPIANE, S.G.; SCHOWENGERDT, R.A. Quality assessment of image classification algorithms for land-cover mapping: a review and a proposal for a cost-based approach. **International Journal of Remote Sensing**, v. 20, n. 8, p. 1461-1486, 1999.

SOARES, P.C.; FIORI, A.P. Lógica e sistemática na análise e interpretação de fotografias aéreas em geologia. **Notícias Geomorfológicas**, Campinas, v. 6, n. 32, p. 71-104, 1976.

SOETERS, R. S.; VAN WESTEN, C. J. Slope instability recognition, analysis and zonation. In: TURNER, A. K.; SCHUSTER, R. L. (eds). **Landslides: investigation and mitigation**. Washington DC: Transportation Research Board, National Academy of Sciences. 1996. p. 129–177. (Special Report. 247).

SORENSEN, M. B.; SPADA, M.; BABEYKO, A.; WIEMER, S.; GRÜNTAL, G. Probabilistic tsunami hazard in the Mediterranean Sea. **Journal of Geographical Research**, 117, 1-15. 2012.

SOUSA, B.F.S.; TEIXEIRA, A.S.; FERREIRA, F.A.T.; ANDRADE, E.M.; BRAGA, A.P.S. Avaliação de classificadores baseados em aprendizado de máquina para a classificação do uso e cobertura da terra no bioma Caatinga. RBC. **Revista Brasileira de Cartografia** (Online), v. 62, p. 385-399, 2010.

SPÖRL, C.; ROSS, J. L. S. Análise comparativa da fragilidade ambiental com aplicação de três modelos. **GEOUSP – Espaço e Tempo**, n. 15, p. 39 – 49. 2004.

SREEDEVI, P.D.; SREEKANTH, P.D.; KHAN, H.H.; AHMED, S. Drainage morphology and its influence on hydrology in a semi-arid region: using SRTM data and GIS. **Environmental Earth Sciences**, v. 70, n. 2, pp. 839-848, 2013.

STEELE, B.M. Combining multiple classifiers: An application using spatial and remotely sensed information for land cover type mapping. **Remote Sensing of the Environment**, v. 74, p. 545–556, 2000.

STORY, M.; CONGALTON, R.G. “Accuracy assessment: A user's perspective”. **Photogrammetric Engineering and Remote Sensing**, v. 52, n. 3, p. 397-399, 1986.

STUMPF, A.; KERLE, N. Object-oriented mapping of landslides using Random Forests, **Remote Sensing of Environment**, v. 115, p. 2564–2577. 2011.

SZUSTER, B.W.; CHEN, Q.; BORGER, M. A comparison of classification techniques to support land cover and land use analysis in tropical coastal zones. **Applied Geography**, v. 31, p. 525-532, 2011.

TAROLLI, P.; CALLIGARO, S.; CAZORZI, F.; DALLA FONTANA, G. Recognition of surface flow processes influenced by roads and trails in mountain areas using high-resolution topography. **European Journal of Remote Sensing**, v. 46, p. 176-197. 2013.

TAROLLI, P.; SOFIA, G.; FONTANA, G.D. Geomorphic features extraction from high-resolution topography: landslide crowns and bank erosion. **Natural Hazards**, v. 61, n. 1, p. 65-83. 2012.

TESTUD, J.; OURY, S.; BLACK, R.A.; AMAYENC, P.; DOU, X. The concept of “normalized” distribution to describe raindrop spectra: A tool for cloud physics and cloud remote sensing. **Journal of Applied Meteorology**, v. 40, n. 6, p. 1118-1140, 2001.

THOMAS, D. S. K.; ETURĞAY, K.; KEMEÇ, S. The role of Geographic Information System/Remote Sensing in Disaster Management. In: RODRIGUEZ, H.; QUARANTELLI, E. L.; DYNES, R. **Handbook of Disaster Research**: Newark: Springer, 2007. p. 83-96.

THOMAS, M. F. **Tropical Geomorphology: a study of weathering and landform development in warm climates**. 2. ed. Londres: MacMillan, 1979, 332p.

TIAN, G.; LIU, J.; XIE, Y.; YANG, Z.; ZHUANG, D.; NIU, Z. Analysis of spatio-temporal dynamic pattern and driving forces of urban land in China in 1990s using TM images and GIS. **Cities**, v. 22, n. 6, p. 400-410, 2005.

TOFANI, V.; HONG, Y.; SINGHROY, V. Introduction: Remote Sensing Techniques for Landslide Mapping and Monitoring. **Landslide Science for Safer Geoenvironment**, p. 301-303, 2014.

TOLEDO, J.M.A. Crop Discrimination Using Harmonic Analysis of EVI Modis Time-Series Data. 2008. 150 p. **Dissertação** (Mestrado) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2008.

TRALLI, D. M.; BLOM, R. G.; ZLOTNICKI, V.; DONNELLAN, A.; EVANS, D. L. Satellite remote sensing of earthquake, volcano, flood, landslide and coastal inundation hazards. **Journal of Photogrammetry & Remote Sensing**, v. 59, p. 185-198. 2005.

TRICART, J. **Introduction to climatic geomorphology**. Londres: Longman, 1972. 295 p.

TRIMBLE. **eCognition Developer 8**. Copyright © Trimble Germany GmbH, 2009.

TSO, G.K.F.; YAU, K.K.W. Predicting electricity energy consumption: a comparison of regression analysis, decision tree and neural networks. **Energy**, v. 32, n. 9, p. 1761–1768, 2007.

TUCKER, G.E.; CATANI, F.; RINALDO, A.; BRAS, R.L. Statistical analysis of drainage density from digital terrain data, **Geomorphology**, v. 36, n. 3-4, p. 187-202, 2001.

VALERIANO, M.M. Curvatura vertical de vertentes em microbacias pela análise de modelos digitais de elevação. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 7, n. 3, p. 539-546, 2003a.

VALERIANO, M.M. Mapeamento da declividade em microbacias com sistemas de informação geográfica. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 7, n. 2, p. 303-310, 2003b.

VALERIANO, M.M. Programação do cálculo da declividade em SIG pelo método de vetores ortogonais. **Espaço e Geografia (UnB)**, Brasília, DF, v. 5, n. 1, p. 69-85, 2002.

VALERIANO, M.M.; CARVALHO JÚNIOR, O.A. Geoprocessamento de modelos digitais de elevação para mapeamento da curvatura horizontal em microbacias. **Revista Brasileira de Geomorfologia**, v. 4, n. 1, p. 17-29, 2003.

VALERIANO, M.M.; ROSSETTI, D.F. Topodata: Brazilian full coverage refinement of SRTM data. **Applied Geography (Sevenoaks)**, v. 32, p. 300-309, 2011.

VANACÔR, R.N.; ROLIM, S.B.A. Mapeamento da suscetibilidade a deslizamentos usando técnicas de estatística bivariada e sistema de informações geográficas na região nordeste do Rio Grande do Sul. **Revista Brasileira de Geomorfologia**, v. 13, n. 1, 2012.

VAPNIK, V. The nature of statistical learning theory. New York: Springer-Verlag. 1995. 314 p.

VEDOVELLO, R. Zoneamento geotécnico, por sensoriamento remoto, para estudos de planejamento do meio físico - aplicação em expansão urbana. 1993. **Dissertação** (Mestrado) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1993.

VEDOVELLO, R.; MATTOS, J.T. Zoneamento geotécnico, por Sensoriamento Remoto, para estudos de planejamento do meio físico – Aplicação em expansão urbana. In: Simpósio Brasileiro de Sensoriamento Remoto, 7., Curitiba, 1993. **Anais...** São José dos Campos: INPE. 1993. p. 155-162.

VENEZZIANI, P.; ANJOS, C.E. **Metodologia de interpretação de dados de sensoriamento remoto e aplicações em geologia**. São José dos Campos: INPE. 1982. 61 p.

WANA, S.; LEI, T.C. A knowledge-based decision support system to analyze the debris-flow problems. at Chen-Yu-Lan River, **Knowledge-based System**, v. 22, p. 580–588, 2009.

WANG, H.; ZHANG, Y.; HU, H. A Study on the relationship between the occurrence of Landslides and Rainfall. In: International Conference on Electric Technology and Civil Engineering, 2., 2012, Washington D.C.. **Anais...** Washington D.C.: IEEE Computer Society, 2012. p. 200-203.

WASKE, B.; VAN DER LINDEN, S.; BENEDIKTSSON, J.A.; RABE, A.; HOSTERT, P. Sensitivity of support vector machines to random feature selection in classification of hyperspectral data. **IEEE Transactions on Geosciences Remote Sensing**, v. 48, p. 2880–2889, 2010.

WASKE, B.; VAN DER LINDEN, S.; OLDENBURG, C.; JAKIMOW, B.; RABE, A.; HOSTERT, P. imageRF – A user-oriented implementation for remote sensing image analysis with Random Forests. **Environmental Modelling & Software**, v. 35, p. 192-193, 2012.

WERNER, M. Shuttle Radar Topography Mission (SRTM), Mission Review. **J. Telecom (Frequenz)**, v. 55, p.75-79, 2001.

WOLLE, C.M. Análise dos escorregamentos translacionais numa região da Serra do Mar no contexto de uma classificação de mecanismos de instabilização de encostas. 1988, 800 p. **Tese** (Doutorado) – Escola Politécnica da Universidade de São Paulo, São Paulo, 1988.

WOŹNIAK, M.; GRAÑA, M.; CORCHADO, E. A survey of multiple classifier systems as hybrid systems. **Information Fusion**, v. 16, p. 3-17, 2014.

WU, F.; ZHAN, J.; YAN, H.; SHI, C.; HUANG, J. Land cover mapping based on multisource spatial data mining approach for climate simulation: a case study in the farming-pastoral ecotone of North China. **Advances in Meteorology**, Online, 2013.

WU, W.; GAO, G. Remote Sensing Image Classification with Multiple Classifiers Based on Support Vector Machines. In: Fifth International Symposium on Computational Intelligence and Design (ISCID), 2012, Hangzhou. **Anais...**, Los Alamitos: IEEE Computer Society, 2012. p. 188-191.

WU, X.; FU REN, F.; NIU. R. Landslide susceptibility assessment using object mapping units, decision tree, and support vector machine models in the Three Gorges of China. **Environmental Earth Sciences**, v. 71, n. 11, p. 4725-4738. 2014.

XU, C. Preparation of earthquake-triggered landslide inventory maps using remote sensing and GIS technologies: Principles and case studies. **Geoscience Frontiers**. 2014.

XU, L.; KRZYŻAK, A.; SUEN, C.Y. Methods of combining multiple classifiers and their applications to handwriting recognition. **IEEE Transactions on Systems Man Cybernetics**, v. 22, p. 418–435, 1992.

YANG, W.; WANG, M.; SHI, P. Using MODIS NDVI time series to identify geographic patterns of landslides in vegetated regions. **IEEE Geoscience and Remote Sensing Letters**, v. 10, n. 4, p. 707-710, 2013.

YAO, X.; THAM, L.G.; DAI, F.C. Landslide susceptibility mapping based on support vector machine: a case study on natural slopes of Hong Kong, China. **Geomorphology**, v. 101, p. 572–582, 2008.

YILMAZ, I. Comparison of landslide susceptibility mapping methodologies for Koyulhisar, Turkey: conditional probability, logistic regression, artificial neural networks, and support vector machine. **Environmental Earth Science**, v. 61, p. 821-836, 2010.

YOUSSEF, A.M.; PRADHAM, B.; HASSAN, A.M. Flash floods risk estimation along the St. Katherine road, southern Sinai, Egypt using GIS based morphometry and satellite imagery. **Environmental Earth Sciences**, v. 62, n. 3, pp. 611-623, 2011.

ZHAO, J.; LIU, C. Monitoring dynamic change of land cover based on SVM and Satellite Images in Hanoi, Vietnam. **Wuham University Journal of Science**, v. 15, n. 4, p. 355-362, 2010.