

**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Mapeamento granulométrico do solo via imagens de satélite
e atributos de relevo**

Caio Troula Fongaro

Dissertação apresentada para obtenção do título de Mestre
em Ciências. Área de concentração: Solos e Nutrição de
Plantas

**Piracicaba
2015**

Caio Troula Fongaro
Engenheiro Agrônomo

**Mapeamento granulométrico do solo via imagens de satélite
e atributos de relevo**

Orientador:
Prof. Dr. **JOSÉ ALEXANDRE MELO DEMATTÊ**

Dissertação apresentada para obtenção do título de Mestre
em Ciências. Área de concentração: Solos e Nutrição de
Plantas

Piracicaba
2015

**Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA - DIBD/ESALQ/USP**

Fongaro, Caio Troula
Mapeamento granulométrico do solo via imagens de satélite e atributos de relevo /
Caio Troula Fongaro. - - Piracicaba, 2015.
106 p. : il.

Dissertação (Mestrado) - - Escola Superior de Agricultura "Luiz de Queiroz".

1. Sensoriamento remoto 2. Mapa de solos 3. Quantificação I. Título

CDD 631.47
F674m

"Permitida a cópia total ou parcial deste documento, desde que citada a fonte – O autor"

Dedico,

A minha família.

AGRADECIMENTOS

A Deus, pelo dom da vida;

Ao Professor Dr. José Alexandre Melo Demattê pela orientação, ensinamento, amizade, apoio e confiança;

Ao Me. Rodnei Rizzo pelo apoio, amizade, e fundamental colaboração que permitiu a realização deste trabalho;

Ao contribuinte paulista por prover recursos para excelência da Universidade de São Paulo;

Ao Departamento de Ciência do Solo pela oportunidade de realização do curso de pós-graduação;

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de estudo concedida;

Ao Dr. Luiz Eduardo Vicente, da EMPRAPA Monitoramento por Satélite, pela colaboração com as correções atmosféricas das imagens de satélite.

A Dra. Shruti Khanna, da UC Davis, pela colaboração técnica.

Aos colegas e amigos do GEOCIS, atuais e ex-participantes, em especial Bruna Gallo, Marco Bortoletto, Marston Franceschini, Matheus Vinícios Rodrigues e Veridiana Sayão, que participaram diretamente da elaboração deste projeto;

Aos amigos da República Boi Babão;

A Raizen por permitir o uso da área em estudo;

A FAPESP pelo apoio financeiro no uso do espectroradiômetro;

A Luiz Vicente de Souza Queiroz (*in memoriam*), que idealizou uma Escola Agrícola na Fazenda São João da Montanha;

Muito obrigado!

SUMÁRIO

RESUMO.....	9
ABSTRACT	11
LISTA DE FIGURAS.....	13
LISTA DE TABELAS.....	15
1 INTRODUÇÃO	17
Referências	18
2 IMAGENS MULTITEMPORAIS DO SATALITE LANDSAT 5 NA DETERMINAÇÃO DE AREAS CONTINUAS COM SOLO EXPOSTO (MUBASII) ..	19
Resumo	19
Abstract.....	19
2.1 Introdução.....	20
2.2 Material e Métodos.....	24
2.2.1 Área de estudo	24
2.2.2 Definição dos locais de coleta	24
2.2.3 Aquisição de série temporal de imagens TM – Landsat 5 e processamento	25
2.2.4 Obtenção de solo exposto.....	25
2.2.5 Obtenção da imagem composta de solo exposto.....	27
2.2.6 Obtenção de espectros de laboratório, orbitais e análises granulométricas convencionais	28
2.2.7 Comparação dos espectro de laboratório com orbital de solo exposto.....	28
2.3 Resultados e Discussão.....	29
2.3.1 Solos da área.....	29
2.3.2 Diferenciação de alvos.....	30
2.3.3 Comparação de dados orbitais e terrestres	32
2.3.4 Cores nas imagens de satélite e solo exposto	33
2.3.5 Solo exposto em imagens de satélite multitemporais.....	34
2.3.6 Considerações finais	37
2.4 Conclusões.....	38
Referências	53
3 DETERMINAÇÃO E MAPEAMENTO GRANULOMÉTRICO BASEADO EM IMAGENS DE SATÉLITE E ATRIBUTOS DO TERRENO	60
Resumo	60
3.1 Introdução.....	61
3.2 Material e Métodos.....	65

3.2.1 Área de estudo.....	65
3.2.2 Definição dos locais de coleta.....	66
3.2.3 Aquisição de série temporal de imagens TM – Landsat 5 e processamento.....	66
3.2.4 Obtenção de solo exposto	67
3.2.5 Obtenção da imagem composta de solo exposto	68
3.2.6 Atributos do terreno	69
3.2.7 Outras variáveis utilizadas	70
3.2.8 Atributos de solo - textura.....	70
3.2.9 Modelagem – Cubist	71
3.2.10 Validação	72
3.2.11 Espacialização	73
3.2.12 Interpolação.....	73
3.3 Resultados e Discussão.....	74
3.3.1 Caracterização granulométrica dos solos da área.....	74
3.3.2 Quantificação dos teores de argila via relevo	74
3.3.3 Quantificação dos teores de argila via imagens de satélite.....	75
3.3.4 Quantificação de argila e areia via imagens, relevo e geomorfologia	77
3.3.5 Estudos de casos no mapeamento granulométrico	78
3.3.6 Considerações gerais	80
3.4 Conclusões.....	84
Referências.....	98

RESUMO

Mapeamento granulométrico do solo via imagens de satélite e atributos de relevo

O planeta terra tem grande dimensão, e seus recursos naturais precisam ser mapeados e conhecidos para nortear políticas públicas. O solo é um destes importantes recursos. O seu conhecimento passa pela caracterização e mapeamento pedológico e/ou de seus atributos. Para o adequado monitoramento, é necessário o conhecimento em escala detalhadas. Isto demanda recursos humanos, altos custos financeiros e de logística. Fato este ainda difícil de se atingir. Logo, é preciso investir em tecnologias que auxiliem na rápida obtenção de informações de qualidade, à baixo custo. Tendo em vista as áreas agrícolas da região de estudo, os objetivos deste trabalho foram: (i) definir uma metodologia que identifique em imagens de satélite, locais de o solo exposto; (ii) Mapear os teores granulométricos através de imagens de satélite e atributos do relevo, utilizou-se das imagens compostas do tópico (i). A área de estudo localiza-se na região de Araraquara, São Paulo, Brasil, com dimensão de 14.614 km². Dentro desta área foram demarcados 952 pontos para coleta de amostras de terra na camada superficial, as quais foram georreferenciadas e analisadas granulometricamente em laboratório. Sua demarcação seguiu os preceitos do método da topossequência com o intuito de representar a variabilidade da região. Foram obtidas imagens do satélite Landsat 5 (sensor TM) multitemporais as quais foram processadas e transformadas em reflectância. As amostras de terra coletadas em campo passaram por sensor em laboratório (400-2500 nm), os espectros laboratoriais foram utilizados para validar aqueles obtidos nas imagens de satélite. Para tanto, nos locais onde foram coletadas as amostras, foram extraídos os dados espectrais dos pixels perfazendo os gráficos das curvas espectrais. Estas foram comparadas com os dados de obtidos em laboratório simulados. Feita a correlação, as imagens passaram por processos de eliminação de objetos que não fossem solo. Todas as imagens multitemporais foram finalizadas contendo apenas solo exposto, as quais dentro do software R foram sobrepostas e gerou-se uma imagem composta, com apenas solo exposto. Os resultados mostraram que as curvas espectrais de laboratório foram extremamente semelhantes aos das imagens de satélite, seguindo a lógica das variações texturais. Além disso, as técnicas de componentes principais e relação entre bandas 3-4, 5-7, e correlação entre bandas (sendo a mais expressiva com r de 0,87 entre TM7), comprovaram que a imagem apresentou solo exposto. Se um usuário utilizar-se somente uma imagem para estudar solos, teria na faixa de 4% de solo exposto, porém utilizando a técnica de composição de imagens, atingiria 43%. Não obstante, se a área de estudo fosse 100 % com agricultura poderia atingir 95% de solo exposto. Num segundo momento, o trabalho comprova, com o modelo Cubist, que tanto por imagens de satélite quanto por relevo foi possível quantificar os teores de argila da área da camada superficial, atingindo R² de ≈0,65. No entanto, a qualidade visual do mapa gerado por relevo é ruim. Porém, quando se integra dados de imagens, relevo e geomorfologia, este resultado é de 0,72 e apresenta o melhor resultado visual.

Palavras chave: Sensoriamento remoto; Mapa de solos; Quantificação

ABSTRACT

Mapping topsoil texture by satellite image and relief

Planet Earth has great dimension, and its natural resources has to be mapped and monitored, looking towards correct decisions. Soil is one of these important resources. Know soils is related with its characterization and mapping by pedological and attributes recognition. For soil monitoring, its necessary maps in large scale, which demand man power and high cost. Thus, its necessary to invest in geotechnologies, to reach the goal faster and low cost. The objective of this work was to determine a method to determine exposed soils in satellite images, even when have vegetation, taking in account a multitemporal dataset, in agricultural areas, where as in a given season will have exposed soils. b. quantify clay and sand contents by satellite images and relief attributes. The area is located in Araraquara, SP, Brazil, with a 14.614 km² dimension. We collected soil samples all over the area with a total of 952 points and 0-20 cm depth, georeferenced, representative of the area. Samples were granulometric analysed and afterwards passed through a vis-nir-swir sensor (400-2500 nm). We collected multitemporal images from landsat satellite from september and october n the last 15 years. Images were atmospheric corrected and transformed into reflectance. Laboratory spectral data was used to validate pixels spectra information from satellite. We extracted all objects which were not soils from all images. Using R software, we merged the multitemporal images and performed a unique bare soil image. Also, we made processing on the DEM of the área reaching several soil attribute factors. Results indicated as follows: a. labortory spectral curves validated satellite data; b) principal componentes and relation between bands 3/4 and 5/7 reached great R² until 0,87 between laboratory and satellite data; d) a user could reach 1,21% of na image with bare soil, while with our method could reach 43% in the entire image. On the other hand, if the user have only agriculture area, could reach until 95% with bare soil. In a second step of this work, we prove that by regression tree statistics, clay and sand content can be quantified by satellite images with a 0,62 of R², as also with terrain atributs. On the other hand, when we associate image spectral data with terrain atributs, we can reach 0,72 on clay quantification. Despite this, the visual aspecto of data, is better using image data than relief , which presented more noise. Another conclusion, is that images could substitute geology information in the models. This work can considerably assist pedologists, farmers and environment professionals on soil monitoring.

Keywords: Remote sensing; Soil mapping: Quantification

LISTA DE FIGURAS

Capítulo 2

- Figura 1 - Sequência metodológica para obtenção da imagem composta de solo exposto..... 40
- Figura 2 - Ilustração de (a) variabilidade textural, 1 muito argiloso, 2 argiloso, 3 médio-argiloso, 4 médio-arenoso, 5 arenoso, 6 muito arenoso, (b) química, 1 eutrófico, 2 epieutrófico, 3 distrófico, 4 álico, 5 ácrico, 6 alumínico, 7 alítico, (c) classe de solos, RQ, Neossolo Quartzarênico; NVf, Nitossolo Vermelho férrico; LV, Latossolo Vermelho; PV, Argissolo Vermelho; LVf, Latossolo Vermelho férrico; LVA, Latossolo Vermelho-Amarelo..... 41
- Figura 3 - (a) Dados espectrais obtidos para diferentes alvos, (b) MIDII para diferentes alvos, sendo cinco ocorrências para cada, (c) NDVI para diferentes alvos, sendo cinco ocorrências para cada, (d) Relação entre as bandas TM7 e TM5, (e) Relação entre as bandas TM4 e TM3 42
- Figura 4 - (a) Dados espectrais de diferentes classes solos obtidos em laboratório e satélite, onde AQ = Neossolo Quartzarênico; PV = Argissolo Vermelho; LE = Latossolo Vermelho; PE = Argissolo Vermelho Escuro; TR = Nitossolo Vermelho férrico; LR = Latossolo Vermelho férrico (Demattê et al., 2009) (b) Dados espectrais obtidos em laboratório de diferentes classes texturais (FRANCESCHINI et al., 2013); (c) resposta espectrais de diferentes alvos, onde L = Lignina; K = Caulinita; G = Gibbsita; A = água; H = hematita 43
- Figura 5 - (a) comparação de espectros entre solos arenosos e argilosos obtidos ao nível laboratório l e relação com as bandas do satélite Landsat 5 (b) relação entre as bandas TM4 e TM3 entre laboratório e orbital com as 639 amostras, (c) comparação entre as bandas TM7 e TM5 entre laboratório e orbital com as 639 amostras..... 44
- Figura 6 - Componentes principais (PC1 vs PC2) das amostras e classes texturais (a) obtidos em laboratório, (b) obtidos em satélite, (c) comparativo entre satélite e laboratório. 45
- Figura 7 - Correlação entre PC1s orbitais e laboratório 46
- Figura 8 - (a) bandas específicas do minerais hematita e goethita, (b) ilustração da composição de cores, (c) Exemplos de valores da imagem e relação com realce, (d) bandas do landsat e faixas espectrais, (e) exemplo de histograma de cores RGB para alteração e realce, (f) exemplos de imagem sem e (g) com realce de composição 543, RGB. 477
- Figura 9 - (a) curva espectral solo exposto argiloso, (b) histograma RGB, (c) alteração da curva espectral no sistema RGB após realce, (d) reflectância óxido, (e) solo exposto púrpura (arroxeadado) após o realce. 477
- Figura 10 - Comparação de casos desde a imagem inicial, passando pela fase de mascaramento até a seleção de áreas com solo exposto..... 488
- Figura 11 - Imagem de satélite multitemporal com 43% de solo exposto e respectivos detalhamentos. 499
- Figura 12 - (a) Curvas espectrais médias obtidas em laboratório (400-2500 nm) simulados para o landsat TM, (b) curvas espectrais obtidas pelos pixels da imagem landsat TM, (c) curvas inseridas graficamente de maneira comparativa (laboratório e orbital). 50

Capítulo 3

- Figura 1 - Ilustração da área de estudo, da distribuição das análises de solo no diagrama textural e dos locais com pontos de observação no campo 85
- Figura 2 - Sequência metodológica 86
- Figura 3 - Distribuição dos valores de análise granulométrica, de um total de 688 amostras 87
- Figura 4 - Predições modelo relevo (a) mapa de argila, (b) mapa de areia, (c) predição argila, (d) triângulo textural com dados mensurados e preditos, onde C = Arenosa, MF = Siltosa, M = Média, F= Argilosa e VF = Muito Argilosa (e) predição areia..... 88
- Figura 5 - Contribuição das variáveis para os modelos, para as condicionais e regressões (a) Argila relevo, (b) areia relevo, (c) argila imagem, (d) areia imagem, (e) argila imagem + relevo, (f) areia imagem + relevo... 89

- Figura 6 - Predições modelo imagem (a) mapa de argila, (b) mapa de areia, (c) predição argila, (d) triângulo textural com dados mensurados e preditos, onde C = Arenosa, MF = Siltosa, M = Média, F= Argilosa e VF = Muito Argilosa (e) predição areia..... 90
- Figura 7 - Predições modelo imagem + relevo (a) mapa de argila, (b) mapa de areia, (c) predição argila, (d) triângulo textural com dados mensurados e preditos onde C = Arenosa, MF = Siltosa, M = Média, F= Argilosa e VF = Muito Argilosa (e) predição areia. 91
- Figura 8 - Modelagem a partir dos dados de imagens de satélite Landsat associados aos atributos do relevo e geomorfologia, e ainda com mapeamento interpolado em áreas não agraciadas (a) mapa dos teores de argila, (b) mapa dos teores de areia, (c) exemplo de área com parte mapeada e parte não mapeada (áreas em branco), juntamente com pontos de localização de amostragem no campo para validação (em vermelho), (d) mesma área do item c, porém inteiramente mapeada por interpolação das áreas em branco, (e) correlação entre os pontos de campo das áreas mapeadas via interpolação para argila, (f) correlação entre os pontos de campo das áreas mapeadas via interpolação para areia..... 92
- Figura 9 - Estudo de caso. (a) área com imagem de satélite de alta resolução, cor verdadeira, indicando a classificação textural. Áreas não indicadas não puderam ser mapeadas, (b) áreas mapeadas por interpolação usando modelo imagem + relevo. Pontos em vermelho indicam locais de solos com textura arenosa validados no campo. 93
- Figura 10 - Estudo de caso. (a) imagem do modelo numérico de elevação, (b) imagem do mapa geológico (CPRM, 2006), (c) imagem do mapa geomorfológico (CPRM, 2009), com detalhamento comparativo com mapa textural..... 944

LISTA DE TABELAS

Capítulo 2

Tabela 1 - Análise estatística das análises granulométricas das amostras da área de estudo.....	51
Tabela 2 - Matriz de correlação entre bandas simulada de laboratório e orbitais.....	51
Tabela 3 - Valores de área de solo exposto obtidas nas imagens do satélite landsat e respectivas datas	52

Capítulo 3

Tabela 1 - Análise estatística dos dados granulométricos	954
Tabela 2 - Percentagem de ocorrência das classes texturais.....	954
Tabela 3 - Resumo da quantificação de atributos do solo via espectroradiômetro (Resumido de DEMATTE et al., 2015).....	965
Tabela 4 - Resumo da quantificação de atributos do solo via plataformas espaciais (Resumido de Demattê et al., 2015).....	976

1 INTRODUÇÃO

O mundo tem dimensões territoriais muito grandes sendo imperativo conhecer seus recursos naturais para poder preservá-los, monitorá-los e explorá-los. Não há recursos humanos e financeiros suficientes para realizar mapeamentos de todas as áreas em escala compatível com as necessidades atuais. Os processos de degradação e a pressão agrícola estão ocorrendo rapidamente, e as políticas públicas necessitam de informações para tomada de decisões.

O sensoriamento remoto tem se mostrado uma das mais importantes ferramentas no auxílio desta tarefa haja visto obter informações remotamente e cujos resultados tem relação física com as características do objeto (BEN-DOR et al., 2009). Dados de sensoriamento remoto obtidos em laboratório (STENBERG et al., 2010, TERRA; DEMATTÊ & VISCARRA, 2015), comprovam existir uma relação intrínseca entre o alvo solo, e a energia que interage e reflete, expressando os atributos ou características que compõem o alvo. Dentre estes atributos, a argila é um dos componentes com maior representatividade conforme inúmeros trabalhos realizados (SORIANO-DISLA et al., 2014).

Por outro lado, não se tem uma metodologia que indique como usar as imagens de satélite para visualizar a superfície dos solos de maneira contínua. Pedólogos e profissionais em manejo de solo necessitam desta informação para distinguir detalhadamente os limites entre os tipos de solos ou variações dos atributos. Da mesma forma, a quantificação de argila tem sido relatada via imagens de satélite ou via atributos do relevo (NANNI & DEMATTÊ, 2006; BRUIN e STEIN, 1998), mas nenhuma usando o seu conjunto no modelo, nem mesmo de forma contínua como aqui proposta.

Neste aspecto, o presente trabalho tem por objetivos determinar uma metodologia que expresse o solo exposto de maneira contínua em grandes áreas agrícolas, permitindo uma visão geral da situação da superfície do solo, através de imagens de satélite. Outro objetivo é avaliar o potencial de predição de argila via imagens de satélite e atributos do relevo. Como hipótese supõe-se que os dados obtidos pelas imagens, quando com solo exposto, expressem as características físicas do solo, enquanto o relevo o fará de maneira a relacionar com os fatores e processos de formação do solo. Também se espera que, quando se observa uma única imagem, pouco se terá de solo exposto, enquanto que, com imagens multitemporais, as áreas de solo exposto encontradas em cada uma, se juntem numa única imagem, gerando um visão contínua e geral da situação do solo.

Referências

BEN-DOR, E.; CHABRILLAT, S.; DEMATTE, J.; TAYLOR, G.; HILL, J.; WHITING, M.; SOMMER, S. Using Imaging Spectroscopy to study soil properties. **Remote Sensing of Environment**, New York, v. 113, p. S38-S55, 2009.

DE BRUIN, S.; STEIN, A. Soil-landscape modelling using fuzzy c-means clustering of attribute data derived from a digital elevation model (DEM). **Geoderma**, Amsterdam, v. 83, n. 1, p. 17-33, 1998.

NANNI, M. R.; DEMATTÊ, J. A. M. Spectral reflectance methodology in comparison to traditional soil analysis. **Soil Science Society of America Journal**, Madison, v. 70, n. 2, p. 393-407, 2006

SORIANO-DISLA, J.M.; JANIK, L.J.; VISCARRA ROSSEL, R.A.; MACDONALD, L. M.; MCLAUGHLIN, M.J. The performance of visible, near-, and mid-infrared reflectance spectroscopy for prediction of soil physical, chemical, and biological properties. **Applied Spectroscopy Reviews**, Philadelphia, v. 49, n. 2, p. 139-186, 2014.

STENBERG, B.; ROSSEL, R.A.V.; MOUAZEN, A.M.; WETTERLIND, J. Chapter five-visible and near infrared spectroscopy in soil science. **Advances in Agronomy**, Newark, v. 107, p. 163-215, 2010.

TERRA, F.S.; DEMATTÊ, J. A.M.; VISCARRA R., RAPHAEL, A. Spectral libraries for quantitative analyses of tropical Brazilian soils: Comparing vis-NIR and mid-IR reflectance data. **Geoderma**, Amsterdam, v. 255/256, p. 81-93, 2015.

2 IMAGENS MULTITEMPORAIS DO SATALITE LANDSAT 5 NA DETERMINAÇÃO DE AREAS CONTINUAS COM SOLO EXPOSTO (MUBASII)

Resumo

Existe uma necessidade premente na viabilização do uso de imagens de satélite, para mapear grandes áreas de solos. Porém, muitas das áreas encontram-se vegetadas o que dificulta a identificação das informações do solo. Face ao exposto, o presente trabalho tem por objetivo desenvolver uma metodologia que permita identificar e mapear grandes áreas com solo exposto. O trabalho foi realizado na região de Araraquara, Estado de São Paulo, num polígono aproximado de 14.614 km². Obtiveram-se padrões de solos na camada superficial (0-20 cm), num total de 952 amostras coletadas e georreferenciadas, distribuídas ao longo da área pelo método da topossequência. As amostras foram analisadas quanto a granulometria e obtidos os dados espectrais por sensor em laboratório (350-2500 nm). Foram obtidas imagens de satélite TM/Landsat de um período de 15 anos, nos meses de junho a outubro. As imagens foram atmosféricamente corrigidas e transformadas em reflectância. Calculou-se NDVI, MIDII, razão das bandas TM1-TM2, TM3-TM2, gráficos de dispersão entre bandas, os quais auxiliaram eliminar das imagens dados que não fossem solo. As imagens foram sobrepostas e obteve-se uma única imagem com solo exposto. Foi possível discriminar solos com diferentes classes texturais. Os dados espectrais de laboratório foram compatíveis com os obtidos pelo satélite Landsat 5, sendo assim validados. Foi possível eliminar das imagens objetos que não fossem solos tais como, vegetação verde, vegetação senescente e palhada. As análises de linha do solo pelas bandas TM3; TM4 e TM5; TM7 foram sensíveis na comparação entre dados de satélite e laboratório, permitindo sua validação. Os dados de componentes principais discriminaram adequadamente os pixels com diferentes classes texturais, tanto ao nível laboratório quanto de satélite. A imagem composição 543, RGB, foi extremamente útil na discriminação e caracterização de solo exposto na referida região. Foi possível atingir uma correlação de $\approx 0,82$ para as bandas TM5 e TM7 com dados de laboratório, ratificando a correlação entre os dados. Com uma única imagem, um usuário poderia ter apenas 1,21 % de solo exposto, enquanto com a referida metodologia, pode-se atingir até 43,5 %. Por outro lado, se considerar apenas as áreas agrícolas, pode-se atingir até 95% de solo exposto. A metodologia permite concluir que é possível obter áreas de solo exposto em grandes áreas, mesmo que vegetadas, desde que tenham áreas agrícolas em algum momento. A metodologia foi validada pelos espectros semelhantes entre laboratório e do satélite e ainda os dados estatísticos. Tal procedimento pode auxiliar em várias frentes tais como mapeamento e caracterização pedológico, mapeamento de atributos do solo, avaliação de erosão do solo, agricultura de precisão entre outras aplicações.

Palavras-chave: Landsat 5; Argila; Quantificação; Imagens satélite

Abstract

There exist a necessity to use satellite images to map soils. Although, many of the areas are with vegetation which makes difficult to use this product. The objective of this work was to develop a methodology to identify exposed soils in satellite images in a continuous for great areas, and consequently quantify soil attributes. The work was realized in the region of Araraquara, SP, Brazil, in a 14.614 km² polygon. The area present a heterogen geology based on sandstone and basalt. We realized field work to collect 952 soil samples from 0-20 cm depth

all georeferenced and afterwards analysed in laboratory. Also they were analysed in a vis-nir-swir sensor (350-2500 nm). Multitemporal Landsat images were acquired for 15 years september and october from each year. The images were processed, atmospheric corrected and transformed into reflectance. IN ENVI software we made several strategies to extract targets which were not soils such as, NDVI, bands TM1-TM2, TM3-TM2, scatter plot between bands 3/4 and 5/7. Each image presented exposed soil. Using R software, the images were superposed and we obtained only one unique image with exposed soil for all the region. It was possible to discriminate soil textures by laboratory spectra and these were greatly correlated with satellite data. It was possible to eliminate targets such as straw, green vegetation, water and others, leaving only soils in each image. Soil line methods by bands 3/4 and 5/7 validated ground with satellite data. Principal componentes discriminated soil textures by satellite data. The composition 543, RGB was importante to determine exposed soils. We reached a 0,82 correlation between several bands and specifically bands 5 and 7 between laboratory and satellite spectra. With one unique image the user would have only 1,21% of exposed soil to analyse, while with our method we reached 43,5%. If the user use the method in a agriculture area, he can reach until 95%. The methodology allow to conclude that, even with vegetation in agriculture areas, we can reach soil information, since these are agriculture areas. This procedure can assist on pedological and attribute mapping, soil conservation and management, precision agriculture, and soil monitoring.

Keywords: Landsat 5; Clay; Quantification; Satellite images

2.1 Introdução

O mundo vem passando por transformações climáticas, as quais podem estar relacionadas às alterações antropogênicas (ORESQUES, 2004). Dentre essas ações, uma de grande relevância trata das alterações do uso da terra (KALNAY & CAI, 2003). De acordo com Skole & Tucker (1993), a Amazônia do Brasil, por exemplo, desmatou o equivalente a 152.000 km² em 10 anos. No final da década de 1960 agricultores da região centro sul iniciaram o desbravamento do cerrado (HENZ et al., 2010), um importante bioma brasileiro, com área estimada de 2.036.448 km² (MMA, 2015), este foi já substituído em parte, (35,8% área antropizada até 1996, IBGE, 1997) pela moderna agropecuária com destaque para produção de grãos. De fato, estados antes intocados como o MS, também tem recebido forte pressão pela agricultura intensiva (ALHO & MARTINS, 1995; BUOL, 2009). Tais alterações de uso provocam diversas reações na natureza tais como, assoreamento de rios e erosão (PIMENTEL et al., 1987).

Existe uma crescente pressão para elevação da produção de alimento, essa necessidade de aumento na produção de alimentos se justifica pelo constante aumento da população mundial, que era de 2,5 bilhões em 1950, passou a 7,3 em 2015 e projeta-se para 9,7 bilhões em 2050, ou seja, um aumento de quase quatro vezes em 100 anos (FAOSTAT, 2015).

De fato, a pressão agrícola já atinge países ainda poucos explorados neste sentido (CLEMENTS e FERNANDES, 2013).

Se por um lado existe a necessidade imperativa em produzir alimentos, por outro, não se sobrevive com a destruição ambiental. Nesse aspecto o solo tem participação importante, pois trata do meio suporte e desenvolvimento, além de se relacionar com as questões ambientais. Lal (2004) indica a importância do solo em questões de estoque de carbono, erosão e segurança alimentar.

Sabe-se há gerações que o solo tem inúmeras funções na natureza tais como: meio de crescimento para plantas; regulador do abastecimento de água; reciclador de matérias primas; agente modificador da atmosfera; habitat para seus organismos; meio para obras de engenharia (BRADY e WEIL, 2013). Devido ao importante papel dos solos e a elevada pressão para aumentar a produção de alimento, nos questionamos: Como preservar os solos e aumentar a produção alimentos em alta proporção? Só se pode preservar o solo se conhecermos o seu funcionamento, a dinâmica dos fluxos d'água por ele regidos. Para tanto, é preciso conhecer mais características tais como profundidade, textura, fertilidade, capacidade de retenção de água, drenagem, relevo, estrutura, agregação entre outros. Um método importante no sentido de agregar, num único nome, todas as características é a classificação taxonômica. Várias são as utilizadas como a Brasileira (EMPRAPA, 2013), a americana (SOIL SURVEY STAFF, 2014) e WRB (IUSS Working Group WRB, 2014). A utilização de sistemas de classificação permite agrupar indivíduos “solos” com características semelhantes, facilitando a sua identificação, comunicação entre pessoas e mapeamento.

O mapeamento de solos sempre foi reconhecido como a melhor forma de planejar o uso da terra. Vink (1963) já alertava sobre essa importância, reiteradamente ratificada por várias décadas (YOUNG, 1973; MCCORMACK, 1974; ZONNEVELD, 1989; SCHULER et., 2006).

O mapeamento de solos auxilia na tomada de decisões sobre quais solos são mais adequadas para culturas e quais devem ser preservadas. Além disso, permite tomar na sua proteção e preservação. A relação entre tipos de solos e produtividade agrícola, também está fortemente estabelecida. Portanto, conhecer a distribuição espacial dos solos é básico para seu melhor uso.

O mapa de solos é um produto trabalhoso, caro e de difícil obtenção (WAISER et al., 2007). Tal fato é justificado pelo pouco que conhecemos da Terra. Em todo o globo, tem-se mapas de solos, mas em nível incompatível com o manejo agrícola. No Brasil por exemplo, apenas 0,25% do território está mapeado em escala 1:20.000 (MENDONÇA-SANTOS, 2006).

Exceção, os EUA são o único país no mundo a apresentar mapas desta natureza em grande parte do território (Soil Survey Staff, 2015). Outras informações de mapas e países encontram-se em IUSS (2014).

Devido às dificuldades desse trabalho, novas tecnologias vêm sendo desenvolvidas, sendo o mapeamento digital de solos a de maior repercussão internacional (MCBRATNEY; MENDONÇA-SANTOS & MINASNY, 2003). Essa tecnologia baseia-se nos fundamentos dos fatores SCORPAN, $S_a = f(s, c, o, r, p, a, n)$ Como se vê, passaram a participar do tema o s de atributos do solo e n de localização espacial. Neste sentido, a tecnologia do sensoriamento remoto (SR) participa do sistema, pela coleta de informações como os atributos do solo.

De fato, o SR vem fortemente estabelecido por fundamentos físicos que explicam as interações entre atributos do solo e a energia eletromagnética desde Baumgardner (1985) até Stenberg et al. (2010) e mais recentemente Ben Dor & Demattê (2015). Estes autores comprovam, através de literatura e pesquisas pessoais, a importância do SR no estudo do solo.

O SR pode ser avaliado por sensores em plataformas localizadas em várias posições em relação ao alvo, desde próximas como no campo até em satélites na órbita terrestre, cada qual com vantagens e desvantagens. A grande vantagem da plataforma orbital é a repetitividade temporal, o que facilita a obtenção de informações, as quais são muitas vezes disponibilizadas gratuitamente, além de ter o potencial para avaliar grandes áreas e de difícil acesso.

Para se estabelecer a utilidade das imagens orbitais no estudo de solos, certas pesquisas são primordiais. Neste aspecto, Coleman et al. (1991) tentaram quantificar teor de argila, obtendo 0,4 de R^2 . Naquela época já indicavam a necessidade de métodos de detecção de solo exposto. Neste sentido, trabalhos foram feitos tais como de Franceschini et al. (2015) e Demattê et al. (2009). Assim, a quantificação de atributos é realizada por sensores multiespectrais (MULDER et al., 2011) até por hiperespectrais (MULDER et al., 2011, FRANCESCHINI et al., 2015). Atualmente, o uso dos sensores hiperespectrais tem acesso restritivo, bem como muitos ainda são embarcados em aviões, ou ainda em processo de construção como o SHALOM de uma associação ítalo israelense (BEN-DOR et al., 2014)

Devido as dificuldades de uso e aquisição de dados hiperespectrais, os multiespectrais, e em particular o programa Landsat, são de fácil uso e gratuitos, facilitando para usuários. Logo, vários trabalhos na quantificação de atributos do solo com produtos Landsat foram realizados (DEMATTÊ et al., 2007 a, DEMATTÊ; FIORIO & BEN-DOR, 2009, FIORIO E DEMATTÊ, 2009, GHAEMI et al., 2013, MASOUD et al., 2014). Além disso,

alguns artigos estabelecem a relação entre informação da camada superficial do solo com sua classificação (DEMATTÊ et al., 2009, NANNI et al., 2012). Para chegar nestas conclusões, os trabalhos de correlação entre dados orbitais por sensores terrestres e o respectivo pixel com informação orbital são fundamentais (DEMATTÊ & NANNI, 2003, NANNI et al. 2012).

Portanto, a detecção de solos via satélite é um importante aliado no mapeamento digital de solos (MCBRATNEY et al., 2003; LAGACHERIE; MCBRATNEY & VOLTZ 2006). Por outro lado, os esforços têm sido no sentido de detectar o solo exposto na imagem (DEMATTÊ et al., 2009). De fato, a detecção do solo em imagens está bem estabelecida, porém, de maneira pontual, num único pixel. Ou seja, as técnicas simplesmente estabelecem em como descobrir se um local está ou não sem vegetação. Por outro lado, a maior parte da superfície do globo está coberta por vegetação natural, áreas urbanas, águas e áreas com manejo agrícola. O manejo agrícola, por sua vez, altera o sinal do solo natural como material orgânico (DEMATTÊ et al., 2006), adubação (DEMATTÊ et al., 2006) e restos agrícolas (DEMATTÊ et al., 2015)

A informação de um pixel pontual sobre o solo é importante. Entretanto, o solo se altera gradualmente na paisagem, o que nos leva a importância de ‘enxergar’ o solo como um continuum. As técnicas atuais, detectam o solo exposto, mas não exploram informações de grandes áreas expostas, para que permita ao intérprete, observar o continuum preconizado por McBratney & Gruijter (1992) e longamente sabido por pedólogos.

Como estabelecer uma técnica que permita “ver” o solo exposto em grandes áreas e de maneira contínua, sabendo que existem as questões de uso da terra? Em áreas com mata nativa preservadas em tempo integral tal objetivo é impossível. Por outro lado, em áreas agrícolas, muitas vezes, em algum momento, a terra foi preparada, e neste momento, ficou exposta podendo ser detectada. Não há nenhum artigo científico que tenha desenvolvido uma técnica via satélite, na detecção de áreas contínuas com solo exposto e geração de uma imagem composta. Tal técnica tem inúmeras implicações na agricultura e monitoramento ambiental e poderá melhorar os conceitos e mapas de solos existentes, levando a discussão sobre a possibilidade de alteração dos mesmos.

Face ao exposto, o objetivo do presente trabalho foi o de desenvolver uma técnica para obtenção de solo exposto em grandes áreas e de maneira contínua via imagem de satélite. Em áreas com atividade agrícola, espera-se que em algum momento o solo estará exposto para preparo, e como tal, imagens multitemporais, poderão montar um painel de áreas contínuas.

2.2 Material e Métodos

2.2.1 Área de estudo

A área localiza-se no interior do estado de São Paulo, sendo que o município de Araraquara está localizado em posição central do polígono de estudo e no total a área é composta por 55 municípios paulistas, sendo os principais Araraquara, Brotas e Guariba, ocupando 14.614 km².

O ponto central da área localiza-se a 21°49'53" de latitude sul e 48°7'5" de longitude oeste. O clima é Aw (Koppen), tropical com estação seca de inverno (ROLIM et al., 2007), com precipitação anual média de 1480 mm e temperatura média máxima de 28,1 °C e mínima de 15,2 °C. A altitude varia de 400 a 1080 m. A Geologia é composta das seguintes formações: Formação Botucatu – Grupo São Bento; Formação Serra Geral intrusiva e extrusiva; Formação Itaqueri; Formação Marília – Grupo Bauru; Formação Vale do Rio Peixe – Grupo Bauru; Formação Tatuí – Grupo Guatá; Formação Iratí – Grupo Passa Dois; Formação Corumbataí – Grupo Passa Dois; Formação Pirambóia; Depósitos aluvionares; Depósitos colúvio-eluvionares (CPRM, 2006).

Os solos desenvolvidos na região de acordo com EMBRAPA (2013) são predominantemente os Latossolos Vermelhos e Vermelho-Amarelo com textura de média a argilosa, férricos ou não; Argissolos Vermelho e Vermelho-Amarelo também com textura e gradiente variável; Neossolos Quartzarênicos e Nitossolos. A área é quase toda agriculturável, tendo a cana-de-açúcar como principal cultura, seguidas pelo reflorestamento de eucalipto, pomares de laranja e pastagens.

2.2.2 Definição dos locais de coleta

Primeiramente foi selecionada a cena do sensor TM do satélite Landsat 5 (TM/Landsat 5) com órbita ponto 220/75. Desta cena foi definida uma área de estudo com um total de 14.614 km² (1.461.400 ha). Assim foram demarcados um total de 952 pontos no campo, baseado no método da topossequência, visando obter dados das muitas variações ocorrentes, principalmente quanto a litologia e relevo, e conforme ratificado por Arruda et al. (2013), sendo coletadas amostras de terra na camada 0-20 cm com trado tipo holandês e georreferenciadas com uso receptor de um GPS (*global positioning system*)

2.2.3 Aquisição de série temporal de imagens TM – Landsat 5 e processamento

A principal cultura da região é a cana de açúcar. Sabe-se que, em média a cada cinco anos, os agricultores fazem uma reforma para renovação do canavial, e por consequência fazem o preparo de solo com aração e gradagem. Desta forma o solo fica exposto até o crescimento do canavial. No geral, e para a região, estas operações são realizadas no período de maio a outubro. O objetivo portanto, foi o de detectar áreas com solo exposto em algum momento através de uma série histórica de imagens do satélite Landsat 5. Neste aspecto a presente metodologia será nomeada como *Multitemporal Basr Soil Image Index* (MUBASII).

Neste sentido foi formado um banco de dados com 50 imagens Level 1 Product do satélite Landsat 5 (LOVELAND & DWYER, 2012) obtidas do “United States Geological Survey” (USGS). Do período de 1995 até 2011, sempre entre os meses de junho a outubro. Este produto derivado do sensor Thematic Mapper (TM) conta com sete bandas: visível azul (450–520 nm), visível verde (520–600 nm), visível vermelho (630–690 nm), infravermelho próximo (760–900 nm), infravermelho ondas curtas (1550–1750 nm), termal (10.400–12.500 nm), infravermelho ondas curtas (2.080–2.350 nm). Com resolução espacial de 30 m para as bandas VIS (visível), NIR (infravermelho próximo) e SWIR (infravermelho ondas curtas) e 120 m no termal.

As imagens foram processadas na plataforma ENVI 5.1, a qual possui algoritmos de correção atmosférica (FLAASH) e transforma os dados de número digital para reflectância (EXELIS, 2015). Em seguida foram transformadas do sistema de coordenadas WGS84 para o SAD69 / UTM zona 23S com a função *Project Raster* do programa ArcGis 10.2 (ESRI, 2013). Não houve necessidade de georreferenciar as imagens, devido ao produto utilizada já ser previamente.

2.2.4 Obtenção de solo exposto

As imagens passaram por processos de eliminação de todos os objetos que não eram solo exposto. A “retirada” de um objeto da imagem, é aqui denominado de máscara. Este processo consiste por exemplo, em solicitar ao software que retire da imagem toda informação que seja água. Portanto, denomina-se que foi realizada uma máscara para retirar este alvo da imagem.

Para realizar os processos de máscaras e retirada de objetos que não fossem solos, foram necessários estudos preliminares dos espectros dos alvos. Neste caso, foram

estudados alvos conhecidos para ciência do espectro quais sejam: água, palhada, vegetação e solos de diferentes texturas.

Assim, foram definidas a utilização de quatro máscaras, o uso do “*Normalized Difference Vegetation Index*” (NDVI) de acordo com a equação (1) para supressão das áreas vegetadas.

$$NDVI = \frac{TM4 - TM3}{TM4 + TM3} \quad (1)$$

A faixa considerada como solo para este índice em todas as imagens foi estabelecida entre 0 e 0,25, sendo os valores superiores referentes a vegetação.

Outro índice diferencial normalizado utilizado foi o “*MID – Infrared index*” (MIDII) sugerido por MADEIRA (1993) de acordo com a equação (2) e foi utilizado para discriminar áreas com palhada de solo.

$$MIDII = \frac{TM5 - TM7}{TM5 + TM7} \quad (2)$$

Para este índice não foi possível estabelecer uma linha de corte única como o anterior. Esta bandas são sensíveis a variações de umidade de solo como demonstra Musick & Pelletier (1988) e mais recentemente Haubrock et al., (2008) propõem um índice de umidade de solo com uma faixa muito próxima as bandas TM5 e TM7. Assim, foi definido uma linha de corte empiricamente para cada imagem com o intuito de suprimir as áreas com palha, no geral a faixa considerada como solo para este índice foi entre 0 e $\approx 0,15$.

O comportamento espectral de solos tropicais observados por sensores orbitando a terra tem uma aspecto ascendente nas bandas TM1, TM2 e TM3 (DEMATTÊ et al., 2009, DEMATTÊ; RIZZO & BORTOLETTO, 2011, DEMATTÊ; RIZZO & BOTTEON, 2015). Desta forma foram utilizadas duas subtrações de bandas para mascarar qualquer comportamento diferente do ascendente, sendo “TM2 - TM1” e “TM3 - TM2”, desta forma os valores negativos foram eliminados.

Uma importante ferramenta utilizada no mascaramento foi a conferência das imagens na composição falsa cor, 543, RGB. Nesta composição após o realce (apenas visual) *Stretch Linear* (1%, 2% e 5%) da plataforma ENVI 5.1, as áreas de solo exposto apresentam um coloração púrpura para solos argilosos e tende para rósea nos arenosos. Desta forma foi possível

fazer uma avaliação visual da eficiência das máscaras aplicadas quanto a coloração, sendo também analisado o contexto.

2.2.5 Obtenção da imagem composta de solo exposto

Na sequência foi necessário agrupar as imagens da série temporal já processadas para solo exposto em uma única imagem composta. De acordo com Ackerson; Demattê e Morgan (2015) o efeito da umidade do solo é o maior limitador para predições de atributos de solo em condições de campo pela espectrometria de reflectância no VIS-NIR. Bricklemeyer & Brown. (2010) segue a mesma linha ao constatar que a umidade dos solos no campo é um dos principais limitantes para o uso de sensores espectroradiômetros “on-the-go”.

Com intuito de reduzir o efeito da umidade, que diminui a intensidade da reflectância e piora acurácia das predições. Em pixels com sobreposição entre diferentes imagens optou-se por selecionar o com menor influência da umidade. Desta forma, a seleção foi pelo menor valor do MIDII, esta operação foi realizada no software R (R Core Team, 2015) com uso do pacote “RASTER” (Hijmans, 2015). Esta escolha se deve ao fato de que a água na faixa da banda TM7 tem maior poder de absorbância que a faixa relativa a banda TM5 (Curcio & Petty, 1951, “apud”, MUSICK & PELLETIER, 1988), isto explica a queda da reflectância da banda TM5 para TM7, o que não ocorre com dados simulados obtidos em laboratório. Esta informação corrobora com o índice de umidade do solo “*Normalized Soil Moisture Index*” (NSMI) sugerido por Haubrock et al. (2008) apresentada pela equação (3), no qual os menores valores se correlacionam com menores teores de umidade.

$$NSMI = \frac{R(1800nm) - R(2119nm)}{R(1800nm) + R(2119nm)} \quad (3)$$

Para geração desta imagem composta, das 50 imagens iniciais, doze foram eliminadas por apresentarem incoerências, sendo assim a imagem composta foi gerada com 38 imagens de solo exposto. Nesta nova imagem os pixels selecionados têm menor influência da umidade e assim maior potencial para predição de atributos de solo.

2.2.6 Obtenção de espectros de laboratório, orbitais e análises granulométricas convencionais

Em seguida, as amostra de terra coletadas no campo foram secas a 45 °C por 24 horas, moídas, peneiradas em uma malha de 2 mm e colocadas em placas de petri. Em seguida foram obtidos os espectros de reflectância com o sensor FieldSpec 3 com comprimento de onda de 350-2.500 nm (Analytical Spectral Devices, Bouldes, CO, EUA). A reflectância de cada amostra foi obtida da média de 100 leituras feitas pelo sensor. O sensor captou a luz através de um cabo de fibra óptica, colocado a 8 cm da superfície da amostra. A fonte de luz utilizada foi uma lâmpada alógena de 50 W, com feixe não colimado para o plano visado, posicionada a 35 cm da amostra com ângulo zenital de 30°. Uma placa de Spectralon foi utilizada para calibração e ajustando em 100% de reflectância.

Os espectros obtidos em laboratório foram simulados para o sensor TM de acordo com metodologia proposta por DEMATTÊ et al. (2004), na qual foi determinada pela média dos valores de reflectância adquiridos nos intervalos espectrais das bandas TM. Desta forma foi possível realizar comparações com os dados obtidos da imagem composta de solo exposto. Os dados espectrais da imagem composta foram extraídos para os pontos de tradagem georreferenciados no software ArcGis 10.2 (ESRI, 2013) com uso da ferramenta “*Extract Multi Values to Points*”, sendo selecionada a opção “*bilinear interpolation*” para reduzir o efeito de salpicamento da imagem composta. No total foram obtidas 639 amostras, com análise granulométrica, espectros laboratoriais simulados e orbitais de solo exposto. Sendo as amostras de terra coletadas, num total de 952 na profundidade 0 -20 cm, foram analisadas em laboratório quanto a granulometria (areia, silte, argila) conforme metodologia de CAMARGO et al. (1986).

2.2.7 Comparação dos espectro de laboratório com orbital de solo exposto

Para avaliar a qualidade da imagem composta de solo exposto foi realizada a comparação com dados espectrais de laboratório. Para tanto, baseado nas respectivas análises de solos, foram elaborados médias de reflectância em função da classe textural das amostras. Classificadas de acordo com o teor de argila a seguir: muito arenosa (menor que 10%), arenosa (de 10 a 15%), médio-arenosa (15 a 25%), médio-argilosa (25 a 35%), argilosa (35 a 60%) e muito argilosa (maior que 60%), classes texturais para fins de manejo do solo conforme Demattê & Demattê (2009). Assim, foram plotadas num mesmo gráfico as médias das classes das curvas espectrais simuladas e orbitais afim de comparação.

As curvas espectrais médias para cada classe textural foram, então, avaliadas pela comparação da forma, intensidade (albedo) e feições de absorção dos espectros médios conforme Demattê (2002) e Demattê et al. (2015).

Foram determinados os coeficientes de correlação de Pearson entre os dados espectrais simulados e orbitais, a fim de se avaliar a relação existente entre dados orbitais e em laboratório. Também foi realizada a análise de componentes principais (ACP) a fim de simplificar a comparação entre dados multiespectrais, reduzindo assim a maior parte da variabilidade em menos variáveis (VARMUZA & FILZMOSE, 2009). Foram realizadas comparações gráficas entre PC1 e PC2 do orbital e simulado. Também foram realizadas novas ACP com um menor número de bandas como segue: (i) TM2, TM3, TM4, TM5, TM7; (ii) TM3, TM4, TM5, TM7; (iii) TM4, TM5, TM7; e (iiii) TM5, TM7. Na sequência foram determinados os coeficiente de correlação de Pearson entre as PC1s.

2.3 Resultados e Discussão

2.3.1 Solos da área

A tabela 1 indica as variações na parte textural variando de 7 a 643 g.kg⁻¹ de argila. Os teores de areia também variam bastante de 86 a 969 g.kg⁻¹. O teor de silte apesar de altamente variável, não se apresenta com valores altos sendo um máximo de 347 g.kg⁻¹. A textura é variável, indo de 30% para os argilosos e muito argilosos, 35% textura média-argilosos e 13% médio-arenosos (Figura 2a). Quimicamente 37% são eutróficos e 30% distróficos (Figura 2b). Os solos da área são tipicamente os Latossolos Vermelho e Vermelho-Amarelos com textura variadas indo da média arenosa (15-25% argila) até muito argilosas (maior que 60% argila). Também ocorrem os Argissolos Vermelhos e Vermelho-Amarelos com textura variada. Ocorrem na área aproximadamente 58% de Latossolos e 6% de Nitossolos. Destaque-se os 21% de Neossolos Quartzarênicos (Figura 2c). Os solos da área são de argila de baixa atividade. Os teores de ferro são variáveis ocorrendo os férricos com certa frequência. A maioria dos valores de ki são baixos, faixa de 0,9 a 1,5 indicando alta intemperização, sendo basicamente oxídica a caulinítica.

2.3.2 Diferenciação de alvos

Com o objetivo de detectar áreas com solo exposto nas imagens, foi necessário conhecer os padrões de diversos alvos (Figura 3). Observar que as curvas de solos obtidas em pixels da imagem quando com solo exposto apresentam baixa intensidade de reflectância nas bandas 1 e 2 iniciando aumento da intensidade na 3 e 4 atingindo um máximo em 5, e decrescendo novamente em 7. Todas as curvas de solos ocorreram da mesma forma variando quanto a angulação de aumento da intensidade. O solo argiloso por exemplo, segue uma trajetória quase plana. Na medida em que a classe textural muda de argilosa para média-argilosa, aumenta a intensidade principalmente nas bandas 5 e 7, com picos máximos na classe muito arenosa. Tais observações estão de acordo com dados obtidos por Demattê et al. (2009) com imagens Landsat (figura 4a). Da mesma forma, as observações vão de encontro a dados obtidos, porém em laboratório, por Franceschini et al. (2013) (Figura 4b). Por outro lado, quando se tem vegetação, ocorre absorção nas bandas 1 e 3 para atividades fotossintéticas, além da reflexão no verde (motivo pelo qual enxergamos a vegetação nesta cor), tendo um pico no infravermelho próximo (banda 4), devido a estrutura foliar (mesófilo esponjoso), caindo novamente em função da umidade (JENSEN & EPIPHANIO, 2009). Isto pode ser observado em curvas obtidas em laboratório com sensor hiperespectral (Figura 4c). Observam-se as nítidas diferenças entre os solos argilosos e arenosos em relação a angulação e as intensidades das bandas no SWIR. Porém, em relação a palhada, o formato é bastante semelhante a do solo arenoso, diferindo pela feição de absorção em 2100 nm da lignina e pelo efeito de ‘pico’ na feição devida a caulinita em 2200 nm (PIZARRO; EPIPHANIO & GALVAO, 2001). De fato, os dados obtidos em laboratório, apesar de mais precisos, corroboram que a tendência de angulação nas intensidades de reflectância nas bandas 4, 5 e 7 auxiliam na diferenciação entre solos arenosos e material seco. A curva espectral quando com material seco (palhada) apresenta uma intensidade bem mais alta na banda 4 em relação ao solo arenoso (Figura 4c). O mesmo ocorre na banda 5. Na banda 7 entretanto, como ambas tem mesma intensidade, a diferenciação ficou por conta da banda 5. Logo, a angulação entre as bandas 5 e 7 são diferentes entre estes dois alvos. Esta observação foi o que norteou a diferenciação dos mesmos nos tópicos posteriores.

Em termos de solos, a imagem do TM/Landsat 5 apresenta padrões de solo arenoso e palhada bastante semelhantes. Apesar da imagem não detectar a banda da lignina conforme indicado (Figura 4c), porém, observa-se um padrão distinto. Nos solos arenosos, inicia-se com baixa reflectância na banda 1 aumentando gradativamente até banda 5 e recaindo

na banda 7. Tal comportamento pode confundir os alvos de solo arenoso e palhada. De fato, a palhada só pode ser adequadamente discriminada pela banda da lignina conforme indicado anteriormente. Por outro lado, observamos diferenças importantes mesmo nos dados multiespectrais do Landsat. Observe que a angulação entre as bandas 5 e 7 é maior para o caso do solo (Figuras 3 a, 4c). Também é observado diferenças entre as bandas 4 e 5. Neste caso, o aspecto é ascendente forte para a palhada (figura 3 a) e ascendente leve para o solo, e em muitos casos, forma-se um ligeira concavidade nos solos (Figura 4 a2). Isto foi constatado numa série de amostragens. De fato, a presença de lignina apresenta maior intensidade de aumento da reflectância entre as bandas 4 e 5 do que solos arenosos. Isso ocorre por que o quartzo presente nos solos arenosos reflete em toda a faixa do SWIR indo até 2500 nm (GOLDSHLEGER et al., 2001), enquanto a lignina tem este efeito somente na faixa da banda 5. De fato, as curvas avaliadas pelo modelo hiperespectral pode ser discriminada por duas bandas, a localizada em 2100 nm e 2200 nm, sendo absorção e pico, respectivamente. Ao contrário, na curva do solo, não ocorre a absorção em 2100, e ocorre em 2200 nm devido a caulinita. Logo, com dados hiperespectrais, é possível discriminar estes alvos. Os multiespectrais, não apresentam estas feições, e portanto, só podemos relacionar com as intensidades das bandas 5 e 7, conforme descrito anteriormente.

Outra forma de diferenciar a palhada de solos foi pelo modelo do MIDII (*MID – Infrared index*) (Figura 3b). Tanto a vegetação quanto a palhada tiveram comportamento distintos no valor do índice. O índice NDVI (*Normalized Difference Vegetation Index*) por sua vez, só conseguiu diferenciar a vegetação verde, e confundiu a palhada com solos. Isto por que a palha e o solo na TM3 e TM4 tem o mesmo comportamento ascendente. Como se trata de um índice diferencial normalizado, o valor fica semelhante.

Outro método comumente utilizado na discriminação de solos é o da linha do solo (NANNI & DEMATTÊ, 2006). As bandas 4 e 3 discriminaram os solos argilosos dos médios dos arenosos, concordando com os citados autores. Isso ocorre por que os solos mais argilosos apresentam alta absorção de energia no visível e infravermelho próximo, havendo uma proximidade maior entre a intensidade destas duas bandas. Por outro lado, os solos arenosos apresentam maior intensidade nestas mesmas faixas causando a diferença no gráfico, concordando com Demattê et al. (2009) e Nanni & Demattê (2006). Além disso, a palhada ficou localizada na linha do solo, porém, ligeiramente separado do grupo dos solos arenosos (Figura 3d). Da mesma forma, a relação entre as bandas 5 e 7 apresentou bons resultados nesta discriminação. A diferenciação entre as bandas 5 e 7 se deve ao aumento abrupto da intensidade de reflectância da palhada na banda 5.

2.3.3 Comparação de dados orbitais e terrestres

Com o objetivo de aumentar a probabilidade de obter solo exposto nas imagens, foram feitos alguns testes, além dos padrões dos alvos analisados no tópico anterior. Primeiramente foram observados os dados dos pixels coletados na linha do solo, tanto das amostras avaliadas por sensor terrestre como pelo respectivo pixel da imagem de satélite (comparativamente). Foram observadas as relações entre linha do solo e espectros obtidos em laboratório e por satélite (Figura 5 a). As curvas de amostras de solo argiloso apresentam baixa intensidade de reflectância em todo o espectro, num formato tipicamente plano, enquanto o solo arenoso apresenta formato ascendente concordando com Demattê et al. (2015). Fazendo a simulação das curvas de laboratório para o TM/Landsat 5, observa-se a perda do detalhamento da forma (perda das feições), mas ainda ocorre a manutenção das tendências de intensidade. A perda das feições é clara, o que impede a detecção de elementos como a caulinita por exemplo. A comparação do formato das curvas hiperespectrais e multiespectrais do mesmo objeto, permite visualizar a sua relação com as bandas 3 e 4, quando plotados na linha do solo (figura 5b). Todos os dados ficam em uma mesma linha de tendência, concordando com Baret & Guyot (1991). Como os dados obtidos em laboratório eram de solo puro, obviamente os pontos caíram exatamente na linha. No caso dos pixels obtidos em imagens do satélite, poderia haver alguma variação, pois, apesar de todos os cuidados, sempre existem alterações no solo em condições de campo e/ou devido as condições atmosféricas. Entretanto, os dados obtidos das imagens ficaram exatamente sobrepostos aos dados de laboratório, ratificando a veracidade dos dados orbitais (figura 5b). Essa foi a primeira evidência de que os pixels extraídos da imagem pelo método proposto, detectou solo exposto. A segunda evidência está no gráfico da figura 5 c. Observar que a relação entre as bandas 5 e 7 também colocaram os mesmos próximo ao eixo 1:1. A diferença no ângulo entre as amostras orbitais e simuladas, está relacionada ao efeito da umidade nas amostras de solo do campo (nos pixels). Mesmo a imagem tendo sido obtida em época seca, houve efeito da umidade, evidenciado pela variação angular, e especificamente pela absorção de energia na banda 7, concordando com Musick & Pelletier (1988) e Khanna et al. (2007).

Através da análises de componentes principais, e utilizando os espectros de todas as bandas em simultâneo, (figura 6a, b) a similaridade entre os dados terrestres e os orbitais, respectivamente, reiterando evidências da discriminação textural dos solos via laboratório e satélite. Da mesma forma, a figura 6c ilustra a sobreposição dos dados de laboratório com satélite, indicando alta similaridade.

Em termos de correlação, a tabela 2 indica valores significativos entre dados de laboratório (simulados para as bandas TM do Landsat) e orbitais. A correlação entre os dados espectrais nestes dois níveis de aquisição atingiram r entre 0,59 (bandas 1 lab com 1 orb) até 0,82 (banda 7 lab com banda 7 orb), com média de 0,70. Tais resultados ratificam, mais uma vez, a boa relação entre os dados terrestres com os orbitais. Os dados dos componentes principais (Figura 7) demonstram correlação (r) entre todas as bandas de 0,74, atingindo o maior coeficiente entre as bandas 5 e 7 com 0,82. Tais resultados indicam que os dados obtidos via satélite são extremamente semelhantes aos dados terrestres e, portanto, novamente validados. Por outro lado, destaque-se que a correlação da banda 1 (azul), apresentou o menor valor, isto pois a mesma sofre espalhamento (JENSEN & EPIPHANIO, 2009). A intensidade entre as bandas 5 e 7 são diferentes para o caso orbital, e semelhantes para o caso em laboratório, porém, apesar disso, apresentam ambas altas correlações devido a linearidade.

2.3.4 Cores nas imagens de satélite e solo exposto

Um dos métodos mais comuns na detecção de solo exposto é pelo visual, devido a intrínseca relação com a visão humana. Neste aspecto, as cores de um solo exposto numa composição real do TM/Landsat 5 321, RGB (cor real), o solo fica com a cor real, como por exemplo marrom, avermelhado ou amarelado, dependendo do solo em questão. Por outro lado, têm-se a composição 543 RGB (falsa cor) também muito utilizada para interpretação de solos. De maneira geral os solos dos trópicos apresentam óxidos em sua constituição em diferentes proporções causando variações nas cores, tanto no real quanto na composição falsa cor. O sistema RGB é um sistema numérico de cores oriundo da mistura do R: Vermelho, G: Verde e B: Azul (Figura 8 b). Através dos valores de cada uma dessas cores é possível gerar inúmeras combinações. Sem um realce (Figura 8 f), fica difícil distinguir as variações e sua relação com solos. Para tanto, é necessário aplicar um realce na imagem através de uma transformação no histograma de cores. Após o realce as cores ficam nítidas (Figura 8 g). Através de inúmeras observações em imagens das regiões tropicais, tem-se observado variações nos níveis de arroxamento, o qual está relacionado a composição do solo (DEMATTE et al., 2009; DEMATTE et al., 2007). Para o presente caso, a questão que fica é: por que a cor numa imagem falsa cor (543, RGB) apresenta variações nos níveis de roxo?

O *Stretch Linear* é um processo de realce visual que transforma os valores dos pixels de acordo com o histograma das bandas selecionadas na composição RGB. As bandas de absorção da Hematita ocorrem nos comprimentos de onda de 445, 530, 650 e 885 nm (Figura

8a). Na Goethita são nos comprimentos de 435, 480, 650, 917 nm. No TM/Landsat 5 na composição RGB 543, as cores roxas indicam óxidos e argila após realce (figura 8f, g). Essas bandas abrangem os comprimentos de onda 1550 a 1750 nm para a banda 5 (Infravermelho ondas curtas), 760 a 900 nm para a banda 4 (Infravermelho próximo) 630 a 690 nm para a banda 3 (Vermelho). Na banda 5 há maior intensidade de reflectância e nas bandas 4 e 3 há maior absorção (Figura 9 a). Na figura 8c, é apresentado o realce onde foram eliminados os valores extremos para se visualizar a cor roxa, sendo que os valores máximos e mínimos que ficam em destaque foram alterados. Assim, com os valores de reflectância dos óxidos, que refletem no R (equivalente ao 1550 nm) e absorvem no G e B (885-917 e 650 nm, respectivamente), seguem os valores da imagem (Figura 8c). Quando se convertem os valores de acordo com o realce para cada banda, os valores se alteram. Fica entretanto, numa proporção equivalente ao roxo em RGB: 153-51-153 (Figura 9c).

Portanto, Em termos de reflectância a valores dos pixel das imagens se compartilham como os óxido se comportam, reflete no Infravermelho médio e absorve no Infravermelho próximo e no vermelho. Porém, se deixarmos apenas os valores brutos enxergamos uma imagem escura (Figura 8f). A partir daí aplicamos um realce, para contrastar melhor as cores das imagens e deixa-las mais nítidas, aparecendo a cor arroxeadada. É como se redistribuísse os valores máximos e mínimos da imagem. Após o realce, os valores dessa imagem podem ser transformados e os máximos e mínimos de cada banda se alteram, e conseqüentemente as proporções de RGB ficando na forma observada figura 8g.

Portanto, a visualização de cores em diferentes níveis de arroxamento, está relacionado aos níveis de óxidos, que por sua vez, se relaciona a intensidade de reflectância e textura do solo. Até este ponto, juntam-se as evidências em como detectar pixels com solo exposto.

2.3.5 Solo exposto em imagens de satélite multitemporais

Um dos benefícios da imagem de satélite é a obtenção da informação solo. Entretanto, o pixel da imagem tem que estar com solo exposto para ser avaliado. Numa imagem de uma única época, nem toda a área terá solo exposto, o que irá comprometer a avaliação dos solos num continuum. Caso o pedólogo ou usuário apenas se interesse em ter um pixel com solo exposto, de maneira pontual, uma única imagem basta. Entretanto, caso o usuário queira enxergar o solo numa forma contínua, é necessário uma abordagem diferenciada. Neste aspecto, o método aqui proposto, obteve imagens multitemporais do TM/Landsat 5. Sabendo-se que em

algum momento histórico, o agricultor arou e gradeou a terra, o solo estaria exposto. Identificando solo exposto através das técnicas anteriormente indicadas, e posteriormente, sobrepondo todas as imagens históricas, objetivou-se ter uma única imagem de satélite com solo exposto.

Para entendimento, observe a tabela 3. Das 38 imagens selecionadas, a área de solo exposto variou de 0,5 % até 10,8%. Mesmo a imagem com a maior área apresenta uma área pequena, além de, esta se encontrar bastante fragmentada. E só terá utilidade se, dentro do universo de 10,8% esteja o pixel desejado com solo exposto. Analisando mais profundamente a tabela, verificamos que a área média obtida é de apenas 4% o que evidencia a pouca área com solo exposto em uma única “fotografia”. Cabe aqui também salientar que houve bastante sobreposição dos pixels de solo exposto dentro da série temporal, o que se verifica ao ver a média de área que cada imagem colaborou com a imagem composta final, que foi de apenas 1,15%. A figura 10 também evidenciou a sobreposição de áreas de solo exposto, sua análise permite verificar a redução de área quando foi feita a seleção dos pixels com menor umidade. Desta forma, a utilização de uma série temporal robusta, com sobreposição de pixels de solo exposto é benéfica ao selecionar pixels com menor efeito da umidade e também ao ampliar a área com solo exposto total na imagem composta.

A figura 11a apresenta a área total de 1.461.400 ha montada por meio da sobreposição de imagens multitemporais (Figura 1), contemplando solo exposto. A área total de solo exposto desta imagem foi de 43,5% (Tabela 3). As outras áreas em verde não tiveram solo exposto em nenhuma época nas imagens e referem-se a outros alvos tais como: água, rios, lagoas, áreas urbanas, mata ciliar, áreas de mata natural e culturas perenes.

Existe uma íntima relação entre a coloração da composição 543 RGB com a classificação textural. Observe a região com número 1 (Figura 11). Nelas nas partes altas do relevo a coloração é mais clara e nos fundos mais escura (próximo aos canais de drenagem). Isto ocorre pois o material de origem no fundo é o basalto, ocorrendo portanto solos mais argilosos, sendo os arenosos nas partes mais altas. As linhas indicam a delimitação das diferentes texturas. Na área 2, as áreas mais claras são de ocorrência do arenito, perfazendo os solos mais arenosos. Na área 3, observa-se tons bastante escuros com textura mais argilosa, com algumas manchas mais arenosas. Na área 4, observa-se locais vegetados com culturas (em verde) e não foi possível detectar solo exposto. Por outro lado, há muitos polígonos com solo exposto o que permite o mapeamento da área. Ou seja, as imagens multitemporais na cena completa, não conseguiu detectar solo exposto em todos os locais, principalmente em áreas com culturas perenes como reflorestamento e citricultura.

Para ter certeza da pureza do pixel em termos de solos Guerschman et al. (2009) também utilizaram metodologia similar, mas não obtiveram dados de maneira contínua. Outra forma de validação das imagens seria a avaliação de um atributo do solo como por exemplo o teor de argila. Desde Henderson et al. (1992) muitos trabalhos tem-se direcionado com o intuito de quantificar atributos do solo como teor de argila, mas na época os valores de R^2 foram baixos. Ademais, Henderson et al (2005) utilizaram-se de um amplo banco de dados com o intuito de mapear atributos do solo entre eles imagens do Landsat, chegando a resultados mais animadores, justamente devido a melhoria de softwares de processamento de imagens. Porém, as imagens auxiliaram somente em dados pontuais (pixels únicos) onde se tinha solo exposto. Portanto, a presente metodologia poderia auxiliar em trabalhos na determinação espacial dos atributos em áreas contínuas.

A literatura é forte na indicação das relações entre reflectância do solo e textura conforme verificado por Viscarra & Chen (2011) e Soriano-Disla et al. (2014), porém, utilizando dados de sensores hiperespectrais em laboratório. Quando se passa para sensores orbitais e no caso TM/Landsat 5, alguns trabalhos também tem sido desenvolvidos tais como com R^2 na faixa de 0,76 (DEMATTÊ & NANNI, 2003; DEMATTÊ et al., 2005; NANNI & DEMATTÊ, 2006a, b; FIORIO et al., 2010). Demattê et al. (2007a) determinaram argila com 0,86 de R^2 para argila em áreas de alta variabilidade. Ainda com o TM/Landsat 5, Demattê et al. (2009) e Fiorio & Demattê (2009) predisseram argila com 0,61 de R^2 .

Afora os multiespectrais, os hiperespectrais também têm sido estudados. A influência da distribuição granulométrica como argila e areia é grande nos dados espectrais, conforme relatado por Selige, Böhner & Schmidhalter (2006) usando o ASS (sensor HyMap), atingindo R^2 de 0,95 e 0,71, respectivamente. DeTar et al. (2008) usaram MLR com a imagem hiperespectral AVNIR (429 a 1010 nm com 60 bandas), e reportaram R^2 de 0,67 para argila. Gomez; Lagacherie & Coulouma (2008 e 2012) quantificaram argila com sensor HyMap com R^2 de 0,64 e RMSE de 49,6 g kg⁻¹ usando PLSR. Hively et al. (2011) usando o HyperSpecTIR obteve R^2 de 0,76 para areia. Casa et al. (2013) compararam diferentes sensores hiperespectrais, como o aerotransportado MIVIS (VIS-NIR-SWIR) e o em satélite CHRIS-PROBA (VIS-NIR), com resoluções espaciais respectivamente de 4,8 e 17 m, atingindo R^2 de 0,68 e 0,55, com RMSE de 4,77, para argila com ambos os sensores.

De fato, a Figura 12a apresenta as curvas espectrais médias das amostras obtidas por sensor hiperespectral em laboratório e simuladas para o sensor TM. Observa-se que, partindo da curva espectral das amostras muito argilosa para argilosas para médio-argilosas para médio-arenosas para arenosas para muito arenosas, as curvas espectrais aumentam a

intensidade de reflectância do visível passando pelo infravermelho próximo e com pico no infravermelho de ondas curtas, especificamente na banda 5. As diferenças granulométricas apresentam-se coerentes neste sentido, ocorrendo um aumento angular do VIS para o SWIR, concordando com Demattê et al. (2014). De fato, esta sequência de curvas concorda com dados obtidos por Demattê et al. (2009) e Franceschini et al. (2013) para dados em laboratório (Figura 4 a1, b).

Ao comparar estes dados com as médias das curvas obtidas por satélite (Figura 12 b), observa-se a mesma tendência, ou seja, solos mais argilosos apresentam baixa intensidade de reflectância e muito arenosos alta intensidade, bem como as variações angulares. A variação angular está relacionada a intensidade devida ao quartzo que ocorre no SWIR tendo seu ápice na banda 5. Ou seja, os dados obtidos no satélite mantem a mesma tendência dos obtidos em laboratório. Aliás, os dados obtidos pelo satélite do presente trabalho (Figura 12 b), são semelhantes ao obtido do satélite por Demattê et al. (2009) figura 4 a2. Ou seja, mesmo coletando dados de imagens do TM/Landsat 5 em diferentes regiões, os resultados são semelhantes.

Comparativamente, os resultados obtidos em laboratório e os do satélite apresentam diferença principal entre as bandas 5 e 7. No caso do laboratório, cujas amostras foram secas, é baixa a diferença entre a intensidade da banda 5 para a 7 (Figura 4 a1; Figura 12 a). Por outro lado, as curvas obtidas via satélite, cuja resposta foi determinada diretamente do campo (e, portanto, tem alterações de umidade), mantém a mesma tendência, mas expressa uma absorção maior na banda 7, devido justamente a presença de umidade, o que aliás, foi observado também na figura 5c, e em concordância com Khanna et al. (2007).

2.3.6 Considerações finais

Como se observa, há vários trabalhos na linha de detecção de solo exposto via imagens de satélite (GREEN et al., 1988; BOARDMAN AND KRUSE, 1994; BOARDMAN; KRUSE & GREEN, 1995; GUERSCHMAN et al., 2009; DEMATTÊ et al., 2009). Entretanto, não há nenhum trabalho que se utilize de imagens multitemporais com o objetivo de montar uma única imagem com solo exposto. O sucesso desta operação depende principalmente de dois fatores, (a) que a área esteja em algum momento com solo exposto, e isso geralmente ocorre em áreas com agricultura, (b) que a imagem e o seu processamento seja de qualidade, (c) que a situação climática da imagem esteja semelhante. De fato, as curvas espectrais obtidas das imagens do presente trabalho, mostraram bastante semelhantes quanto a forma e intensidade

da reflectância quando comparados os espectros obtidos em laboratório. Essa comparação foi fundamental para a comprovação e validação dos dados das imagens. Os procedimentos analíticos como relação entre bandas, também comprovaram a similaridade entre os dados em laboratório e em satélite. Portanto, mesmo as imagens sendo de anos diferentes, os espectros pouco se alteraram. Isso também teve relação com a obtenção dos dados numa mesma época do ano, no caso, com pouca umidade, diminuindo seu efeito nos espectros.

2.4 Conclusões

Foi possível detectar solo exposto via imagens de satélite, comprovado e validado pela comparação entre espectros obtidos em laboratório com os respectivos obtidos em pixels diretamente do campo. As curvas espectrais de laboratório apresentaram coerência em relação a sua classe textural. Na sequência de classes muito argiloso; argiloso; médio-argiloso; médio-arenoso; arenoso; muito arenoso, a curva espectral aumenta a intensidade de reflectância atingindo seu ápice na banda 5 (1550-1750 nm). Tal fato corre pela atuação das variações de quartzo e mineralogia em geral. A curva toma um aspecto ascendente a partir do visível até o infravermelho de ondas curtas. O mesmo ocorreu com as curvas obtidas nos dados do satélite TM/Landsat 5.

Os procedimentos para obtenção de solo exposto tais como, remoção da vegetação com NDVI, remoção da palhada com MIDII, seleção do pixel com menor umidade, permitiram obter pixels puros com elevada probabilidade de ser solo.

Os procedimentos de relação entre bandas 3-4, 5-7, demonstraram a similaridade entre dados do satélite e terrestres. A correlação entre bandas atingiu 0,70 entre laboratório e satélite reiterando os dados obtidos pela referida metodologia. As melhores bandas na detecção de solo exposto foram a B5 com B7 atingindo correlação (r) de 0,82. A composição colorida 543, RGB respectivamente apresentou-se adequada para avaliação da variação de solos em imagens TM/Landsat 5.

A metodologia demonstrou que, se um usuário for estudar solo com uma única imagem, dentro de um universo de uma cena com 14000 km² ou 1.400.000 ha terá aproximadamente 4% de solo exposto. Entretanto, se utilizar a metodologia proposta, poderá atingir até 43% de área com solo exposto. Ainda, se for analisar áreas exclusivamente agrícolas, poderá atingir até 95% de áreas com solo exposto.

O referido método tem aplicação nas mais diversas áreas quais sejam mapeamento e caracterização de solos, conservação de solos, manejo físico do solo,

monitoramento ambiental entre outros, permitindo análise de grandes áreas. O método funciona principalmente em áreas agrícolas.

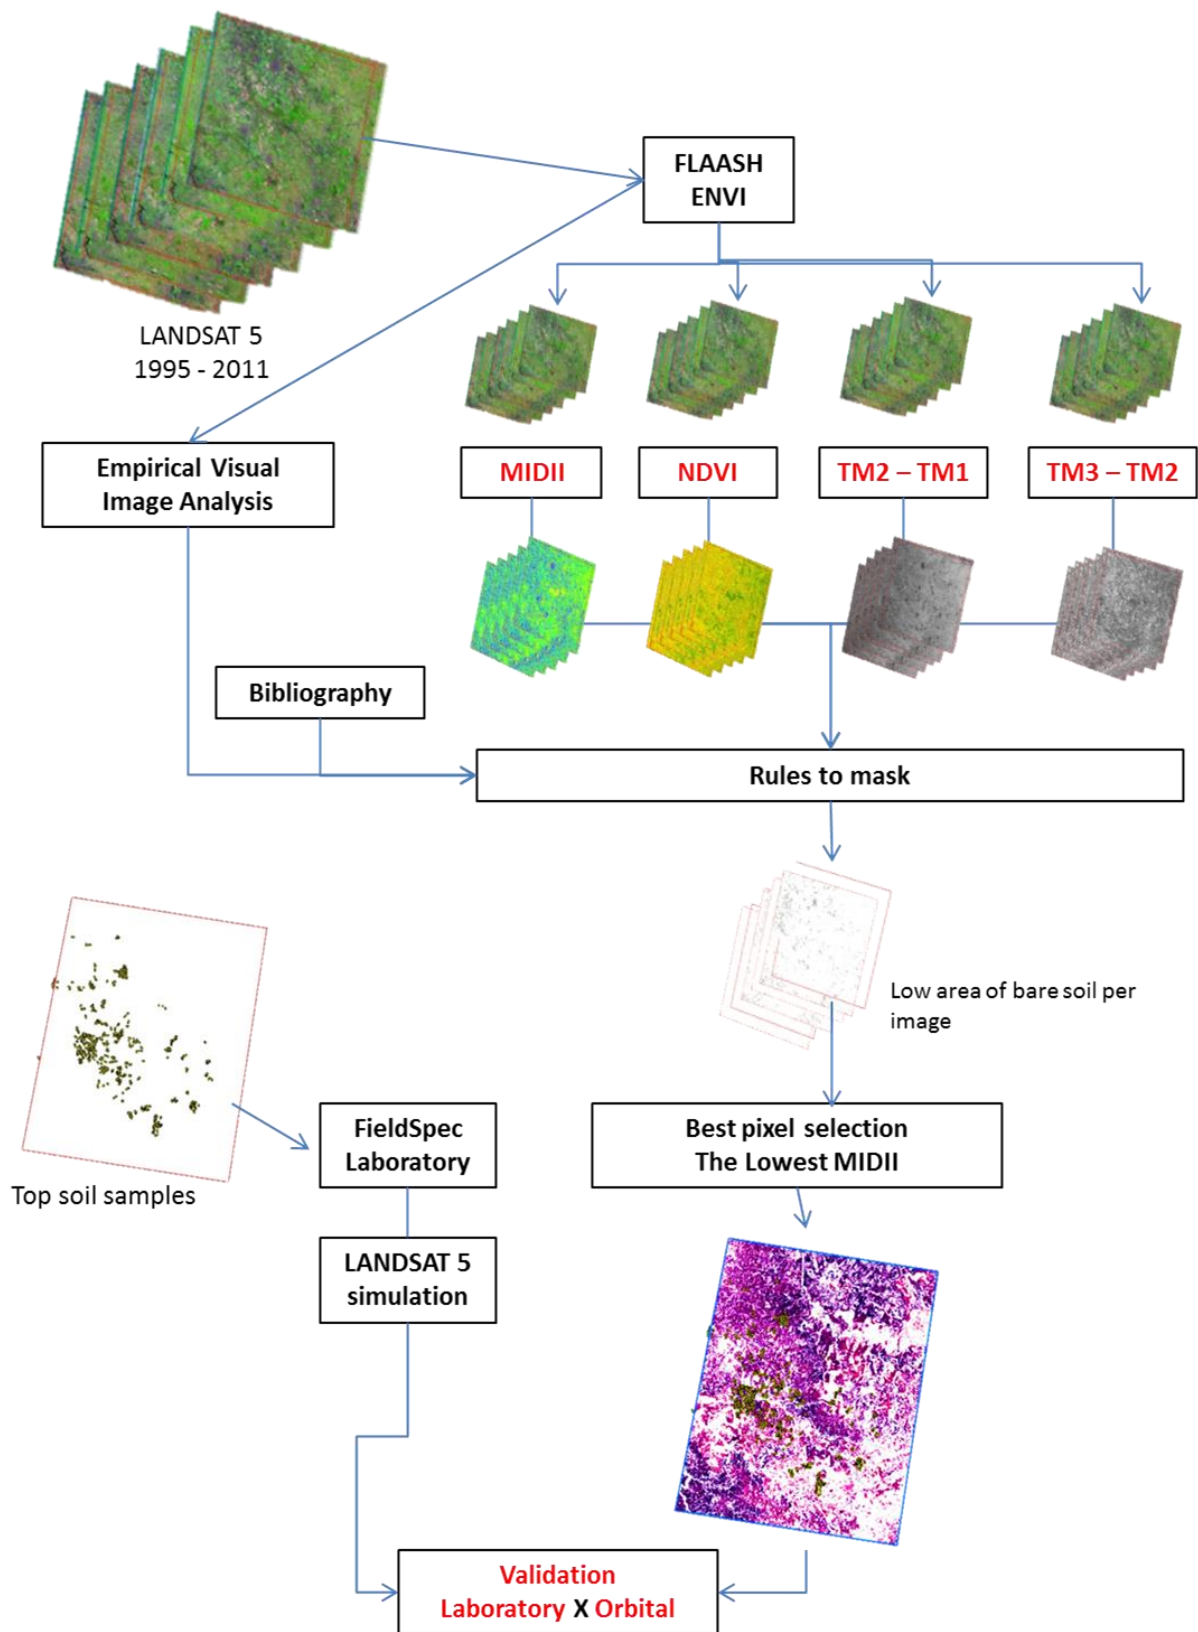


Figura 1 - Sequência metodológica para obtenção da imagem composta de solo exposto

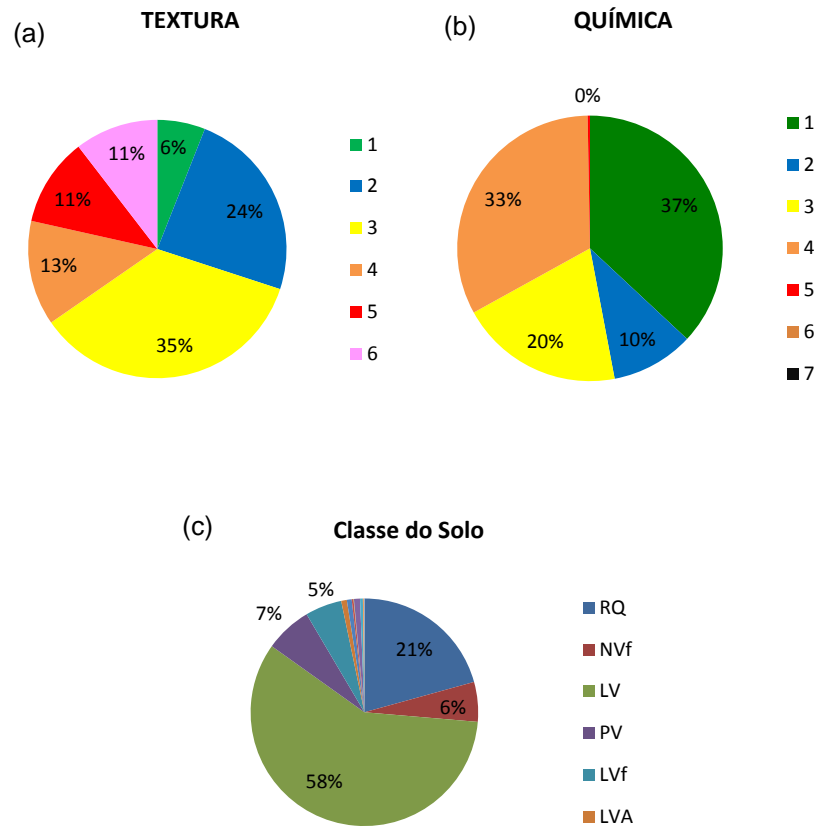


Figura 2 - Ilustração de (a) variabilidade textural, 1 muito argiloso, 2 argiloso, 3 médio-argiloso, 4 médio-arenoso, 5 arenoso, 6 muito arenoso, (b) química, 1 eutrófico, 2 epieutrófico, 3 distrófico, 4 álico, 5 ácrico, 6 alumínico, 7 alítico, (c) classe de solos, RQ, Neossolo Quartzarênico; NVf, Nitossolo Vermelho férrico; LV, Latossolo Vermelho; PV, Argissolo Vermelho; LVf, Latossolo Vermelho férrico; LVA, Latossolo Vermelho-Amarelo

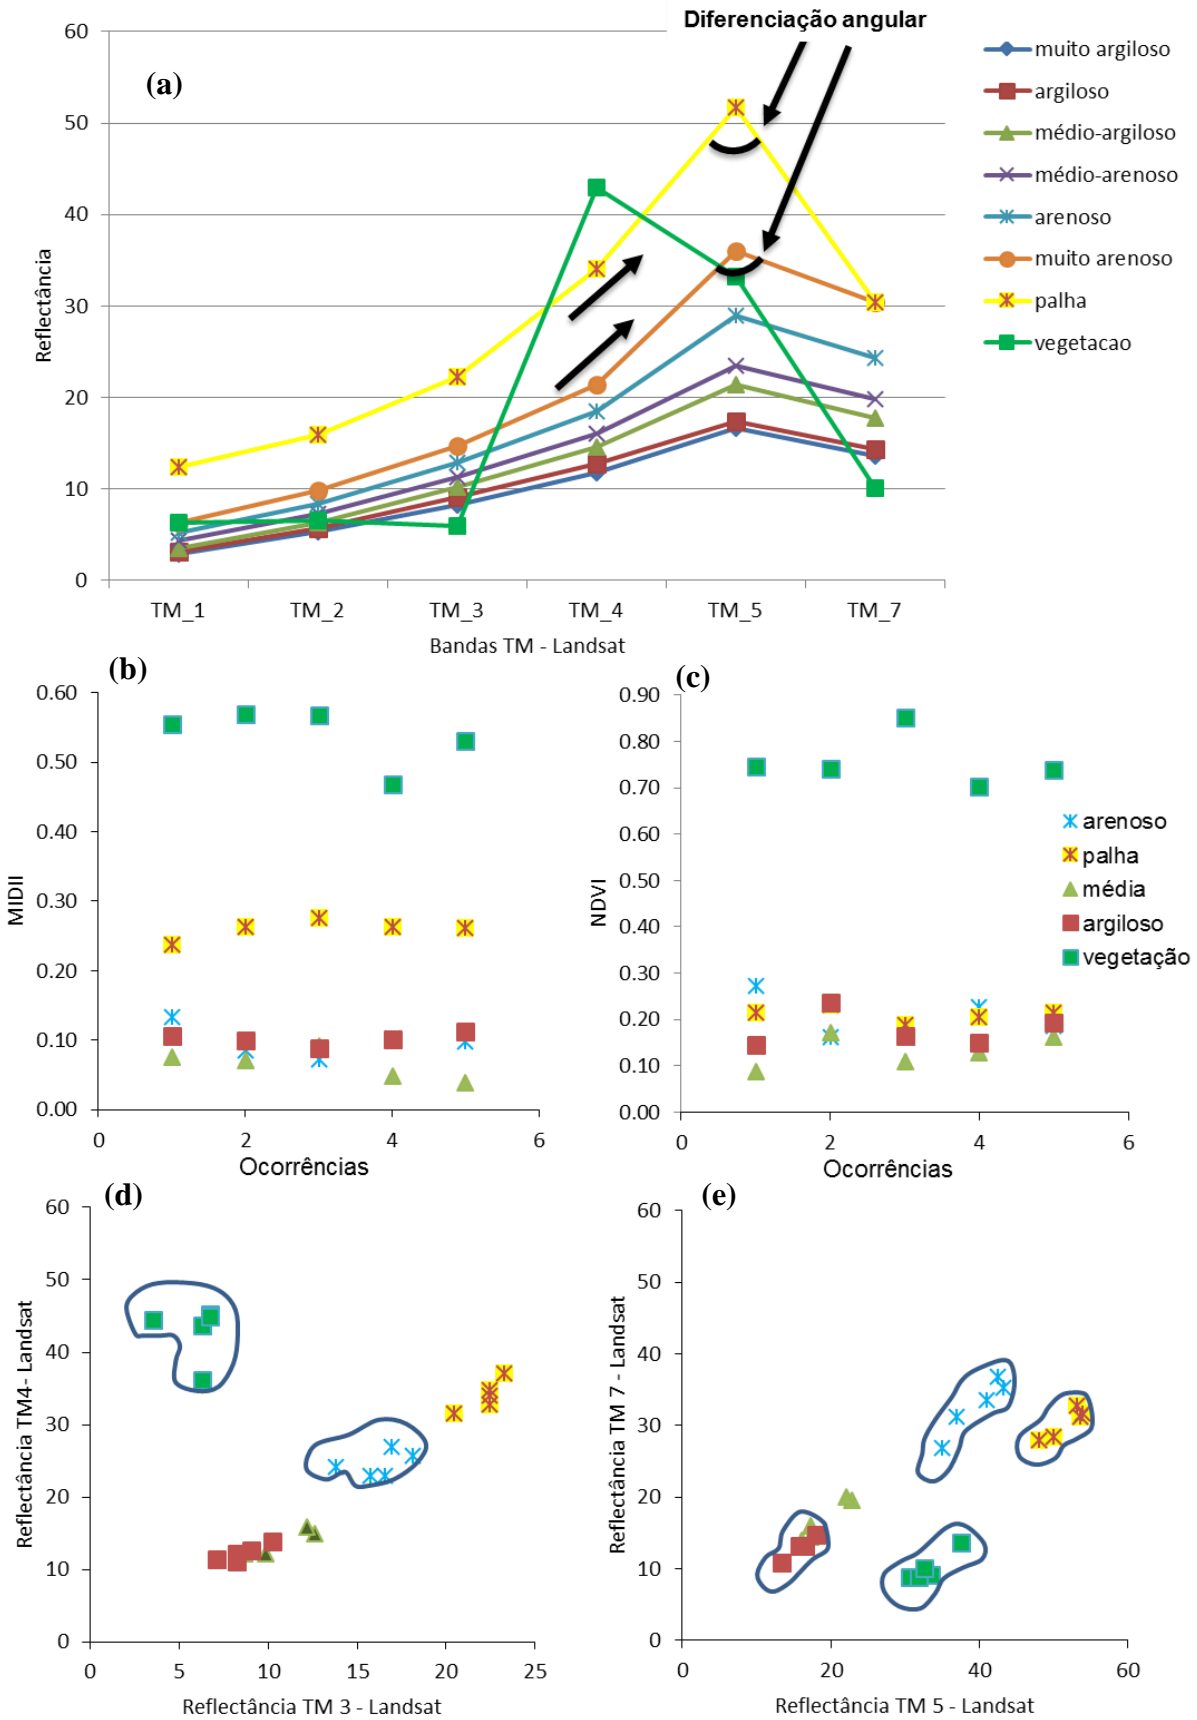


Figura 3 - (a) Dados espectrais obtidos para diferentes alvos, (b) MIDII para diferentes alvos, sendo cinco ocorrências para cada, (c) NDVI para diferentes alvos, sendo cinco ocorrências para cada, (d) Relação entre as bandas TM7 e TM5, (e) Relação entre as bandas TM4 e TM3

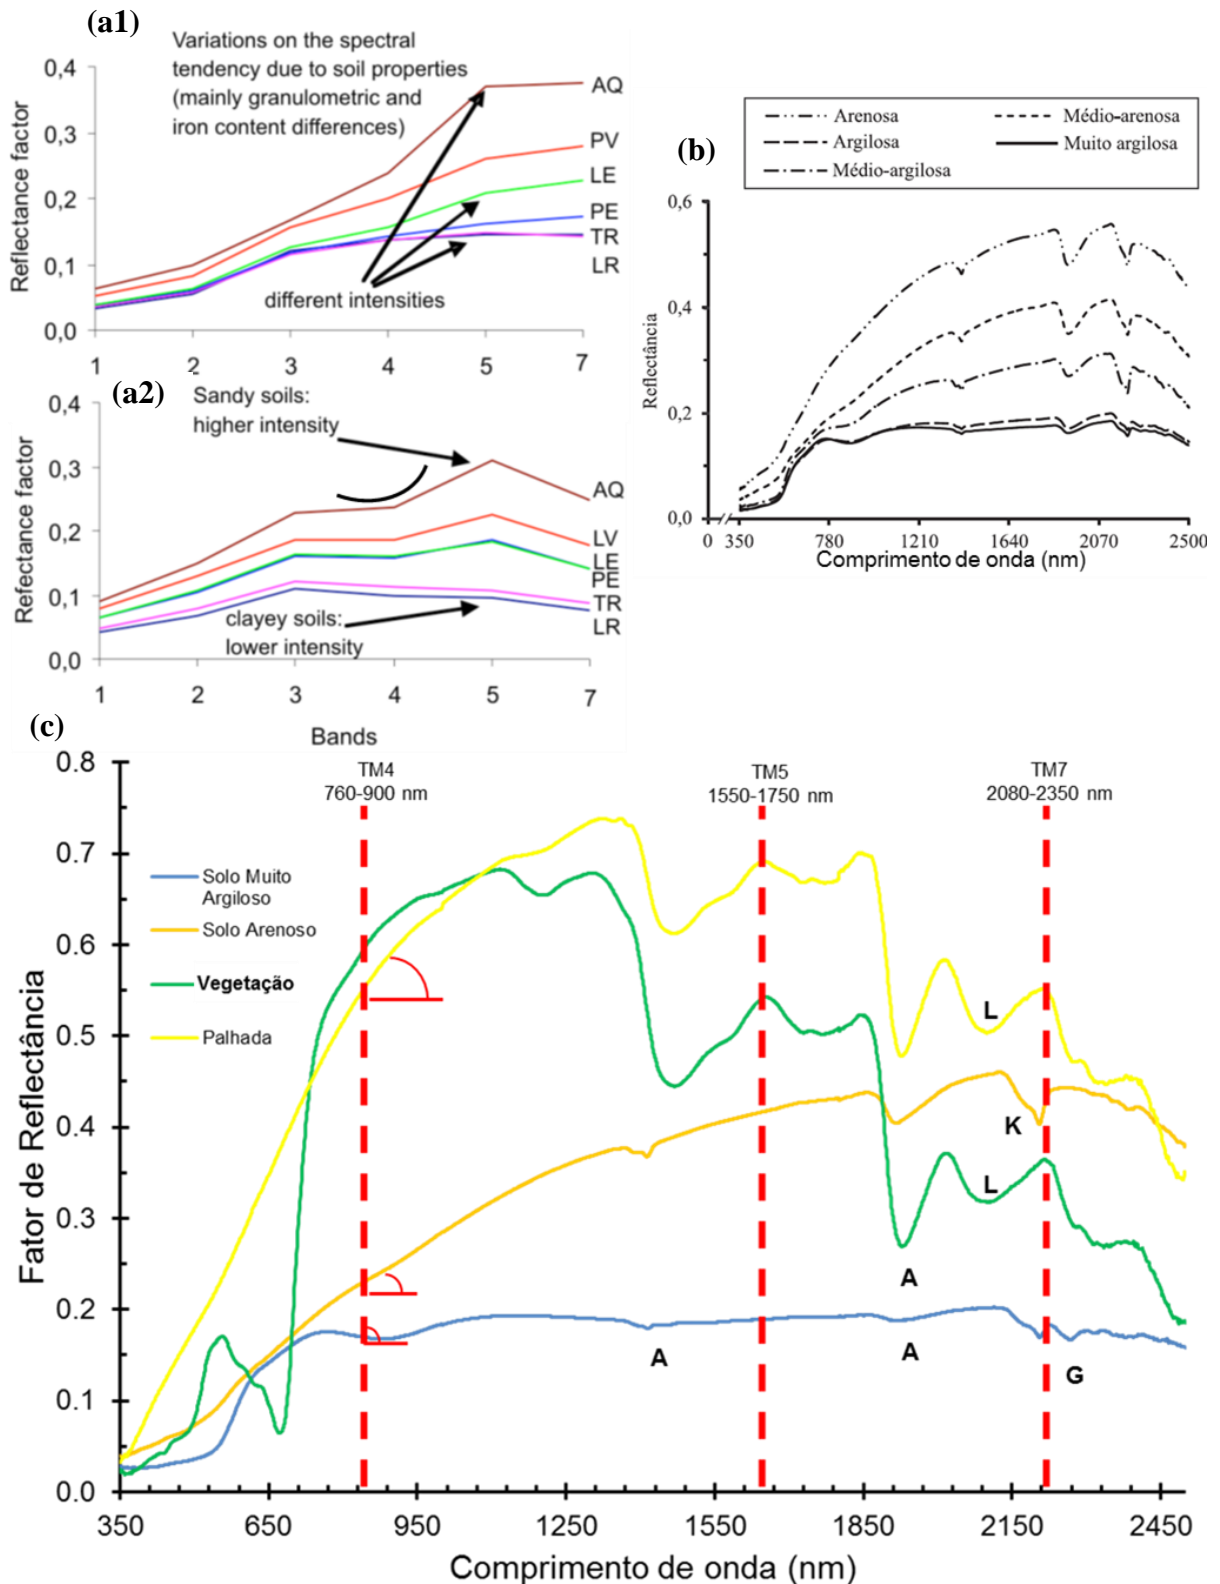


Figura 4 - (a) Dados espectrais de diferentes classes solos obtidos em laboratório e satélite, onde AQ = Neossolo Quartzarênico; PV = Argissolo Vermelho; LE = Latossolo Vermelho; PE = Argissolo Vermelho Escuro; TR = Nitossolo Vermelho férrico; LR = Latossolo Vermelho férrico (Demattê et al., 2009) (b) Dados espectrais obtidos em laboratório de diferentes classes texturais (FRANCESCHINI et al., 2013); (c) resposta espectrais de diferentes alvos, onde L = Lignina; K = Caulinita; G = Gibbsita; A = água; H = hematita

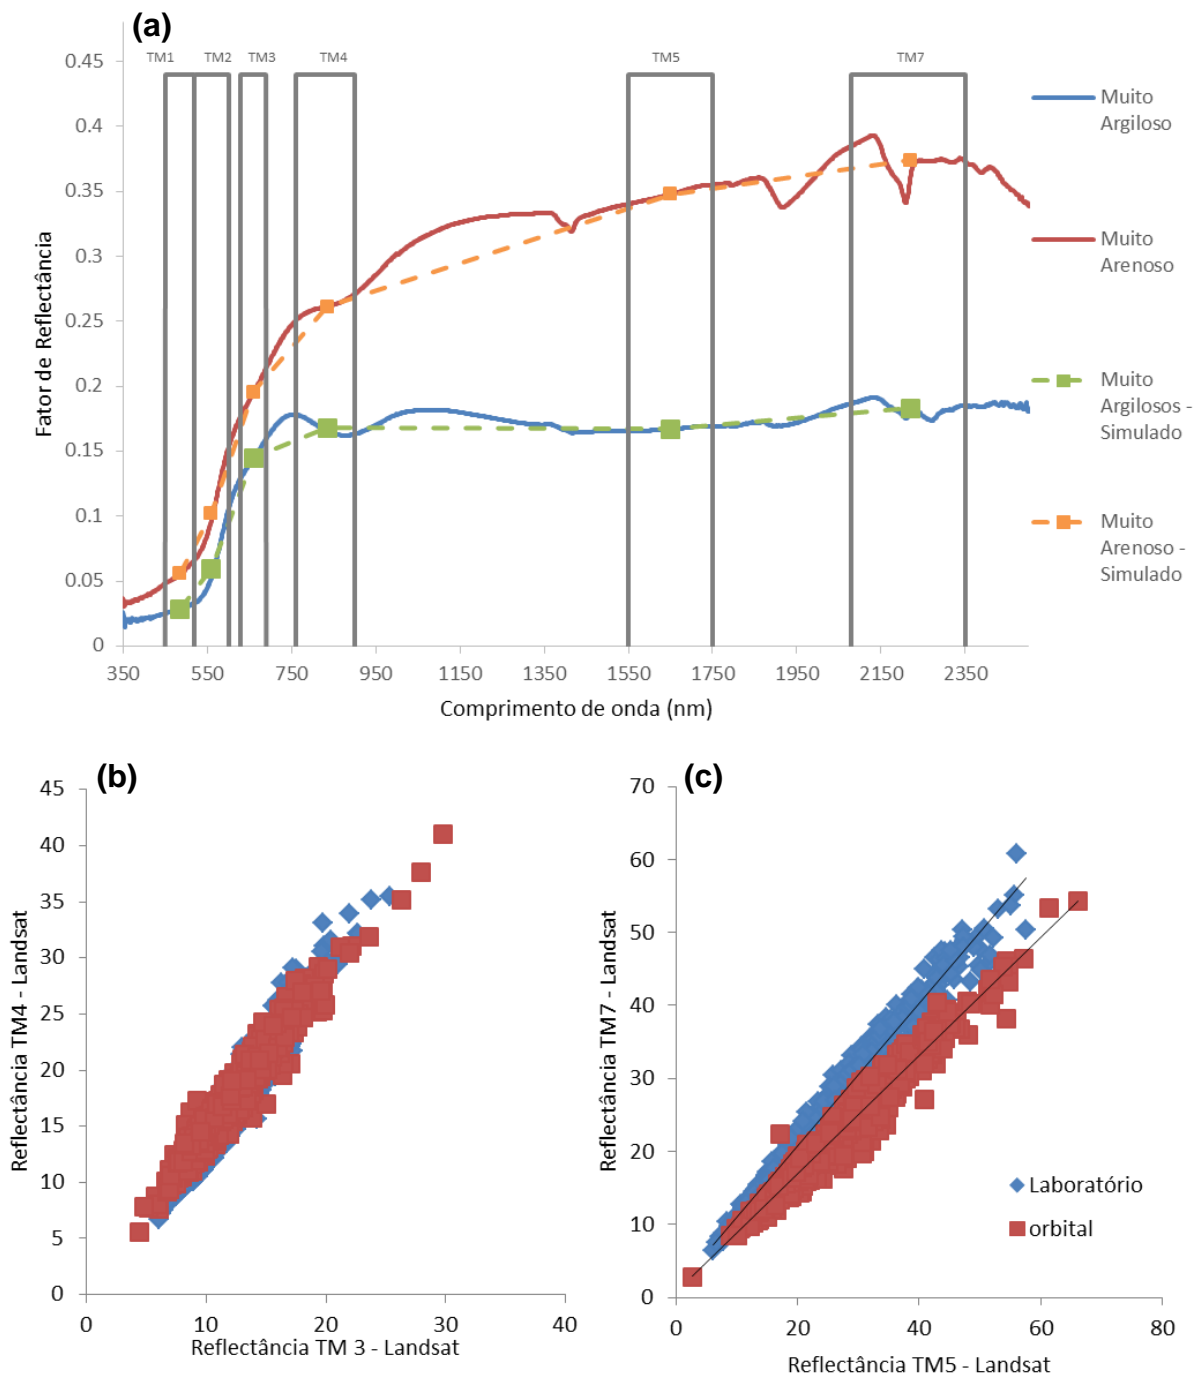


Figura 5 - (a) comparação de espectros entre solos arenosos e argilosos obtidos ao nível laboratório I e relação com as bandas do satélite Landsat 5 (b) relação entre as bandas TM4 e TM3 entre laboratório e orbital com as 639 amostras, (c) comparação entre as bandas TM7 e TM5 entre laboratório e orbital com as 639 amostras.

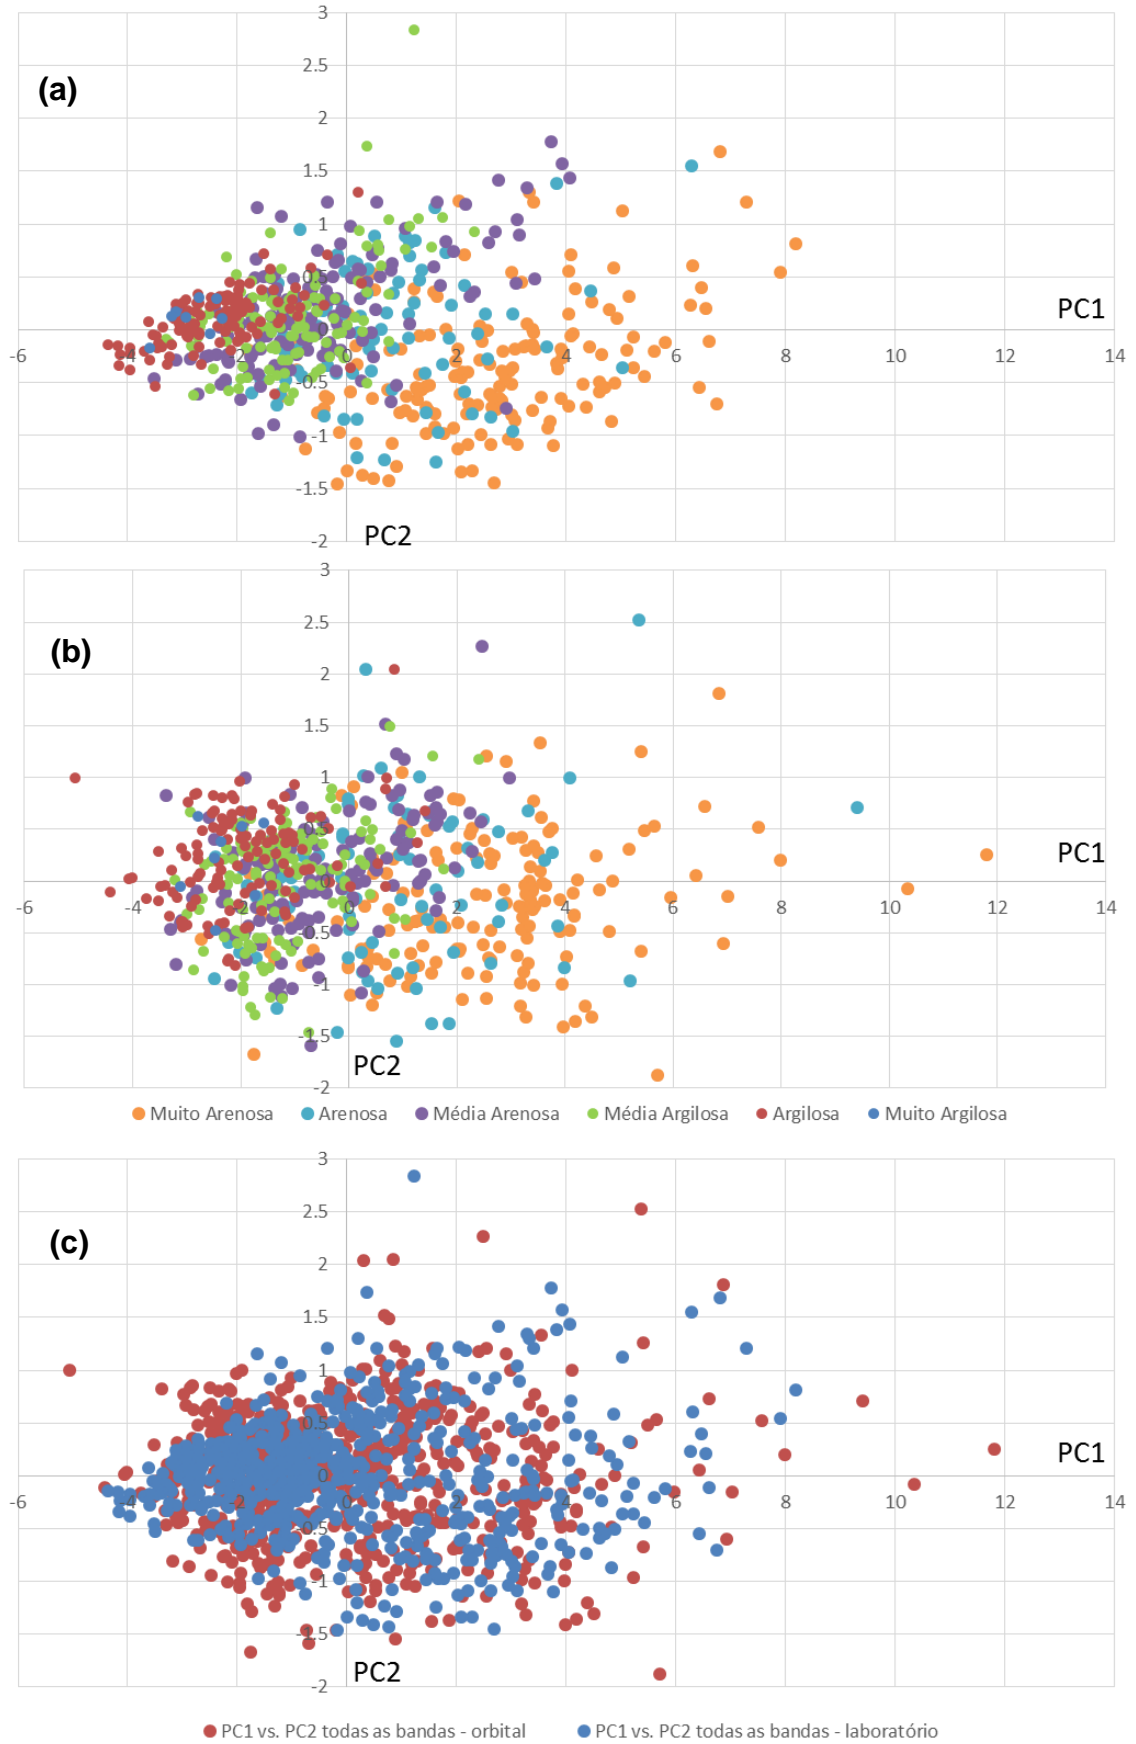


Figura 6 - Componentes principais (PC1 vs PC2) das amostras e classes texturais (a) obtidos em laboratório, (b) obtidos em satélite, (c) comparativo entre satélite e laboratório

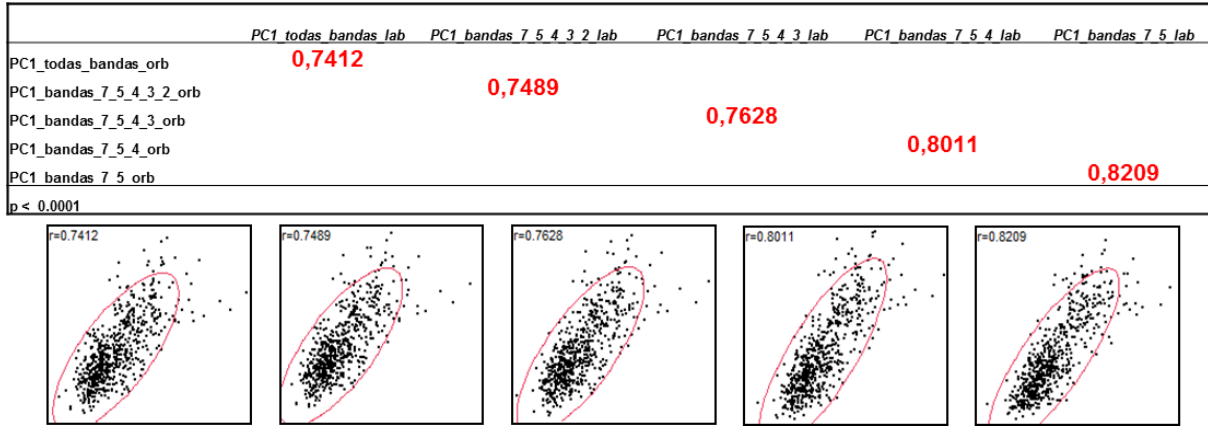


Figura 7 - Correlação entre PC1s orbitais e laboratório

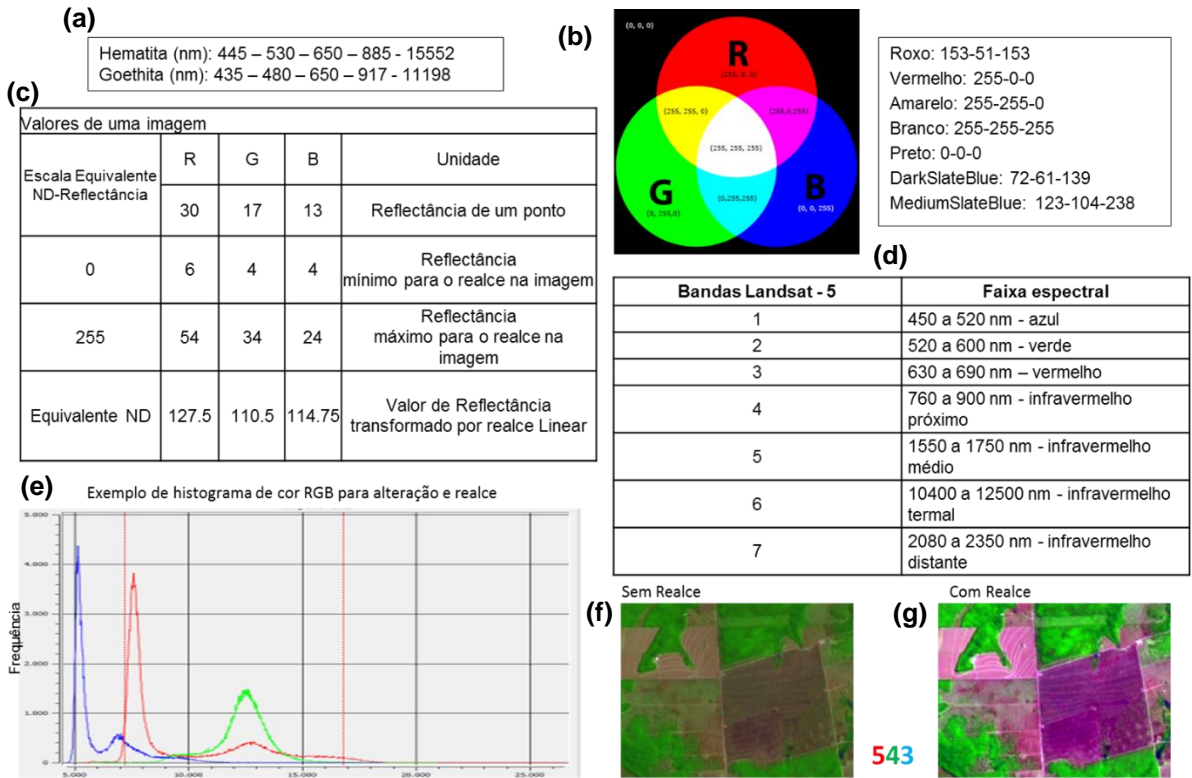


Figura 8 - (a) bandas específicas dos minerais hematita e goethita, (b) ilustração da composição de cores, (c) Exemplos de valores da imagem e relação com realce, (d) bandas do landsat e faixas espectrais, (e) exemplo de histograma de cores RGB para alteração e realce, (f) exemplos de imagem sem e (g) com realce de composição 543, RGB

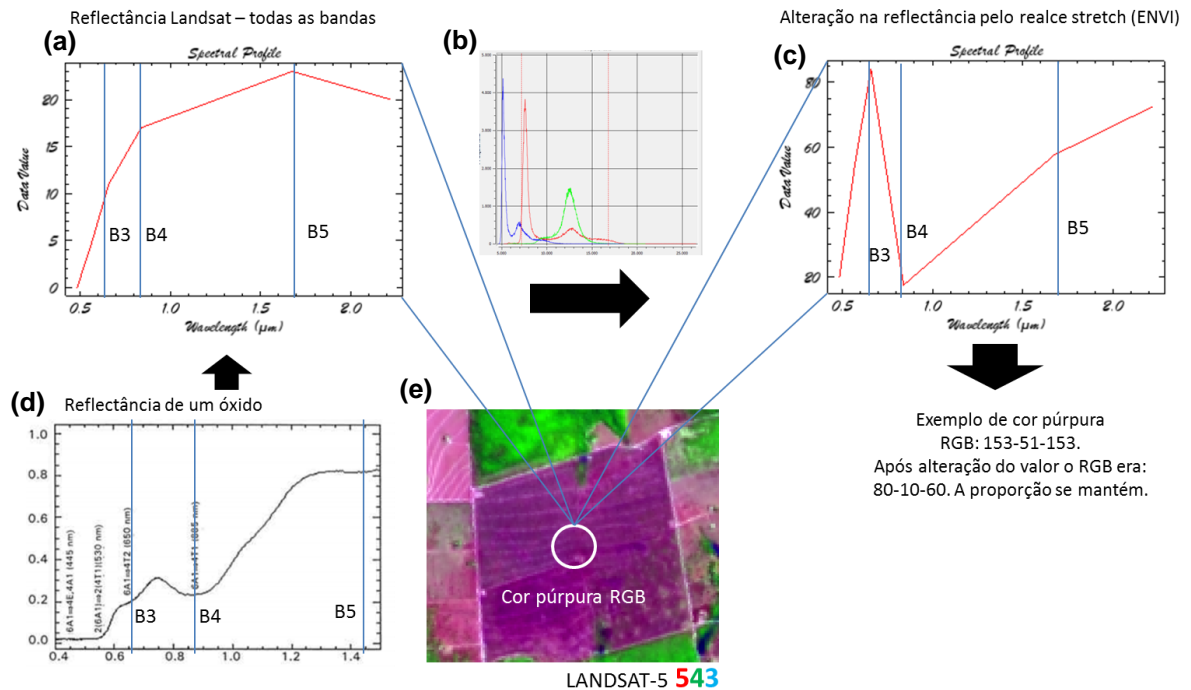


Figura 9 - (a) curva espectral solo exposto argiloso, (b) histograma RGB, (c) alteração da curva espectral no sistema RGB após realce, (d) reflectância óxido, (e) solo exposto púrpura (arroxado) após o realce

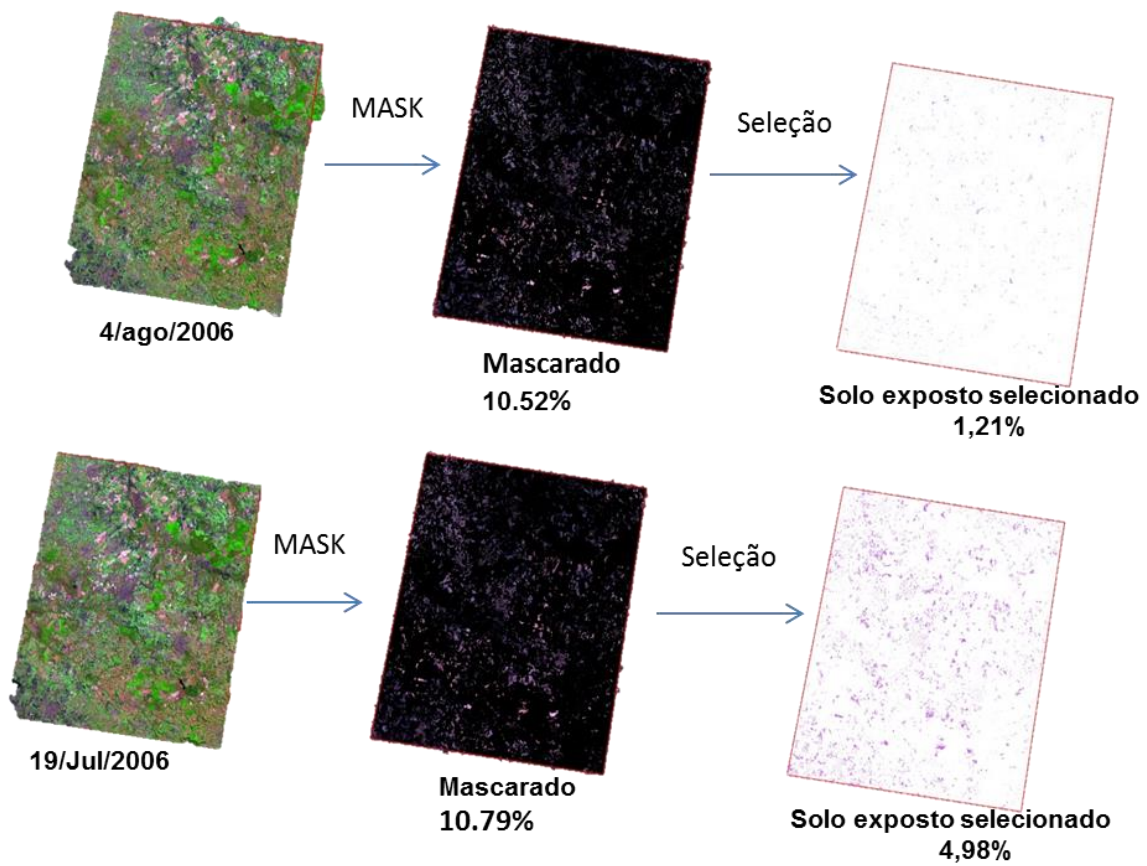


Figura 10 - Comparação de casos desde a imagem inicial, passando pela fase de mascaramento até a seleção de áreas com solo exposto




Figura 11 - Imagem de satélite multitemporal com 43% de solo exposto e respectivos detalhamentos

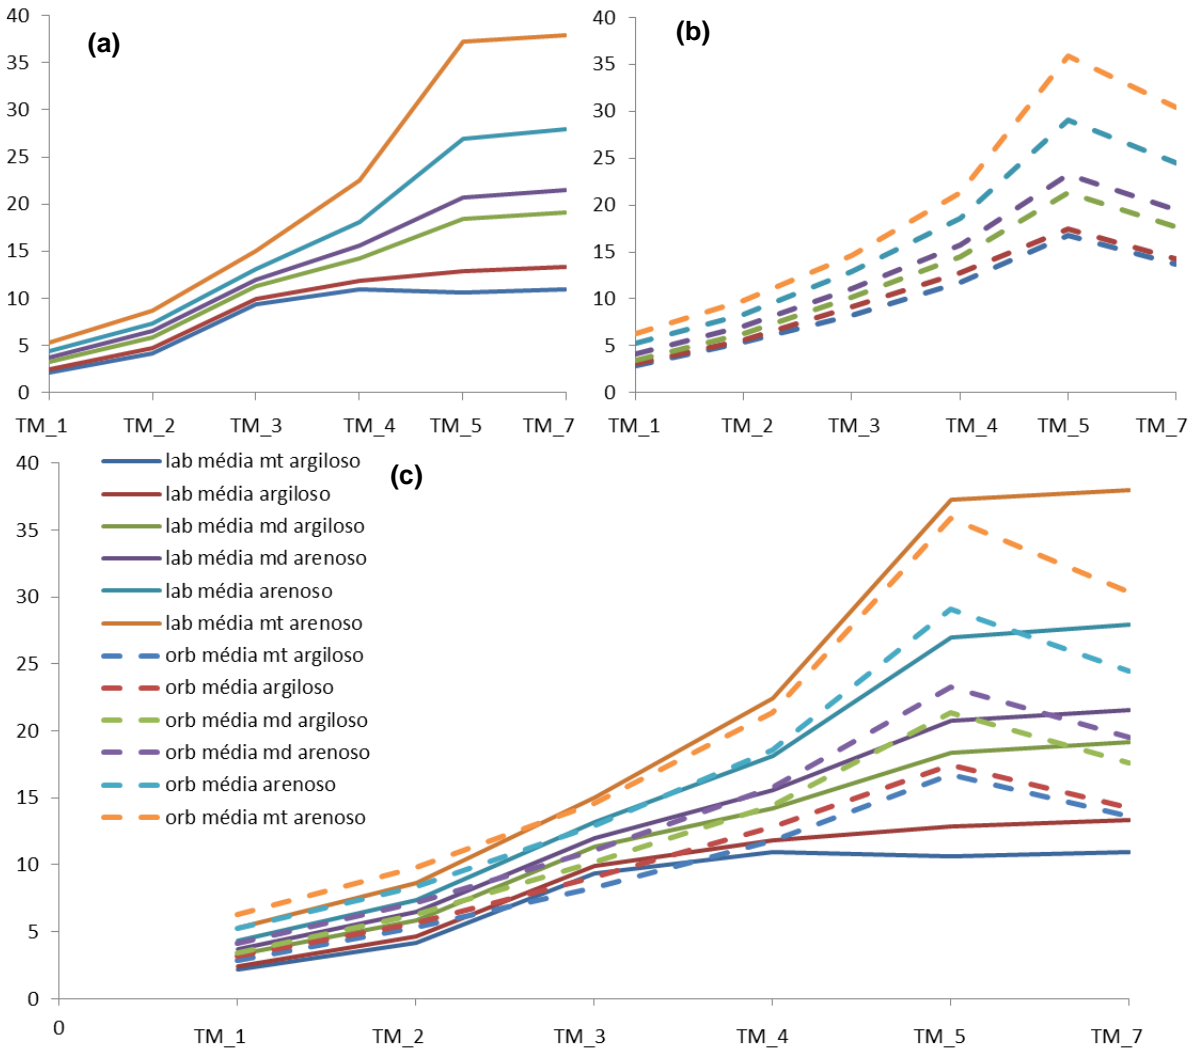


Figura 12 - (a) Curvas espectrais médias obtidas em laboratório (400-2500 nm) simulados para o Landsat TM, (b) curvas espectrais obtidas pelos pixels da imagem Landsat TM, (c) curvas inseridas graficamente de maneira comparativa (laboratório e orbital)

Tabela 1 - Análise estatística das análises granulométricas das amostras da área de estudo

Atributo	n	Média	σ	Soma	Mínimo	Máximo
				g.kg-1		
Areia		707	208.9	451804	86	969
Silte	639	63.6	64.8	40628	2	347
Argila		229.4	153	146568	7	643

n. número de amostras; σ . desvio padrão

Tabela 2 - Matriz de correlação entre bandas simulada de laboratório e orbitais

	<i>TM1_lab</i>	<i>TM2_lab</i>	<i>TM3_lab</i>	<i>TM4_lab</i>	<i>TM5_lab</i>	<i>TM7_lab</i>	<i>TM1_orb</i>	<i>TM2_orb</i>	<i>TM3_orb</i>	<i>TM4_orb</i>	<i>TM5_orb</i>	<i>TM7_orb</i>
<i>TM1_lab</i>	1.0000											
<i>TM2_lab</i>	0.9765	1.0000										
<i>TM3_lab</i>	0.8610	0.9404	1.0000									
<i>TM4_lab</i>	0.8904	0.9371	0.9609	1.0000								
<i>TM5_lab</i>	0.8548	0.8636	0.8525	0.9537	1.0000							
<i>TM7_lab</i>	0.8380	0.8470	0.8425	0.9380	0.9909	1.0000						
<i>TM1_orb</i>	0.5969	0.5926	0.5470	0.6189	0.6248	0.6048	1.0000					
<i>TM2_orb</i>	0.6419	0.6469	0.6044	0.6815	0.6904	0.6679	0.9125	1.0000				
<i>TM3_orb</i>	0.5947	0.6129	0.6050	0.6763	0.6874	0.6693	0.8128	0.9251	1.0000			
<i>TM4_orb</i>	0.6355	0.6494	0.6348	0.7223	0.7461	0.7289	0.7972	0.9230	0.9713	1.0000		
<i>TM5_orb</i>	0.6781	0.6659	0.6281	0.7504	0.8126	0.7914	0.7679	0.8563	0.8822	0.9209	1.0000	
<i>TM7_orb</i>	0.6872	0.6753	0.6371	0.7644	0.8340	0.8197	0.7406	0.8483	0.8886	0.9226	0.9777	1.0000

$p < 0.0001$

Tabela 3 - Valores de área de solo exposto obtidas nas imagens do satélite Landsat e respectivas datas

	DATA	MASCARADO		SELECIONADO	
		área (ha)	Máscara %	área(ha)	Selecionado%
1	6/1/2006	108,105.66	7.40%	35,357.85	2.42%
2	8/1/2005	99,866.88	6.83%	5,166.81	0.35%
3	9/2/1999	92,280.51	6.31%	20,468.79	1.40%
4	6/3/2001	50,411.25	3.45%	27,527.94	1.88%
5	9/3/2011	59,311.62	4.06%	4,455.00	0.30%
6	8/4/2006	153,812.79	10.52%	17,612.37	1.21%
7	9/5/2006	39,624.12	2.71%	2,460.51	0.17%
8	8/6/2001	97,823.88	6.69%	33,879.33	2.32%
9	8/7/2007	69,577.29	4.76%	14,943.96	1.02%
10	9/7/1995	63,519.57	4.35%	11,004.57	0.75%
11	9/8/2007	17,244.54	1.18%	1,396.44	0.10%
12	7/10/1997	64,591.83	4.42%	53,454.60	3.66%
13	9/10/2008	55,319.31	3.79%	6,604.02	0.45%
14	9/10/2011	18,952.38	1.30%	1,754.73	0.12%
15	6/12/2010	65,059.29	4.45%	32,197.95	2.20%
16	8/12/2009	27,296.01	1.87%	6,785.64	0.46%
17	9/13/2009	6,791.13	0.46%	423.18	0.03%
18	6/14/2005	65,367.54	4.47%	14,148.54	0.97%
19	8/14/2004	26,743.23	1.83%	4,897.53	0.34%
20	6/15/2011	69,608.61	4.76%	34,438.59	2.36%
21	8/15/2010	43,394.04	2.97%	8,325.72	0.57%
22	7/16/2005	97,915.68	6.70%	31,554.36	2.16%
23	9/16/2010	40,238.91	2.75%	5,474.88	0.37%
24	8/17/2005	152,901.27	10.46%	65,879.55	4.51%
25	8/18/2001	67,687.38	4.63%	10,112.49	0.69%
26	7/19/2006	157,749.12	10.79%	72,796.32	4.98%
27	8/19/2000	61,443.27	4.20%	13,867.38	0.95%
28	9/19/2011	12,440.79	0.85%	1,179.00	0.08%
29	9/20/2000	31,236.12	2.14%	4,084.20	0.28%
30	8/22/1995	27,456.66	1.88%	9,239.94	0.63%
31	8/23/2007	43,480.08	2.98%	3,767.58	0.26%
32	8/25/2008	27,676.26	1.89%	5,514.93	0.38%
33	8/28/2009	8,070.66	0.55%	590.31	0.04%
34	7/29/1998	74,396.16	5.09%	45,348.48	3.10%
35	7/30/2010	58,847.49	4.03%	19,922.13	1.36%
36	8/30/2004	45,860.94	3.14%	4,043.97	0.28%
37	8/31/2010	31,758.12	2.17%	4,207.32	0.29%
38	10/31/2009	7,021.26	0.48%	1,577.16	0.11%
Média		58,970.57	4.04%	16,749.05	1.15%
σ		39,244.20	2.69%	18,518.20	1.15%
Soma		2,240,881.65	-----	636,464.07	43.55%
Mínimo		6,791.13	0.46%	423.18	0.03%
Máximo		157,749.12	10.79%	72,796.32	4.98%

 σ . Desvio padrão

Referências

- ACKERSON, J.P.; DEMATTÊ, J.A.M.; MORGAN, C. L.S. Predicting clay content on field-moist intact tropical soils using a dried, ground VisNIR library with external parameter orthogonalization. **Geoderma**, Amsterdam, v. 259, p. 196-204, 2015
- ALHO, C.R.J.; MARTINS, E. de S. **De grão em grão, o cerrado perde espaço (cerrado-impactos do processo de ocupação)**. WWF, 1995. 66p.
- ARRUDA, G.P.; J.A.M.; DEMATTÊ; CHAGAS, C.S. MAPEAMENTO DIGITAL DE SOLOS POR REDES NEURAS ARTIFICIAIS COM BASE NA RELAÇÃO SOLO-PAISAGEM. **Revista Brasileira de Ciências do Solo**, Viçosa, v.37, p.327-338, 2013.
- BARET, F.; GUYOT, G. Potentials and limits of vegetation indices for LAI and APAR assessment. **Remote Sensing of Environment**, New York, v. 35, n. 2, p. 161-173, 1991.
- BAUMGARDNER, M.F.; STONER, E.R.; SILVA, L.F.; BIEHL, L.L. Reflective properties of soils. In: BRADY, N. (Ed), **Advances in Agronomy**, New York, v. 38, p. 1-44, 1985.
- BEN-DOR, E.; KAFRI, A.;VARACALLI, G. Shalom: an italian- israeli hyperspectral orbital mission - update. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM, Quebec, Canada. July 13–18, 2014.p WE2.09.2
- BOARDMAN, J. W.; KRUSE, F. A.; GREEN, R. O. Mapping target signatures via partial unmixing of AVIRIS data. In: **Proc. JPL airborne earth sci. workshop**. 1995. p. 23-26.
- BOARDMAN, J.W.; KRUSE, F. A. Automated spectral analysis: a geological example using AVIRIS data, north Grapevine Mountains, Nevada. In: THEMATIC CONFERENCE ON GEOLOGIC REMOTE SENSING, 1994.Michigan **Proceedings...** Environmental Research Institute of Michigan, 1994. p. I-407.
- BRADY, N.C.; WEIL, R.R. **Elementos da natureza e propriedades dos solos**. Porto Alegre: Bookman, 2013. p. 1-29
- BRICKLEMYER, R.S.; BROWN, D.J. On-the-go VisNIR: Potential and limitations for mapping soil clay and organic carbon. **Computers and Electronics in Agriculture**, Oxon, v. 70, n. 1, p. 209-216, 2010.
- BUOL, S.W. Soils and agriculture in central-west and north Brazil. **Scientia Agricola**, Piracicaba, v. 66, n. 5, p. 697-707, 2009.
- CAMARGO, O.; MONIZ, A.; JORGE, J. ; VALADARES, J. **Métodos de análise química, mineralógica e física de solos do Instituto Agronômico de Campinas**. Campinas, Instituto Agronômico de Campinas, 1986. 94p. (Boletim Técnico, v. 106).
- CASA, R.;CASTALDI, F.; PASCUCCI, S.; PALOMBO, A.; PIGNATTI, S. A comparison of sensor resolution and calibration strategies for soil texture estimation from hyperspectral remote sensing. **Geoderma**, Amsterdam, v. 197, p. 17-26, 2013

COLEMAN, T.L.; AGBU, P.A.; MONTGOMERY, O.L., GAO, T.; PRASAD, S. Spectral band selection for quantifying selected properties in highly weathered soils. **Soil Science**, Baltimore v. 151, n. 5, p. 355-361, 1991.

CPRM. Serviço Geológico DO BRASIL. **Mapa Geológico do Estado de São Paulo**. SIG Brasil, v. 1, n. 2006, Escala: 1:750.000. 1 CDROM.

PIMENTEL, D. ; ALLEN, J. ; BEERS, A. ; GUINAND, L. ; LINDER, R. ; MCLAUGHLIN, P. ; MEER, B. ; MUSONDA, D. PERDUE, S. POISSON, S. SIEBERT, K. STONER, R. SALAZAR; HAWKINS, A. World agriculture and soil erosion. **BioScience**, Oxford, v 37, n.4 p. 277-283, 1987.

DEMATTÊ, J.A.M.; BELLINASSO, H.; ROMERO, D.J.; FONGARO, C.T. Morphological Interpretation of Reflectance Spectrum (MIRS) using libraries looking towards soil classification. **Scientia Agricola**, Piracicba, v. 71, n. 6, p. 509-520, 2014.

DEMATTÊ, J.A.M. GALDOS, M. V.; GUIMARÃES, R.V.; GENÚ, A.M.; NANNI, M. R.; ZULLO JR, J. Quantification of tropical soil attributes from ETM+/LANDSAT-7 data. **International Journal of Remote Sensing**, Oxon, v. 28, n. 17, p. 3813-3829, 2007.

DEMATTÊ, J.A.M.; HUETE, A.R.; FERREIRA JÚNIOR, L.G.; NANNI, M.R.; ALVES, M.C.; FIORIO, P.R. Methodology for bare soil detection and discrimination by Landsat TM image. **Open Remote Sensing Journal**, Sharjah, v. 2, p. 24-35, 2009a.

DEMATTÊ, J.A.M.; MORETI, D.; VASCONCELOS, A.D.; GENÚ, A.M. Uso de imagens de satélite na discriminação de solos desenvolvidos de basalto e arenito na região de Paraguaçu Paulista. **Pesquisa Agropecuária Brasileira**, Brasília, v. 40, n. 7, p. 697-706, 2005.

DEMATTÊ, J.A.M.; SOUSA, A.A. ALVES, M.C.; NANNI, M.R. FIORIO, P.R.; CAMPOS, R.C. Determining soil water status and other soil characteristics by spectral proximal sensing. **Geoderma**, Amsterdam, v. 135, p. 179-195, 2006.

DEMATTÊ, J.A.M.; FIORIO, P.R.; BEN-DOR, E. Estimation of soil properties by orbital and laboratory reflectance means and its relation with soil classification. **Open Remote Sensing Journal**, Sharjah, v. 2, p. 12-23, 2009b.

DEMATTÊ, J.A.M.; NANNI, M.R. Weathering sequence of soils developed from basalt as evaluated by laboratory (IRIS), airborne (AVIRIS) and orbital (TM) sensors. **International Journal of Remote Sensing**, Oxon, v. 24, n. 23, p. 4715-4738, 2003.

DEMATTE, J.A.M.; TOLEDO, A.M.A.; SIMOES, M.S. Metodologia para reconhecimento de três solos por sensores: laboratorial e orbital. **Revista Brasileira de Ciências do Solo**, Viçosa, v. 28, n. 5, p. 877-889, Oct. 2004.

DEMATTÊ, J.A.M. Characterization and discrimination of soils by their reflected electromagnetic energy. **Pesquisa Agropecuária Brasileira**, Brasília, v.37, p.1445-1458, 2002.

DEMATTE, J.L.I.; DEMATTE, J.A.M. Ambientes de produção como estratégia de manejo na cultura de cana-de-açúcar. **Informações Agronômicas**, Piracicaba, n.127, p.10-18, 2009.

DEMATTE, J.A.M.; RIZZO, R.; BORTOLETTO, M. A. M. Método geotecnológico integrativo na caracterização de solos desenvolvidos de diferentes materiais de origem. **Bragantia**, Campinas, v. 70, n. 3, p. 638-648, 2011.

DEMATTE, J. A.M.; RIZZO, R.; BOTTEON, V.W.. Pedological mapping through integration of digital terrain models spectral sensing and photopedology. **Revista Ciência Agronômica**, Fortaleza v. 46, n. 4, p. 669-678, 2015.

DETAR, W. R.; CHESSON, J. H; PENNER, J. V.; OJALA, J. C.. Detection of Soil Properties with Airborne Hyperspectral Measurements of Bare Fields. **Transactions of the ASABE**, ST Joseph, v. 51, p 463-470, 2008.

FAOSTAT. **População Mundial**. Disponível em: <<http://faostat.fao.org/>>. Acesso em: 14 out. 2015.

FIORIO, P.R.; DEMATTE, J.A.; NANNI, M.R.; FORMAGGIO, A.R. Diferenciação espectral de solos utilizando dados obtidos em laboratório e por sensor orbital. **Bragantia**, Campinas ,v. 69, n. 2, p. 453-466, 2010

FIORIO, P. R.; DEMATTE, J. A. M. Orbital and laboratory spectral data to optimize soil analysis. **Scientia Agricola**, Piracicaba, v. 66, n. 2, p. 250-257, 2009.

FRANCESCHINI, M.H.D.; DEMATTE, J.A.M. DA SILVA TERRA, F.; VICENTE, L. E.; BARTHOLOMEUS, H.; DE SOUZA FILHO, C.R. Prediction of soil properties using imaging spectroscopy: Considering fractional vegetation cover to improve accuracy. **International Journal of Applied Earth Observation and Geoinformation**, Amsterdam, v. 38, p. 358-370, 2015.

FRANCESCHINI, M.H.D.; DEMATTE, J.A.M.; SATO, M.V.; VICENTE, L.E., GREGO, C.R. Semiquantitative and quantitative approaches for soil texture evaluation through VIS-NIR-SWIR bidirectional reflectance spectroscopy. **Pesquisa Agropecuária Brasileira**, Brasília, v. 48, n. 12, p. 1569-1582, 2013

GHAEMI, M.; ASTARAEI, A.R.; SANAEINEJAD, S.H.; ZARE, H. Using satellite data for soil cation exchange capacity studies. **International Agrophysics**, Warsaw, v. 27, n. 4, p. 409-417, 2013.

GOLDSHLEGER, N.; BEN-DOR, E.; BENYAMINI, Y.; AGASSI, M.; BLUMBERG, D.G. Characterization of soil's structural crust by spectral reflectance in the SWIR region (1.2–2.5 μm). **Terra Nova**, Hoboken, v. 13, n. 1, p. 12-17, 2001.

GOMEZ, C.; LAGACHERIE, P.; COULOUMA, G.. Continuum removal versus PLSR method for clay and calcium carbonate content estimation from laboratory and airborne hyperspectral measurements. **Geoderma**, Amsterdam, v. 148, n. 2, p. 141-148, 2008.

GOMEZ, C.; LAGACHERIE, P.; COULOUMA, G.. Regional predictions of eight common soil properties and their spatial structures from hyperspectral Vis–NIR data. **Geoderma**, Amsterdam, v. 189, p. 176-185, 2012.

GREEN, A.A; BERMAN, M.; SWITZER, P.; CRAIG, M.D. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. **Geoscience and Remote Sensing, IEEE Transactions on**, Piscataway, v. 26, n. 1, p. 65-74, 1988.

GUERSCHMAN, J.P. HILL, M.J. RENZULLO, L.J. BARRETT, D.J.; MARKS, A.S.; BOTHA, E.J. Estimating fractional cover of photosynthetic vegetation, non-photosynthetic vegetation and bare soil in the Australian tropical savanna region upscaling the EO-1 Hyperion and MODIS sensors. **Remote Sensing of Environment**, New York, v. 113, n. 5, p. 928-945, 2009.

HAUBROCK, S.N. CHABRILLAT, S.; LEMMNITZ, C.; KAUFMANN, H. Surface soil moisture quantification models from reflectance data under field conditions. **International Journal of Remote Sensing**, Oxon, v. 29, n. 1, p. 3-29, 2008.

HENDERSON, B.L.; BUI, E.N.; MORAN, C.J.; SIMON, D.A.P. Australia-wide predictions of soil properties using decision trees. **Geoderma**, Amsterdam, v. 124, n. 3, p. 383-398, 2005.

HENDERSON, T.L.; BAUMGARDNER, M.F.; FRANZMEIER, D.P. STOTT, D.E. ; COSTER, D.C. High dimensional reflectance analysis of soil organic matter. **Soil Science Society of America Journal**, Madison, v. 56, n. 3, p. 865-872, 1992.

HENZ, G.P.; RAGASSI, C.F.; ANJOS, U.G.; FERRAZ, R.M. **Novos ângulos da história da agricultura no Brasil**. Embrapa Informação Tecnológica, 2010. 112p.

HIVELY, W.D.; MCCARTY, G.W. REEVES, J.B.; LANG, M.W. OESTERLING, R. A.; DELWICHE, S.R. Use of airborne hyperspectral imagery to map soil properties in tilled agricultural fields. **Applied and Environmental Soil Science**, Cairo, v. 2011, n. 358193, 2011.

IBGE. **Censo Agropecuário: 1995-1996**. Rio de Janeiro, 1997. 265p.

IUSS WORKING GROUP, W.R.B. **World reference base for soil resources. World Soil Resources Report**, Rome, v. 103, 2014, 191p.

JENSEN, J. R.; EPIPHANIO, J.C. Neves. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese Editora, 2009. 585p.

KALNAY, E.; CAI, M.. Impact of urbanization and land-use change on climate. **Nature**, London, v. 423, n. 6939, p. 528-531, 2003.

KHANNA, S.; PALACIOS-ORUETA, A.; WHITING, M.L.; USTIN, S.L.; RIAÑO, D., ; LITAGO, J. Development of angle indexes for soil moisture estimation, dry matter detection and land-cover discrimination. **Remote Sensing of Environment**, New York, v. 109, n. 2, p. 154-165, 2007

LAGACHERIE, P.; MCBRATNEY, A.; VOLTZ, M. **Digital soil mapping**: An introductory perspective. Amsterdam: Elsevier, 2006.595p.

LAL, R. Soil carbon sequestration impacts on global climate change and food security. **Science**, Washington, v. 304, n. 5677, p. 1623-1627, 2004.

LEMENTS, E.A.; FERNANDES, B. Land grabbing, agribusiness and the peasantry in Brazil and Mozambique. **Agrarian South: Journal of Political Economy**, Los Angeles, v. 2, n. 1, p. 41-69, 2013.

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

Madeira, N.J. **Etude Quantitative des Relations Constituants Minéralogiques-Réfectance Diffuse des Latosols Brésiliens**: Application à l'utilisation Pédologique des Données Satellitaires TM (Région de Brasília); Paris, France: Université Pierre et Marie Curie: 1993. 250p.

MASOUD, A. A. Predicting salt abundance in slightly saline soils from Landsat ETM+ imagery using spectral mixture analysis and soil spectrometry. **Geoderma**, Amsterdam, v. 217, p. 45-56, 2014.

MCBRATNEY, A.B.; GRUIJTER, J.J. de. A continuum approach to soil classification by modified fuzzy k-means with extragrades. **Journal of Soil Science**, Hoboken, v. 43, n. 1, p. 159-175, 1992.

MCBRATNEY, A.B.; SANTOS, M.L.; MENDONÇA; MINASNY, B. On digital soil mapping. **Geoderma**, Amsterdam, v. 117, n. 1, p. 3-52, 2003.

MCCORMACK, D.E. Soil potentials: A positive approach to urban planning. **Journal of Soil Water Conservation** Ankeny ,v. 29, p. 258-262, 1974.

MENDONÇA-SANTOS, M.L.; DOS SANTOS, H.G. The state of the art of Brazilian soil mapping and prospects for digital soil mapping. **Developments in Soil Science**, Amsterdam v. 31, p. 39-601, 2006.

MMA. **O Bioma Cerrado**, 2015. Disponível em: <<http://www.mma.gov.br/biomas/cerrado>>. Acesso em: 13 de out. 2015.

MULDER, V.L.; DE BRUIN, S.; SCHAEPMAN, M.E.; MAYR, T.R. The use of remote sensing in soil and terrain mapping—A review. **Geoderma**, Amsterdam v. 162, n. 1, p. 1-19, 2011.

MUSICK, H. B.; PELLETIER, R. E. Response to soil moisture of spectral indexes derived from bidirectional reflectance in thematic mapper wavebands. **Remote Sensing of Environment**, New York, v. 25, n. 2, p. 167-184, 1988.

NANNI, M.R.; DEMATTÊ, J.A.M.; CHICATI, M.L.; FIORIO, P.R.; CÉZAR, E.; OLIVEIRA, R.B.D. Soil surface spectral data from Landsat imagery for soil class discrimination. **Acta Scientiarum. Agronomy**, Maringá v. 34, n. 1, p. 103-112, 2012.

- NANNI, M.R.; DEMATTÊ, J.A. M. Spectral reflectance methodology in comparison to traditional soil analysis. **Soil Science Society of America Journal**, Madison, v. 70, n. 2, p. 393-407, 2006.
- NANNI, M.R.; DEMATTÊ, J.A.M. Soil line behavior obtained by laboratorial spectroradiometry for different soil classes. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 30, n. 6, p. 1031-1038, 2006.
- ORESQUES, N. The scientific consensus on climate change. **Science**, Washington, v. 306, n. 5702, p. 1686-1686, 2004.
- PIZARRO, M.A.; EIPHANIO, J.C. NEVES; GALVAO, L.S. Caracterização mineralógica de solos tropicais por sensoriamento remoto hiperespectral. **Pesquisa Agropecuária Brasileira**, Brasília , v. 36, n. 10, p. 1277-1286, Oct. 2001 .
- R Core Team (2015). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. URL, <https://www.R-project.org/>.
- ROLIM, G.D.S.; CAMARGO, M.D.; LANIA, D.G.; MORAES, J.D. Classificação climática de Köppen e de Thornthwaite e sua aplicabilidade na determinação de zonas agroclimáticas para o estado de São Paulo. **Bragantia**, Campinas, v. 66, n. 4, p. 711-720, 2007.
- ROSSEL, R.A. VISCARRA; CHEN, C.. Digitally mapping the information content of visible–near infrared spectra of surficial Australian soils. **Remote Sensing of Environment**, New York, v. 115, n. 6, p. 1443-1455, 2011.
- SCHULER, U.; CHOOCHAROEN, C.; ELSTNER, P.; NEEF, A.; STAHR, K.; ZAREI, M.;HERRMANN, L. Soil mapping for land-use planning in a karst area of N Thailand with due consideration of local knowledge. **Journal of Plant Nutrition and Soil Science**, Weinheim, v. 169, n. 3, p. 444-452, 2006.
- SELIGE, T.; BÖHNER, J.; SCHMIDHALTER, Urs. High resolution topsoil mapping using hyperspectral image and field data in multivariate regression modeling procedures. **Geoderma**, Amsterdam, v. 136, n. 1, p. 235-244, 2006.
- SKOLE, D.; TUCKER, C. Tropical deforestation and habitat fragmentation in the Amazon. Satellite data from 1978 to 1988. **Science**, Washington, v. 260, n. 5116, p. 1905-1910, 1993.
- Soil Survey Staff, Natural Resources Conservation Service, United States Department of Agriculture. **Web Soil Survey**. Disponível em: <http://websoilsurvey.nrcs.usda.gov/> Acesso em: 19 out. 2015.
- SOIL SURVEY STAFF. **Keys to soil taxonomy**. Soil Conservation Service, 2014. 372p.
- SOLOS, Embrapa. Sistema brasileiro de classificação de solos. **Centro Nacional de Pesquisa de Solos: Rio de Janeiro**, 2013. 253p.

SORIANO-DISLA, J.M.; JANIK, L. J., VISCARRA ROSSEL, R.A., MACDONALD, L. M.; MCLAUGHLIN, M.J. The performance of visible, near-, and mid-infrared reflectance spectroscopy for prediction of soil physical, chemical, and biological properties. **Applied Spectroscopy Reviews**, Philadelphia, v. 49, n. 2, p. 139-186, 2014.

STENBERG, B.; ROSSEL, R.A.V.; MOUAZEN, A.M.; WETTERLIND, J. chap. five-visible and near infrared spectroscopy in soil science. **Advances in agronomy**, Newark, v. 107, p. 163-215, 2010.

VARMUZA, K.; FILZMOSER, P. **Introduction to multivariate statistical analysis in chemometrics**. Boca Raton: CRC Press, 2009. 336p.

VINK, A.D.A. **Fografias aereas y las ciencias del suelo**. Delf: International Training Centre for Aerial Survey, 1963. 200p.

WAISER, T.H.; MORGAN, C.L. BROWN, D.J.; HALLMARK, C.T. In situ characterization of soil clay content with visible near-infrared diffuse reflectance spectroscopy. **Soil Science Society of America Journal**, Madison, v. 71, n. 2, p. 389-396, 2007.

YOUNG, A. Soil survey procedures in land development planning. **Geographical journal**, Cambridge, p. 53-64, 1973.

ZONNEVELD, I.S. The land unit—a fundamental concept in landscape ecology, and its applications. **Landscape Ecology**, Dordrecht, v. 3, n. 2, p. 67-86, 1989.

3 DETERMINAÇÃO E MAPEAMENTO GRANULOMÉTRICO BASEADO EM IMAGENS DE SATÉLITE E ATRIBUTOS DO TERRENO

Resumo

O planeta terra tem grande dimensão, e seus recursos naturais precisam ser mapeados e conhecidos para nortear políticas públicas. O solo é um destes importantes recursos. O seu conhecimento passa pela caracterização e mapeamento pedológico e/ou de seus atributos. Para o adequado monitoramento, é necessário o conhecimento em nível de alta escala, o que demanda recursos humanos, altos custos financeiros e de logística, o que hoje ainda não é possível de se atingir. Neste sentido é preciso investir em tecnologias que auxiliem na obtenção de informações mais rápidas e de baixo custo. Os objetivos deste trabalho foram a quantificação da textura e seu mapeamento através de imagens de satélite e atributos do relevo. A área de estudo localiza-se na região de Araraquara, São Paulo, Brasil, com dimensão de 14.614 km². Dentro desta área foram demarcados 952 pontos para coleta de amostras de terra na camada superficial, as quais foram analisadas granulometricamente em laboratório e georreferenciadas. Sua demarcação seguiu os preceitos do método da topossequência com o intuito de representar a variabilidade da região. Foram obtidas imagens do satélite TM/Landsat 5 multitemporais as quais foram processadas e transformadas em reflectância. As amostras de terra coletadas em campo passaram por sensor em laboratório (350-2500 nm), cujos espectros foram utilizados para validar os obtidos posteriormente das imagens. Nos locais onde foram coletadas as amostras, foram extraídos os dados espectrais perfazendo os gráficos das curvas espectrais as quais foram comparadas com os dados de satélite. Todas as imagens multitemporais foram finalizadas contendo apenas solo exposto, as quais dentro do software R foram sobrepostas e gerou-se uma única imagem toda com solo exposto. Os resultados mostraram que as curvas espectrais de laboratório foram extremamente semelhantes aos das imagens de satélite, seguindo a lógica das variações texturais. Num segundo momento, o trabalho comprova, através de árvores de regressão, através de R² de 0,62 que tanto por imagens de satélite quanto por relevo foi possível quantificar os teores de argila da área da camada superficial. Quando se integra dados de imagens com relevo e geomorfologia, este resultado sobe para 0,72. Por outro lado, o resultado visual quando realizado por imagens de satélite fica melhor do que quando se utiliza relevo devido a ruídos provocados pelos dados matriz do relevo. Outra conclusão é que as imagens de satélite sobrepuseram ou quase que substituíram as informações dos mapas geológicos.

Palavras chave: Sensoriamento remoto; Mapa de solos; Quantificação

Abstract

Planet Earth has great dimension, and its natural resources has to be mapped and monitored, looking towards correct decisions. Soil is one of these important resources. Know soils is related with its characterization and mapping by pedological and attributes recognition. For soil monitoring, its necessary maps in large scale, which demand man power and high cost. Thus, its necessary to invest in geotechnologies, to reach the goal faster and low cost. The objective of this work was to quantify clay and sand contents by satellite images and relief attributes. The area is located in Araraquara, SP, Brazil, with a 14.614 km² dimension. We collected soil samples all over the area with a total of 952 points and 0-20 cm depth, georeferenced, representative of the area. Samples were granulometric analysed and afterwards passed through a vis-nir-swir sensor (400-2500 nm). We collected multitemporal images from landsat satellite from september and october n the last 15 years. Images were atmospheric

corrected and transformed into reflectance. Laboratory spectral data was used to validate pixels spectra information from satellite. We extracted all objects which were not soils from all images. Also, we made processing on the DEM of the area reaching several soil attribute factors. We prove that by regression tree statistics, clay and sand content can be quantified by satellite images with a 0,62 of R², as also with terrain attributes. On the other hand, when we associate image spectral data with terrain attributes, we can reach 0,72 on clay quantification. Despite this, the visual aspect of data, is better using image data than relief, which presented more noise. Another conclusion, is that images could substitute geology information in the models. This work can considerably assist pedologists, farmers and environment professionals on soil monitoring.

Keywords: Remote sensing; Soil mapping; Quantification

3.1 Introdução

Não se discute mais a importância de um mapa de solos. Suas aplicações são inúmeras tais como: conservação do solo, paisagismo, planejamento urbano, manejo físico e químico, alocação varietal, valoração da terra, estimativa de produção, uso da terra, preservação e monitoramento ambiental.

De fato, em recente artigo, Minasny e Mcbratney (2015), ilustram o histórico dos mapeamentos e sua importância para o mundo. Por outro lado, a obtenção deste produto não é fácil. As técnicas tradicionais exigem altos custos com análises de solo e muito trabalho de campo. Isto torna os mapeamentos caros e exigem grande quantidade de mão de obra (Waiser et al., 2007).

A época de grande formação de pedólogos no Brasil, foi justamente durante o desenvolvimento de grandes mapeamentos no mundo nas décadas de 60, 70 e 80 (RADAM). A partir de então, houve uma queda no desenvolvimento de mapas de solos bem como de profissionais da área. De fato, grande discussão sobre o tema foi realizada na década de 2000. Pedólogos vão acabar? Chegou-se a discutir o tema se “pedólogos iriam acabar”. Logo em seguida, porém surge a denominação técnica mapeamento digital de solos criada por McBratney et al. (2003), tal documento deu novos impulsos na área de pedologia, pois mostrou que o entendimento das relações solo/paisagem, poderiam ser feitas por técnicas matemáticas, ou denominadas de pedotransfêrencia. Nisto surge também à pedometria, definida como a “medida do solo”. O artigo promoveu a discussão sobre o novo papel do pedólogo, bem como o surgimento dos “pedometristas”.

De fato, foi justamente a partir de 2000 que houve forte avanço nas atividades computacionais, surgindo inúmeros pacotes estatísticos (rede neurais, fuzzy) até então pouco

conhecidos e utilizados. Observou-se aumento significativo de artigos científicos na década passada, ratificando as alterações de comportamento da comunidade científica internacional.

Os métodos pedométricos e em mapeamento digital, portanto, permitem fortemente o uso de informações quantitativas do solo, obtidas por diferentes produtos desde os cartográficos (modelos de elevação e atributos do relevo) até os por sensoriamento remoto (SR). Neste aspecto e em paralelo ao surgimento do mapeamento digital, o SR já vinha com conceitos físicos definidos desde a década de 50 com o surgimento do primeiro satélite mundial, o Sputnik. Mas foi pelos estudos com sensores terrestres em laboratório com Bowers and Hanks (1965), Hunt et al. (1971) e posteriormente Stoner & Baumgardner (1981), que foi definitivamente a referida área. Porém, de 1980 a 1995 aproximadamente, não surgiram grandes avanços em equipamentos sensores. Nesta época porém, autores como Henderson et al. (1992) e Ben-Dor e Banin (1995), continuaram a fortalecer e ratificar a importância do tema no estudo do solo. De fato, trabalhos reiteraram as possibilidades de quantificação de atributos do solo como argila (VISCARRA ROSSEL et al., 2011), matéria orgânica (TERRA et al., 2015), hematita e goethita (SHERMAN & WAITE, 1985), caulinita (ROSSEL; MCGLYNN & MCBRATNEY, 2010), quartzo (ROSSEL et al., 2006), água (LOBELL & ASNER, 2002), classes texturais (FRANCESCHINI et al., 2013). Assim, a partir de 2000 e em paralelo aos avanços tecnológicos a ao mapeamento digital, o SR ganha enorme impulso. De fato, inúmeros trabalhos comprovam a importância do SR nível terrestre denominado como sensoriamento proximal (DEMATTE el al., 2000; SHEPARD & WALSH, 2002).

Os embasamentos científicos das técnicas terrestres, deram novo impulso às plataformas orbitais. Tanto é que novos sensores multi (Landsat, Aster, Palsar, WorldView, RapidEye, Ikonos, SPOT) e hiperespectrais em satélites (Hyperion) em funcionamento, passaram a ser mais estudados. Até sensores hiperespectrais embarcados em aviões tiveram impulso (FRANCESCHINI et al., 2015), impulsionando novos projetos nível orbital. Da mesma forma a espectroscopia evolui no tema e hoje trabalha na montagem de bibliotecas espectrais em vários países (SCHEPARD & WALSH, 2002, BELLINASSO; DEMATTE & ROMEIRO, 2010). Tais trabalhos tem dois objetivos: (a) auxiliar futuros trabalhos nível terrestre e (b) validar e otimizar os trabalhos com satélites.

Assim, o uso de dados de satélites no conhecimento do solo é de grande relevância, considerando seu potencial na avaliação de grandes áreas, ter dados multitemporais e a forte relação física entre energia e solo. A facilidade de obtenção desse produto é grande. O Brasil foi um dos primeiros países do mundo a disponibilizar gratuitamente imagens do satélite

CBERS. Com isso, o Brasil se tornou por duas vezes o que teve mais usuários e utilizando imagens (INPE/DGI).

Nada que se compare a chegada do Google Earth em 2005. Tal fato foi o maior marco histórico na guinada para popularização de imagens orbitais. Aliado a isso os Estados Unidos através do GLOVIS (*the USGS Global Visualization Viewer*), passaram a disponibilizar imagens de vários satélites, incluindo o mais famoso da história, o Landsat. Lançado pela primeira vez em 1971, o então Landsat 1, chegamos hoje ao Landsat 8, em plena atividade. A facilidade de obtenção, a multitemporalidade (uma imagem a cada 16 dias), as bandas que vão do visível (VIS) ao infravermelho (WIR) e infravermelho de ondas curtas (SWIR), fazem deste produto um dos mais respeitados do mundo.

Os resultados são animadores. Em 1991 Coleman et al. Conseguiu estimar argila com 0,4 de R^2 . Hoje atingimos R^2 de 0,67 (NANNI & DEMATTÊ, 2006); 0,61 (FIORIO et al., 2010). Vale destacar que sensores hiperespectrais de avião atingem até 0,77 (FRANCESCHINI et al., 2015). Ou seja, um multiespectral (6 bandas) com o sensor a 800 km de distância e resolução espacial de 30 metros atinge 0,70% de acerto em relação a um hiperspectral (na faixa de 60 bandas) de avião. Ainda, um hiperespectral em satélite, o Hyperion com 60 bandas, atingiu 0,83 de R^2 para argila (ZHANG et al., 2013). Tais resultados mostram a importância e necessidade de continuidade nos estudos com produtos da família Landsat.

Especificamente em relação a solos, entretanto, é importante destacar a necessidade de solo exposto para sua detecção. Trabalhos nesse sentido tem obtido ótimos resultados (DEMATTÊ et al., 2009). Porém, pedólogos e pedometristas necessitam, não somente onde é o solo exposto, mas de uma informação contínua para se observar todas as variações relacionadas às suas características. Isto vai de acordo com observações de Mcbratney et al., (2003) para quais o solo varia como um continuum e não há limites rígidos. Porém, como “enxergar” essa variação via satélite coma presença de vegetação e/ou intenso manejo agrícola? Para tanto, é preciso gerar uma técnica que consiga “montar” uma imagem “única”, contendo o máximo de informação do solo exposto. Até o momento não se encontra tal técnica, motivo do presente trabalho, o mais próximo a isto foi o recente trabalho de Shabou el al. (2015), que usa uma séria temporal do TM/Landsat 5 para predição de argila, mas não gera uma imagem composta única.

Em contrapartida, sabe-se que o relevo tem forte relação com o solo (DEMATTÊ et al., 2014). De fato, o surgimento de fotografias aéreas no estudo de solo com Vink (1963) gerou a primeira revolução no estudo do solo via sensoriamento remoto. Tal informação

associada ao modelo de derivação do relevo pela pedometria, geraram grandes impulsos nas relações solo paisagem.

O que estaria faltando então para evoluir no tema? A “cor” nada mais é que uma propriedade, mas sem significado físico, e portanto sendo realmente regida pelas suas características. A cor do solo tem íntima relação com características como teor de óxidos matéria orgânica, umidade, drenagem, mineralogia. Logo, a detecção das variações de “cores” podem auxiliar sobremaneira na discriminação de solos. Seria possível fazer essa relação ao nível de satélite? A imagem de satélite capta apenas informações da camada superficial do solo, não sendo possível a mensuração do horizonte B, que é o diagnóstico. Por outro lado, existem estudos que demonstram que características de cor observadas na superfície, tem relação com a dinâmica e fluxo de água na subsuperfície. A detecção pura e simples das variações da cor da superfície podem auxiliar na determinação de “manchas” de solos diferentes, sem se preocupar, neste primeiro momento, com a classificação taxonômica, que ficaria para uma avaliação *in-situ*. De fato, conforme preconizado por Vink (1963), “mapear solos é antes de tudo, mapear coisas distintas e não relativo a classificação”. Seguindo esta linha de raciocínio Demattê et al. (2007), Demattê et al. (2009) e Nanni et al. (2012), discriminaram classes de solos baseado na característica superficial captada por imagem de satélite.

Existe, portanto, uma lacuna de produtos que auxiliem no mapeamento digital de solos. Neste caso, um produto que indique as “cores” de toda a superfície do solo, agregada às formas de relevo podem substancialmente melhorar a precisão dos mapeamentos. Tal produto ainda não foi explorado em sua plenitude. Trabalhos tem realizados no mapeamento de solos usando a relação solo paisagem (ARRUDA et al., 2013), relevo e espectroscopia (VASQUEZ et al., 2015) e fotopedologia associada a aspectos de imagens (DEMATTÊ; RIZZO e BOTTEON, 2015). Entretanto, não se tem notícia de trabalhos agregando imagens multitemporais com solo exposto e derivadas de relevo.

Dentre os atributos de solo de grande relevância está o teor de argila. A fração argila é a que contém grande parte do material vivo do solo, as cargas de retenção, o material orgânico e os óxidos e hidróxidos de ferro e alumínio e mineralogia. A fração argila por tanto, tem grande importância nas relações com nutrientes do solo, retenção de água e agregação do solo. Fortes impactos no sistema ocorrem em solos com diferentes teores de argila. Considerando estar nesta fração e por conseguinte a classe textural do solo, as relações com elementos fortemente relacionados a energia eletromagnética refletida, seu mapeamento se mostra de alta relevância. Os trabalhos em mapeamento digital têm preconizado a espacialização de uma classe de solo ou atributo, através da denominada pedotransferência. Ou

seja, esse método, tendo um local padrão conhecido, infere o resultado de um local desconhecido. Por outro lado, os espectros de reflectância obtidos por uma imagem de satélite são fenômenos diretamente relacionados ao resultado do objeto. Logo, dados de reflectância podem indicar a informação direta, e não por pedotransferência, o que traz a luz a importância do uso de imagens ainda pouco explorado.

Face ao exposto, o objetivo do presente trabalho foi de realizar o mapeamento textural do solo por um método de pedotransferência semiquantitativa, baseada em dados obtidos de imagens de satélite multi-temporais. Supõe-se que a energia eletromagnética da superfície do solo esteja altamente relacionada com às frações granulométricas e em especial a argila. Espera-se que dados obtidos por imagem, sejam mais precisos que o relevo isoladamente, no mapeamento deste atributo. Tal hipótese baseia-se no fato do relevo mapeia argila via pedotransferência, enquanto a imagem usa a informação real do espectro de superfície. Por outro lado, a associação de ambos, deverá ampliar a performance do mapeamento textural.

3.2 Material e Métodos

3.2.1 Área de estudo

A área localiza-se no interior do estado de São Paulo, sendo que o município de Araraquara está localizado em posição central do polígono de estudo e no total a área é composta por 55 municípios paulistas, sendo os principais Araraquara, Brotas e Guariba, ocupando 14.614 km².

O ponto central da área localiza-se a 21°49'53" de latitude sul e 48°7'5" de longitude oeste. O clima é Aw (Koppen), tropical com estação seca de inverno (ROLIM et al., 2007), com precipitação anual média de 1480 mm e temperatura média máxima de 28,1 °C e mínima de 15,2 °C. A altitude varia de 400 a 1080 m. A Geologia é composta das seguintes formações: Formação Botucatu – Grupo São Bento; Formação Serra Geral intrusiva e extrusiva; Formação Itaqueri; Formação Marília – Grupo Bauru; Formação Vale do Rio Peixe – Grupo Bauru; Formação Tatuí – Grupo Guatá; Formação Iratí – Grupo Passa Dois; Formação Corumbataí – Grupo Passa Dois; Formação Pirambóia; Depósitos aluvionares; Depósitos colúvio-eluvionares (CPRM, 2006).

Os solos desenvolvidos na região de acordo com EMBRAPA (2013) são predominantemente os Latossolos Vermelhos e Vermelho-Amarelo com textura de média a argilosa, férricos ou não; Argissolos Vermelho e Vermelho-Amarelo também com textura e

gradiente variável; Neossolos Quartzarênicos e Nitossolos. A área é quase toda agriculturável, tendo a cana-de-açúcar como principal cultura, seguidas pelo reflorestamento de eucalipto, pomares de laranja e pastagens.

3.2.2 Definição dos locais de coleta

Primeiramente foi selecionada a cena do sensor TM do satélite Landsat 5 (TM/Landsat 5) com órbita ponto 220/75. Desta cena foi definida uma área de estudo com um total de 14.614 km² (1.461.400 ha). Assim foram demarcados um total de 952 pontos no campo, baseado no método da topossequência, visando obter dados das muitas variações ocorrentes, principalmente quanto a litologia e relevo, e conforme ratificado por Arruda et al. (2013), sendo coletadas amostras de terra na camada 0-20 cm com trado tipo holandês e georreferenciadas com uso receptor de um GPS (*global positioning system*)

3.2.3 Aquisição de série temporal de imagens TM – Landsat 5 e processamento

A principal cultura da região é a cana de açúcar. Sabe-se que, em média a cada cinco anos, os agricultores fazem uma reforma para renovação do canavial, e por consequência fazem o preparo de solo com aração e gradagem. Desta forma o solo fica exposto até o crescimento do canavial. No geral, e para a região, estas operações são realizadas no período de maio a outubro. O objetivo portanto, foi o de detectar áreas com solo exposto em algum momento através de uma série histórica de imagens do satélite Landsat 5. Neste aspecto a presente metodologia será nomeada como *Multitemporal Basr Soil Image Index* (MUBASII).

Neste sentido foi formado um banco de dados com 50 imagens Level 1 Product do satélite Landsat 5 (LOVELAND e DWYER, 2012) obtidas do “United States Geological Survey” (USGS). Do período de 1995 até 2011, sempre entre os meses de junho a outubro. Este produto derivado do sensor Thematic Mapper (TM) conta com sete bandas: visível azul (450–520 nm), visível verde (520–600 nm), visível vermelho (630–690 nm), infravermelho próximo (760–900 nm), infravermelho ondas curtas (1550–1750 nm), termal (10.400–12.500 nm), infravermelho ondas curtas (2.080–2.350 nm). Com resolução espacial de 30 m para as bandas VIS (visível), NIR (infravermelho próximo) e SWIR (infravermelho ondas curtas) e 120 m no termal.

As imagens foram processadas na plataforma ENVI 5.1, a qual possui algoritmos de correção atmosférica (FLAASH) e transforma os dados de número digital para reflectância

(EXELIS, 2015). Em seguida foram transformadas do sistema de coordenadas WGS84 para o SAD69 / UTM zona 23S com a função *Project Raster* do programa ArcGis 10.2 (ESRI, 2013). Não houve necessidade de georreferenciar as imagens, devido ao produto utilizada já ser previamente.

3.2.4 Obtenção de solo exposto

As imagens passaram por processos de eliminação de todos os objetos que não eram solo exposto. A “retirada” de um objeto da imagem, é aqui denominado de máscara. Este processo consiste por exemplo, em solicitar ao software que retire da imagem toda informação que seja água. Portanto, denomina-se que foi realizada uma máscara para retirar este alvo da imagem.

Para realizar os processos de máscaras e retirada de objetos que não fossem solos, foram necessários estudos preliminares dos espectros dos alvos. Neste caso, foram estudados alvos conhecidos para ciência do espectro quais sejam: água, palhada, vegetação e solos de diferentes texturas.

Assim, foram definidas a utilização de quatro máscaras, o uso do “*Normalized Difference Vegetation Index*” (NDVI) de acordo com a equação (1) para supressão das áreas vegetadas.

$$NDVI = \frac{TM4 - TM3}{TM4 + TM3} \quad (1)$$

A faixa considerada como solo para este índice em todas as imagens foi estabelecida entre 0 e 0,25, sendo os valores superiores referentes a vegetação.

Outro índice diferencial normalizado utilizado foi o “*MID – Infrared index*” (MIDI) sugerido por MADEIRA (1993) de acordo com a equação (2) e foi utilizado para discriminar áreas com palhada de solo.

$$MIDI = \frac{TM5 - TM7}{TM5 + TM7} \quad (2)$$

Para este índice não foi possível estabelecer uma linha de corte única como o anterior. Esta bandas são sensíveis a variações de umidade de solo como demonstra Musick & Pelletier (1988) e mais recentemente Haubrock et al., (2008) propõem um índice de umidade

de solo com uma faixa muito próxima as bandas TM5 e TM7. Assim, foi definido uma linha de corte empiricamente para cada imagem com o intuito de suprimir as áreas com palha, no geral a faixa considerada como solo para este índice foi entre 0 e $\approx 0,15$.

O comportamento espectral de solos tropicais observados por sensores orbitando a terra tem uma aspecto ascendente nas bandas TM1, TM2 e TM3 (DEMATTÊ et al., 2009, DEMATTÊ; RIZZO & BORTOLETTO, 2011, DEMATTÊ; RIZZO & BOTTEON, 2015). Desta forma foram utilizadas duas subtrações de bandas para mascarar qualquer comportamento diferente do ascendente, sendo “TM2 - TM1” e “TM3 - TM2”, desta forma os valores negativos foram eliminados.

Uma importante ferramenta utilizada no mascaramento foi a conferência das imagens na composição falsa cor, 543, RGB. Nesta composição após o realce (apenas visual) *Stretch Linear* (1%, 2% e 5%) da plataforma ENVI 5.1, as áreas de solo exposto apresentam um coloração púrpura para solos argilosos e tende para rósea nos arenosos. Desta forma foi possível fazer uma avaliação visual da eficiência das máscaras aplicadas quanto a coloração, sendo também analisado o contexto.

3.2.5 Obtenção da imagem composta de solo exposto

Na sequência foi necessário agrupar as imagens da série temporal já processadas para solo exposto em uma única imagem composta. De acordo com Ackerson; Demattê e Morgan (2015) o efeito da umidade do solo é o maior limitador para predições de atributos de solo em condições de campo pela espectrometria de reflectância no VIS-NIR. Bricklemyer & Brown. (2010) segue a mesma linha ao constatar que a umidade dos solos no campo é um dos principais limitantes para o uso de sensores espectroradiômetros “on-the-go”.

Com intuito de reduzir o efeito da umidade, que diminui a intensidade da reflectância e piora acurácia das predições. Em pixels com sobreposição entre diferentes imagens optou-se por selecionar o com menor influência da umidade. Desta forma, a seleção foi pelo menor valor do MIDII, esta operação foi realizada no software R (R Core Team, 2015) com uso do pacote “RASTER” (HIJMANS, 2015). Esta escolha se deve ao fato de que a água na faixa da banda TM7 tem maior poder de absorbância que a faixa relativa a banda TM5 (Curcio & Petty, 1951, “apud”, MUSICK e PELLETIER, 1988), isto explica a queda da reflectância da banda TM5 para TM7, o que não ocorre com dados simulados obtidos em laboratório. Esta informação corrobora com o índice de umidade do solo “*Normalized Soil*

Moisture Index” (NSMI) sugerido por Haubrock et al. (2008) apresentada pela equação (3), no qual os menores valores se correlacionam com menores teores de umidade.

$$NSMI = \frac{R(1800nm) - R(2119nm)}{R(1800nm) + R(2119nm)} \quad (3)$$

Para geração desta imagem composta, das 50 imagens iniciais, doze foram eliminadas por apresentarem incoerências, sendo assim a imagem composta foi gerada com 38 imagens de solo exposto. Nesta nova imagem os pixels selecionados têm menor influência da umidade e assim maior potencial para predição de atributos de solo.

3.2.6 Atributos do terreno

O modelo digital de elevação (MDE) escolhido para ser utilizado foi o SRTM (FARR et al., 2007), gerado por um radar de abertura sintética. Este foi obtido do “United States Geological Survey” (USGS) gratuitamente no formato de 1 arc segundo (1” = ~30 m) de resolução horizontal projeção geográfica WGS84 e sistema de referência vertical EGM96. Como foi necessário o uso quatro cenas para área de estudo, o primeiro passo foi mosaicar os MDE com a ferramenta “Mosaic to New Raster” do programa ArcGis 10.2 (ESRI, 2013). Em seguida foi alterado o sistema de projeção da mesma forma que citado anteriormente.

Para geração dos atributos de terreno, o MDE foi processado pelo software SAGA GIS 2.1.3 (CONRAD et al., 2015) com a ferramenta *Basic Terrain Analysis* que utiliza uma série de algoritmos. Assim foram geradas as seguintes derivadas: *Analytical Hillshading* (YOËLI, 1965); *Slope* (HORN, 1981); *Aspect* (GALLANT & WILSON, 1996); *Plan Curvature* (HEERDEGEN & BERAN, 1982); *Profile Curvature* (HEERDEGEN & BERAN, 1982); *Convergence Index* (KOTHE & LEHMEIER, 1996); *Closed Depressions* (MARTZ & GARBRECHT, 1999); *Catchment Area* (FREEMAN, 1991); *Topographic Wetness Index* (KOETHE et al., 2002); *LS fator* (DESMET & GOVERS, 1996); *Channel Network Base Level* (CNBL) (BAND, 1993); *Vertical Distance to Channel Network* (VDCN) (Möller et al., 2012); *Valley Depth* (CONRAD, 2012); *Relative Slope Position* (BOEHNER & CONRAD, 2008). Também foi gerada o *Multiresolution Index of Valley Bottom Flatness* (MRVBF) (GALLANT & DOWLING, 2003), com a ferramenta *Multiresolution Index of Valley Bottom Flatness*.

O *Valley Depth* descrito acima é basicamente é a distância vertical no nível base da rede de canais. Já o MRVBF identifica fundos de vale com base na assinatura topográfica e segundo Malone et al. (2011) é associado a variação de umidade do solo textura. VDCN é

distância vertical acima da rede de canais e o CNBL é a interpolação da rede de canais no nível base. E *Relative Slope Position* é a combinação da altitude acima das linhas dos canais com a altitude abaixo da *Ridge Lines* (cumeeira).

3.2.7 Outras variáveis utilizadas

Além do uso da imagem composta de solo exposto e dos atributos de terreno, foram utilizadas informações da geomorfologia da região extraídas do “MAPA GEODIVERSIDADE DO ESTADO DE SÃO PAULO” (CPRM, 2009) e geológicas retiradas do “MAPA GEOLÓGICO DO ESTADO DE SÃO PAULO” (CPRM, 2006) Também foram utilizadas coordenadas cartesianas (XY) do ponto central dos pixels da imagem composta.

3.2.8 Atributos de solo - textura

As amostras de terra coletadas, num total de 952 na profundidade 0 -20 cm, foram analisadas em laboratório quanto a granulometria (areia, silte, argila) conforme metodologia de Camargo et al. (1986). Destas, 688 foram contempladas pela imagens de solo exposto. Assim os dados espectrais da imagem composta foram extraídos para os pontos georreferenciados no software ArcGis 10.2 (ESRI, 2013) com uso da ferramenta “*Extract Multi Values to Points*”, sendo selecionada a opção “*bilinear interpolation*” para reduzir o efeito de salpicamento da imagem composta. Com a mesma ferramenta também foram extraídas as informações das demais variáveis preditoras, porém, sem a selecionar “*bilinear interpolation*”. Para o geração do modelo de validação, as amostras com espectros orbital foram divididas em dois grupos: primeiro com aproximadamente três quartos das amostras (513 pontos), foi utilizada para o treinamento dos modelos de predição; e a segunda com cerca de um quarto das amostras (175 pontos) para a validação dos modelos com dados independentes.

A divisão dos pontos foi aleatória, porém, foi realizado dentro das classes de acordo com o teor de argila a seguir: muito arenosa (menor que 10%), arenosa (de 10 a 15%), médio-arenosa (15 a 25%), médio-argilosa (25 a 35%), argilosa (35 a 65%) e muito argilosa (maior que 65%), classes texturais para fins de manejo do solo conforme DEMATTÊ & DEMATTÊ (2009). Para ambos os terem proporção entre as classes.

3.2.9 Modelagem – Cubist

Foi escolhido o modelo estatístico *Cubist* - R package version 0.0.18 (KUHN et al., 2014) para predição da granulometria superficial do solo (argila e areia). Este modelo é uma extensão do *Quinlan's M5 model tree*, sendo em formato de árvore, baseado em regras e onde os nós finais, ou seja as folhas, são regressões lineares, também ocorrem modelos lineares intermediários. Foi proposto por QUINLAN (1986, 1992, 1993), sendo bastante usado na modelagem de propriedades do solo (HENDERSON et al., 2005; MINASNY et al., 2008; PADARIAN et al., 2014; MILLER et al., 2015). A vantagem de utilizar um modelo que trabalha com regras e no formato de árvore é que ele permite gerar diferentes modelos lineares afim de capturar relações de diferentes localidades da área estudada.

Para o ajuste do modelo foi utilizado o pacote *Caret* - R package version 6.0-58 (KUHN, 2015), sendo definido o ajuste para o menor valor do erro quadrático médio da predição (*Root Mean Squared Error* – RMSE). É importante salientar que um problema possível é o “*model overfitting*”, onde o modelo gerado não apresenta apenas relações reais mas também relações ao acaso entre os dados utilizados no treinamento (CARR, 1988). Para diminuir este efeito, foi realizado um ajuste empírico considerando as contribuições das variáveis preditoras para o modelo, as validação por variáveis independentes e aspecto visual do mapa gerado.

Desta forma, algumas variáveis anteriormente propostas não foram utilizadas na predição. Da imagem composta de solo exposto foram apenas utilizadas as bandas TM3, TM5 e TM7. Dos atributos de relevo foram utilizados o MDE, *slope*, *LS fator*, *channel network base level*, *vertical distance to channel network*, *valley depth*, *relative slope position* e o MRVBF. Também foram utilizadas as coordenadas cartesianas e o mapa geomorfológico. Totalizando um total de catorze variáveis.

Afim de verificar o potencial da imagem composta de solo exposto quanto seu poder de predição, foram gerados os seguintes modelos para areia e argila, com as seguintes variáveis preditoras. **Modelo imagem**, com apenas as bandas TM3, TM5 e TM7. **Modelo relevo**, com os atributos de relevo, coordenadas cartesianas e mapa geomorfológico. E **modelo imagem + relevo**, com todas as variáveis, este com intuito de verificar sinergia nas predições entre a imagem de satélite e o relevo. Mesmo para o modelo relevo, o mapa gerado computou apenas as áreas com solo exposto, isto para realizar uma comparação mais fiel entre os mapas. A sequência metodológica é apresentada na figura 2.

3.2.10 Validação

A validação dos modelos foi feita com a determinação dos coeficientes de determinação (R^2) do grupo de validação, dado pela equação (4).

$$R^2 = 1 - \left(\frac{RSS}{TSS} \right) \quad (4)$$

Onde RSS é a soma dos quadrados dos resíduos (*Residual Sum of Squares*) e TSS é a soma dos quadrados total (*Total Sum of Squares*) apresentados nas equações (5) e (6), respectivamente.

$$RSS = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

$$RSS = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (6)$$

Nas equações, y_i representa os valores observados do atributo para amostra i , \hat{y}_i o valor estimado do atributo para amostra i , \bar{y} a média do atributo e n o número de observações. Também foram determinados os erros quadráticos médios das predições (*Root Mean Squared Error – RMSE*), como segue na equação (7).

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (7)$$

O RMSE usa as mesmas unidades dos atributos, desta forma eles foram apresentados em g.kg^{-1} . Na sequência foram calculados os fatores RPD (*Relative Percent Deviation*), que é razão do desvio padrão (σ) do atributo e o RMSE, como representado pela equação (8).

$$RPD = \frac{\sigma}{RMSE} \quad (8)$$

O dados de RPD foram avaliados segundo metodologia de Chang et al. (2001) para predições de propriedades de solo, no qual valores acima de 2 indicam desempenho ótimo na predição, valores entre 2 e 1,4 indicam desempenho intermediário de predição, e menores que 1,4 sugerem um modelo com desempenho ruim.

Com intuito de verificar o comportamento das predições no triângulo textural, os teores de silte foram estimado por diferença entre as predições de areia e argila. Isto para o modelo imagem, modelo relevo e modelo imagem + relevo. Os dados preditos foram plotados em triângulos texturais junto com os dados mensurados para comparações visuais.

Como sugerido por Parian et al. 2014, também foi realizada uma avaliação visual dos mapas gerados. Com intuito de verificar se o modelo não gerou uma representação falsa e com anomalias.

3.2.11 Espacialização

Para geração dos mapas de teores de argila e areia superficiais, os pixels de solo exposto da imagem composta foram transformados em pontos com a ferramenta “*Point to Raster*” (ESRI, 2013). Os pontos gerados são localizados no centro de cada pixel e foi utilizada a mesma metodologia que descrita anteriormente para extração das informações para os pontos. Os dados foram salvos no formato de tabela e processados nos seis modelos gerados anteriormente. Na sequência a tabela foi transformada em pontos e os pontos transformados em raster com a função “*Point to Raster*” (ESRI, 2013).

3.2.12 Interpolação

A fim eliminar as lacunas do mapa, devido a imagem composta não abranger toda área, foi escolhida a técnica de interpolação *Inverse Distance Weighted* (CONRAD, 2003) contida no SAGA GIS e utilizada a configuração padrão no processamento. Foi realizado para os mapas de areia e argila dos melhores modelos. Esta é uma técnica de interpolação computacional determinística proposta inicialmente por Shepard (1968).

Na sequência, os 264 pontos com tradagens que não haviam sido contemplados anteriormente tiveram as informações dos mapas de textura interpolados extraídas para os pontos com as técnicas já mencionadas anteriormente. Desta forma foi possível realizar as validações deste dados.

3.3 Resultados e Discussão

3.3.1 Caracterização granulométrica dos solos da área

Na região foram observadas várias classes de solos, entre elas, os Latossolos, Argissolos, Neossolos Quartzarênicos e Nitossolos nas mais variadas classes texturais. A tabela 1 apresenta as variações das análises granulométricas na camada superficial (0-20 cm). Observa-se uma distribuição com solos desde argilosos até arenosos, sendo o segundo mais significativo. Os teores de argila variam de 7 a 643 g.kg⁻¹ com desvio padrão de 150,74 e média de 227, g.kg⁻¹. A figura 3 ilustra a frequência de ocorrência dos atributos granulométricos. Observa-se uma distribuição de teores de argila com maior parte menores que 300 g.kg⁻¹. Os teores de areia mais significativos acima de 600 g.kg⁻¹ e silte com valores baixos indo até 80 g.kg⁻¹. Os resultados indicam heterogeneidade das classes texturais na área, com predominância dos solos mais arenosos.

A tabela 2 apresenta a ocorrência das diferentes classes texturais. Observa-se 37% de ocorrência dos solos arenosos e muito arenosos e 20% argilosos e muito argilosos, e 43% textura média.

3.3.2 Quantificação dos teores de argila via relevo

Os mapas de teores de argila e areia encontram-se na figura 4 a, b. Observa-se alta heterogeneidade das áreas mapeadas para os dois atributos.

A quantificação de teores de argila via relevo foi possível com um R² de 0,66 e RMSE de 90,5 g.kg⁻¹ (Figura 4c, e). Os teores de areia atingiram 0,62 de R² com erro na casa de 129,79 g.kg⁻¹. Os valores medidos (via análise de laboratório) e preditos (via fórmula de relevo), também podem ser visualizados no triângulo textural (figura 4d). Observa-se alta similaridade na distribuição dos pontos ao longo do gráfico, sendo que as texturas mais ocorrentes são as arenosas e médias.

Neste aspecto, a determinação das variações granulométricas na superfície, podem ter relação com as questões de relevo. De fato, alguns parâmetros de relevo apresentaram alta participação nos modelos para quantificação de argila e areia (Figura 5 a, b). Para argila, o atributo com maior participação nas condicionais foi a posição cartográfica (longitude) (com 92%) seguido da longitude com 53% de contribuição. Já nos modelos de regressão o atributo

com maior contribuição foi o modelo numérico de elevação com 83%. O MRVBF, que é uma medida dos fundos de vales, obteve baixa participação no modelo (14%). Para a areia, as contribuições foram bastante semelhantes, o MDE e o CNBL (*Channel network base level*) obtiveram a alta participação nos modelos (Figura 5b). Sousa Junior & Demattê (2008) observaram alta relação entre o modelo de elevação e classes de solos. No caso, os Latossolos ocorreram nas altitudes mais elevadas e os Argissolos menos elevadas.

Trabalhos no mapeamento digital de atributos do solo tem relatado variações na quantificação de argila. Henderson et al. (2005) obteve R^2 de 0,44 para a camada superficial usando arvores de decisão e atributos do relevo. Stepien et al. (2015) obtiveram resultados pouco afirmativos com atributos do terreno na indicação das classes texturais de solos. Estes autores observaram variação nos resultados dependendo da área de estudo. De maneira geral, a elevação obteve 0,2 de R^2 . Ceddia et al. (2009), Landrum et al. (2014) e Pontes de Oliveira et al. (2013), observaram relações mais consistentes entre relevo e argila em solos da região nordeste do Brasil.

3.3.3 Quantificação dos teores de argila via imagens de satélite

A quantificação dos teores de argila via imagens de satélite é ilustrada na figura 6 a, b. Observa-se similaridade das principais manchas de classes texturais obtidas via relevo (Figura 4) e via satélite (Figura 6). Os valores quantitativos indicam um R^2 de 0,64 para argila e 0,63 para areia (Figura 6c, e), bastante semelhantes aos resultados obtidos na quantificação por atributos do relevo. A distribuição dos valores preditos e medidos no triângulo textural (Figura 6d) também mostram-se bastante próximos.

A variação dos teores de argila numa área estão em função de fatores pedogenéticos e climáticos variados, sendo o mais consistente o material de origem. De fato, a região é composta basicamente por materiais de formações que geram solos argilosos (tais como a Serra geral) e arenosos (Botucatu e Piramboia). Durante os fatores e processos de formação dos solos, ocorre ao desenvolvimento dos pedons e consequente expressão das classes granulométricas nos mais variados horizontes, desde os superficiais (horizontes A) até os subsuperficiais (horizontes B).

Avaliar solos em plataformas aéreas ou espaciais é sem dúvida, uma tarefa difícil. Uma imagem de satélite tentando determinar o teor de um atributo do solo a aproximadamente 800 km de distância e numa resolução espacial na faixa dos 30 metros em nada contribui para facilitar este trabalho. Há vários fatores que interferem nos dados, como

problemas atmosféricos, da superfície do solo, presença de materiais que não seja solo (palhada, pedras, tocos, culturas, entre outros). Portanto, a chave para a detecção adequada da informação do solo está na correta identificação do pixel como sendo solo exposto.

A maioria dos trabalhos fizeram a quantificação com sensores multiespectrais. Sullivan et al. (2005) avaliou sensores com alta resolução espacial com o IKONOS porém com baixa resolução espectral em regiões do Alabama. Chen et al. (2008) usaram o sensor ATLAS (2 m de resolução espacial e 8 bandas no VIS-NIR-SWIR) na predição de carbono orgânico, reportando R^2 de 0,63 com erro de 22%, bastante semelhantes aos aqui reportados (R^2 de 0,64) porém para argila.

A detecção de solo exposto foi realizada, entre outros por Demattê et al. (2009). Através da utilização desta técnica, vários autores quantificaram o teor de argila via satélite Landsat atingindo a faixa de R^2 de 0,67 usando o MLR (DEMATTÊ & NANNI, 2003; DEMATTÊ et al., 2005; NANNI & DEMATTÊ, 2006a, b; FIORIO et al., 2010). Usando a mesma metodologia, Demattê et al. (2007a) atingiram valores mais expressivos na faixa de 0,86 R^2 para argila, porém destacando a alta variabilidade textural da região.

Agregando todas as informações do ASTER, incluindo a faixa de 2000–14000 nm no termal, Hewson et al. (2012) estudou os dados através de uma biblioteca espectral (SWIR e TIR) na avaliação de índices para determinação de argila com relativo sucesso.

Além dos dados multiespectrais, existem os hiperespectrais. Diferenciam-se dos multiespectrais devido ao maior número de bandas. A influência das partículas do solo, em especial a argila e areia no espectro foi estudada por Selige et al. (2006) através do ASS (HyMap sensor). Os autores obtiveram R^2 de 0,71 e 0,95 para argila e areia respectivamente, bem superiores aos dados deste trabalho. De Tar et al. (2008) usaram MLR com o AVNIR (60 bandas entre 429 e 1,010 nm), e reportaram R^2 de 0,81, 0,75 e 0,67 para areia, silte e argila, respectivamente. Gomez et al. (2008) e Gomez et al. (2012) quantificaram argila pelo HyMap com R^2 de 0,64 e 0,67, com erro de 49,6 e 42,2 g kg⁻¹ respectivamente usando o PLSR. Hively et al. (2011) usando HyperSpecTIR obteve R^2 de 0,79, 0,79 e 0,66 para areia, silte e argila. Chegando ao nível de avião, onde ocorrem menores problemas atmosféricos, Casa et al. (2013b) compararam diferentes sensores hiperespectrais, o de avião MIVIS (VIS-NIR-SWIR), e o em satélite CHRIS-PROBA (VIS-NIR) com resolução espacial de 4,8 e 17 m, respectivamente, obtendo R^2 de 0,48 e 0,52, com erros de 7,20 e 6,87, para argila em ambos os sensores, respectivamente.

A quantificação de atributos do solo tem sido realizado há algum tempo. De longe, os estudos de quantificação via laboratório são mais consistentes para o atributo argila

(Tabela 3). Isto está relacionado ao fato da mineralogia e água serem atributos espectral mente ativos (STENBERG et al., 2010). Observa-se que existem variações nos índices de R^2 na quantificação em laboratório na faixa de 0,67 a 0,86 (Tabela 3). Por outro lado, dados terrestres no campo, estes resultados provam que a técnica hiperespectral terrestre tem a capacidade de prever este atributo.

Ao nível aerotransportado e em satélite outros dados podem ser avaliados (Tabela 4). Está claro que uma adequada correção atmosférica e radiométrica, melhora significativamente os dados quantitativos. De fato, umidade e elementos fotossinteticamente ativos e vegetação, reduzem o potencial dos algoritmos em prever os solos. Várias estatísticas tem-se apresentado como alternativa na quantificação de argila, sendo as multivariadas as predominantes. Ao considerar os sensores multiespectrais, a regressão múltipla é a mais usada. Por outro lado, o PLSR é mais usado em dados hiperespectrais (Tabela 3).

De maneira geral observa-se na tabela 4 o seguinte - a. os resultados de R^2 variam de muito baixos (abaixo de 0,3) a altos (acima de 0,8) e muito altos (acima 0,9); b. numa visão geral, os sensores multiespectrais, com menor número de bandas como o IKONOS, apresentam os resultados mais baixos; c. outros sensores multiespectrais, como o TM/Landsat, apresentam dados variáveis, mas na maioria bons resultados com forte amparo conceitual nos últimos 44 anos; d. informações hiperespectrais deveriam ser os melhores, entretanto, muitos deles são similares aos do TM/Landsat. Isto pode estar relacionado a menor experiência que se tem com dados hiperespectrais orbitais, os quais podem ser melhorados no futuro; f. está claro que a comunidade científica está indo em direção aos dados hiperespectrais como Hymap e Spectir; g. considerando a repetibilidade de dados gerando a sua consistência científica, a quantificação de argila encontra-se em posição privilegiada. Portanto, observa-se que os dados do presente trabalho na quantificação de argila via satélite multiespectral com R^2 na faixa de 0,64 está dentro do esperado e observado em literatura, porém menor que os dados hiperespectrais.

3.3.4 Quantificação de argila e areia via imagens, relevo e geomorfologia

Apesar das dificuldades inerentes ao número de bandas dos sensores multiespectrais, existe a possibilidade de *linkagem* com dados de relevo, de aquisição fácil e muitas vezes gratuita na internet. Neste caso, o presente trabalho determinou modelos de quantificação utilizando as bandas do TM/Landsat 5 associado aos atributos do relevo como: o MDE, fator LS, Slope, entre outros. A figura 7 a, b apresenta os mapas de argila e areia obtidos a partir de modelos que associaram os dados das imagens de satélite, atributos do relevo e mapas

de geomorfologia. Através desta combinação, foram determinados R^2 de 0,72 e 0,71 para argila e areia, respectivamente.

Nos últimos 20 anos as pesquisas tem demonstrado que modelos digitais de elevação (MDE) são uma ferramenta secundaria útil no mapeamento de propriedades do solo (BICHOP & MINASNY, 2006). De fato, um modelo de elevação representa a distribuição das elevações ao longo da paisagem. O termo digital começou a ser utilizado na década de 70 quando houve a substituição dos dados cartográficos em papel pelos digitais. Dados primários podem ser calculados diretamente do MDE, enquanto que dados secundários podem ser calculados por um ou mais dados primários do terreno. Dados básicos mais comuns usando dados primários do terreno são derivados da superfície, tais como declividade, aspecto e curvatura. A topografia e um dos cinco fatores de formação do solo conforme Jenny (1942) – $s = f$ (clima, organismos, relevo, material de origem, tempo), e portanto, auxilia na detecção das variações das propriedades do solo como a argila.

Associado a estes fatores, houve considerável incremento das técnicas estatísticas as quais hoje, entre elas as regressões lineares múltiplas (ODEH et al., 1995), arvores de regressão (MCKENZIE E RYAN, 1999), modelo linear generalizado (GESSLER et al., 1995) e modelos generalizados aditivos (ODEH et al, 1997) tem se destacado. De fato o presente trabalho utilizou-se do modelo Cubist, com as variáveis preditoras do relevo: MDE, slope, LS fator, channel network base level, vertical distance to channel network, valley depth, relative slope position e o MRVBF, obtendo R^2 de 0,66 para argila (Figura 4). Das variáveis extraídas do relevo, as mais significativas foram a latitude (92%), o MDE (83%), o CNBL (72%), slope e VDCN ($\approx 60\%$). Macbratney et al. (2003) propuseram a inclusão do fator S e da informação espacial (N) em adição ao fatores propostos por de Jenny, obtendo o formato $s=f(s, c, o, r, p, a, n)$. De fato, isso havia sido observado por Gessler et al. (1995) e Moran & Bui (2002), para os quais derivados do relevo como elevação em relação ao canal de drenagem, distância do canal de drenagem apresentaram-se como bons preditores de propriedades do solo. As premissas destes autores corroboram os resultados do presente trabalho onde a argila obteve sucesso na sua quantificação baseada em variáveis do relevo (Figura 4 e 5).

3.3.5 Estudos de casos no mapeamento granulométrico

Durante o processo de realização dos mapas, algumas áreas não foram quantificadas, ficando em branco nos mapas conforme se verifica nas figuras 4, 6 e 7. Para o caso das imagens, só foi possível mapear onde se tinha solo exposto. Por outro lado, para o caso

do relevo, apesar dos dados se apresentarem contínuos se optou por manter as lacunas, a fim de comparação dos mapas. Com o intuito de mapear estas áreas, recorreu-se ao método de *Inverse Distance Weighted*, que é uma técnica determinística de interpolação. Com esta metodologia foi possível fechar as lacunas tendo-se um mapa contínuo conforme pode ser visualizado nas figuras 8 a, b para argila e areia respectivamente. A figura 8 c apresenta o detalhe das áreas em branco e a figura 8 d as áreas mapeadas por interpolação. Em algumas áreas que não puderam ser mapeadas inicialmente, haviam pontos de análise de solo, mas não foi gerado o mapa no local. Porém, após o interpolação destas áreas, foi possível realizar uma validação com este grupo de dados.

Observa-se que com os pontos observados no campo em locais mapeados por interpolação, os R^2 foram de 0,62 e 0,63 (Figura 8 e, f) para argila e areia respectivamente, inferiores aos 0,72 e 0,71 validados para as áreas mapeadas com dados reais de relevo associado a imagens (Figura 7). Tais resultados indicam que mapear, utilizando dados de variáveis dependentes sólidas como relevo ou imagens de satélite, são mais estáveis que uma interpolação de dados.

Fato que merece ser mencionado está relacionado aos resultados de imagens de satélite. Observar os três pontos demarcados na figura 8f. Trata-se de pontos de validação de campo os quais apresentaram textura arenosa. Neste locais, a cultura perene não permitiu a exposição de solo, assim não foi feita a predição (Figura 9 a). Trata-se de um caso específico que foi mapeado por interpolação de dados. O resultado da interpolação (figura 9 b), indicou a área como sendo de solos argilosos. Isto ocorreu pois trata-se de uma área próxima ao canal de drenagem onde há excesso de umidade. As imagens de satélite obtiveram dados de reflectância com intensidade baixas devido ao excesso de umidade apesar de granulometria arenosa. Logo, a interpolação utilizou-se dos dados da imagem com reflectância baixa (mais próximas ao canal de drenagem), agregando as áreas mais elevadas arenosas e as classificou como argilosas. Isso se refletiu no gráfico de correlação baixando o R^2 . Portanto, a interpolação de informações diminui o grau de assertividade dos dados.

Concluiu-se que de fato, a associação de dados de imagens de satélite com dados de relevo aumentou a assertividade no mapeamento da argila. Por outro lado, observou-se que os mapas obtidos via relevo apresentaram inconsistências (Figura 7 a, b). Tal fato decorre do alta dependência das coordenadas cartesianas na condicionais do e está em concordância com observado por Padarian et al. (2014). Este efeito também está relacionado com a elevada concentração das amostras de solo, caso elas fossem melhor distribuídas o modelo se ajustaria e provavelmente esta inconsistência seria menos significativa.

As imagens de satélite por outro lado, determinam um valor de argila para o pixel específico, cuja informação espectral está diretamente relacionada aos fatores físicos que compõem a amostra de terra. Sabe-se que existe uma relação e explicação física para a correlação entre teor de argila e mineralogia e a forma do espectro (STEMBERG et al., 2010). Isto também está comprovado pelos trabalhos de quantificação de argila em laboratório (ARAUJO et al., 2015, TERRA et al., 2015). Ou seja, no momento em que se tem um pixel com solo exposto, o dado espectral das respectivas bandas de um sensor (como no caso do TM/Landsat 5), expressa fisicamente o conteúdo do material analisado (amostra de terra). Isso já havia sido comprovado por autores conforme indicado na tabela 3. Portanto, a imagem de satélite detecta o valor mais provável do teor da amostra do alvo diretamente. A quantificação via relevo por sua vez, realiza um trabalho de correlação entre posição na paisagem com teor do atributo, e atribui o valor de argila, função dos parâmetros de formação de solos conforme preconizado por Jenny (1941) e Macbratney et al. (2003) – processo de pedotransferência. Face a isso, as imagens tem como vantagem indicar o valor do ponto fisicamente e não por extrapolação, como, de fato, se observou que, interpolar dados, geralmente diminui a assertividade.

3.3.6 Considerações gerais

A determinação da textura do solo é uma das mais importantes propriedades pois influencia todos os processos físicos, químicos e biológicos. A textura do solo e o resultado de processos físico químicos em atividade nas rochas e minerais, influenciado por fatores externos como clima, topografia e organismos. A textura pode ser considerada uma propriedade com baixa alteração ao longo do nosso tempo, e portanto, uma interessante propriedade a ser quantificada.

No processo de quantificação foi utilizada a estratégia de uso via imagens de satélite. Interessante observar que a quantificação dos teores de argila por espectroradiometria utilizando sensores hiperespectrais em laboratório (mais de 1500 bandas), tem obtido altos valores de R^2 chegando a 0,85 e 0,90 (NANNI & DEMATTE, 2006; TERRA et al., 2015). De fato, as quantificações quimiométricas de atributos do solo são mais robustas nestes casos pois ocorrem em ambientes controlados, com sensores com várias bandas e resolução espacial de cm, e ainda não tem interferência atmosférica, além do alvo ser solo sem nenhum material interferente. Ao mudarmos de plataforma, como a aérea hiperespectral, os valores continuam altos, mas não faixa de 0,70 podendo chegar a 0,80. Franceschini et al (2015) usando sensor

aéreo Spectir, obtiveram R^2 de 0,92 em laboratório e 0,77. Saltando ao nível orbital, numa distância do alvo de 800 km, os hiperespectrais chegam a 0,7 e portanto, não melhorando em relação aos em avião. Por outro lado, os dados obtidos por sensores multiespectrais, na faixa de 7 bandas e resolução espacial de 30 m apresentam resultados semelhantes aos hiperespectrais tanto em satélite quanto laboratório. Fiorio & Dematte (2009) obtiveram R^2 de 0,71 para argila com dados Landsat. No caso, tinham certeza de que a área estava com solo exposto por ocasião da imagem. Logo, esta informação é fundamental para se atingir melhores resultados. Genu & Dematte (2012) também observaram boa correlação entre solos e dados do multiespectral Aster. Tal fato demonstra a importância dos multiespectrais neste nível de aquisição, cujo resultado não difere significativamente dos hiperespectrais. Além disso, são dados mais fáceis de serem adquiridos (muitas vezes gratuitos), e mais fáceis de serem processados. Provavelmente, os bons resultados do TM/Landsat esteja relacionado a distribuição adequada das bandas que possui, já que para avaliação de solos, o importante são as faixas do visível (VIS), infravermelho próximo (NIR) e no infravermelho de ondas curtas (SWIR).

O ponto é que teoricamente, os resultados deveriam ter a seguinte sequência de precisão do melhor para o pior: dados de laboratório – dados de campo – dados aéreos hiperespectrais – dados orbitais hiperespectrais – dados orbitais multiespectrais. Entretanto, como observado em literatura (Tabela 3) observa-se que ocorre sobreposição de resultados na sequência apresentada. De fato, pode-se encontrar dados do multiespectrais melhores ou semelhantes aos hiperespectrais e vice-versa. Os resultados do presente trabalho com máximo de R^2 0,66 é melhor que vários resultados de hiperespectrais de outros trabalhos. Pode-se concluir que a quantificação do atributo argila via sensores é um fato e pode ser realizada por qualquer plataforma, porém, com variação da precisão. A variação dos resultados pode estar relacionada a vários fatores entre eles o número de amostras dos modelos, homogeneidade ou heterogeneidade dos dados, o modelo do sensor, resolução espacial e espectral, qualidade das imagens e da correção atmosférica, qualidade do sensor, época de aquisição das imagens, situação do solo no momento da aquisição do dado (umidade, presença de material que não seja solo, rugosidade, entre outros). Portanto, é preciso levar estes pontos em consideração em futuros trabalhos.

Numa segunda abordagem foi utilizado os parâmetros de relevo (Figura 4). De fato, técnicas pedométricas tem sido largamente difundidas após o ano 2000 (MEIRVENNE & CLEEMPUT, 2006). No presente trabalho foi utilizada a técnica *Cubist*, árvore de regressão, através da qual foi possível quantificar os teores de argila com 0,66 de R^2 , levando-se em consideração os valores específicos dos pixels. Isso pois, vários autores tem se deparado com a

tentativa de gerar mapas preditivos e representados como classes texturais. Entretanto, este procedimento tem encontrado algumas inconsistências a saber (MEIRVENNE E CLEEMPUT, 2006) – a. limites fixos entre classes texturais não representam a realidade e portanto, não devem ser utilizados; b. existem diferenças entre os triângulos texturais entre algumas nações o que torna impossível as comparações; c. a legenda do mapa oferece uma informação qualitativa, pois indica uma faixa, enquanto que nos dias de hoje torna-se imprescindível valores quantitativos, principalmente quando analisados em sistemas de informação geográficos e inseridos em modelos de pedotransferencia; d. não é possível oferecer informações sobre a acurácia dos mapas texturais, pois dentro de um mesmo polígono textural, pode-se ter pixels com valores texturais diferentes que foram agregados no polígono principal. De fato, a influência da topografia nas propriedades do solo é amplamente discutida em Florinsky (2012). Isso concorda com o que foi observado no presente trabalho, onde, após ter mapas texturais, não foi possível obter bons dados de validação. Portanto, justifica-se a apresentação de mapas onde cada pixel está quantificado (Figura 4).

Numa terceira estratégia foram agregados vários atributos do relevo associados as informações espectrais obtidas via satélite. Esta abordagem em associar atributos diversos no intuito de quantificar um elemento do solo, tem sido realizado por outros autores como Demattê et al (2011), Demattê et al. (2014), Vasquez et al. (2014) e Alves et al. (2015). No presente trabalho, foram associados dados de relevo e imagens de satélite. Tal associação, através da modelagem pelo *Cubist*, atingiu um R^2 de 0,72, superior ao do relevo ou da imagem individualmente que atingiram R^2 de $\approx 0,65$. De fato, os parâmetros de relevo fornecem um tipo de informação relativa as posições do atributo em função dos fatores e processos de formação do solo, enquanto a imagem de satélite agrega o valor espectral do ponto. Como a literatura demonstra que ambas as informações são importantes, a sua associação gera um resultado expressivo. Ben-dor et al. (2009) relata em extensa revisão bibliográfica a importância das imagens de satélite na avaliação e caracterização de solos, enquanto que Nanni et al. (2014) ratificam em estudo de caso a íntima relação entre dados orbitais e terrestres, reiterando a sua importância na quantificação de solos. Esta quantificação está intimamente relacionada, entre outros fatores, ao sucesso na detecção de pixels com solo exposto conforme relatado por Demattê et al. (2009). O presente trabalho se utilizou de uma técnica na obtenção de solo exposto atingindo correlação (r) entre dados de sensor de laboratório com o orbital de 0,70 (dados apresentados no capítulo 1), dentro das faixas obtidas em literatura (Tabela 3) e expressivo quando comparado com dados do satélite TM/Landsat 5.

Importante correlacionar os mapas granulométricos (Figura 8) com produtos cartográficos da região (Figura 10). A mesma relaciona os atributos MDE, geologia e geomorfologia da área. Observa-se estreita similaridade entre o mapa de altitudes e a textura da área. As áreas com maior altitude apresentam os solos mais arenosos enquanto as com menor altitude solos mais argilosos, concordando com Sousa & Demattê (2008) que estudaram a relação geológica e solos da região. Os autores observaram a presença de Latossolos textura media nas altitudes mais elevadas e Nitossolos argilosos nas mais baixas, corroborando os dados do presente trabalho. De fato, observa-se (Figura 10 a, b, c) que na região indicada 1, os solos são textura media tendendo a arenosa, justamente onde ocorre o material de origem do Grupo Bauru, arenito. Na região indicada 2, a área é mais arenosa segundo os mapas, indo de encontro ao material de origem da formação Botucatu. A área 3, com indicação da formação Itaqueri também indica solos mais arenosos. Finalmente, na área 4, onde ocorre a formação serra geral, desenvolvem-se solos com textura mais argilosa, em conformidade com o mapa granulométrico.

O mapa geomorfológico (Figura 10 c) desenvolvido por CPRM(2009), indica outro tipo de avaliação. Os autores obtiveram estes mapas através da avaliação de dados do SRTM e relacionaram os tipos de relevo. Observar (comparando figura 8 a, b com figura 10c), que na área 1 ocorre o domínio do relevo R4a1 sendo de colinas amplas e suaves, com textura média. Na área 5 observa-se mais claramente uma ótima relação entre o mapa de relevo R4a2, R2b e R4e, com textura media a argilosa.

De qualquer maneira, durante os trabalhos de modelagem, observou-se que modelos com relevo ou imagem individualmente apresentaram R^2 semelhantes na faixa de 0,62. A associação relevo+imagem melhora o modelo mas não atinge o ápice da correlação. A associação relevo+geologia obteve bom resultado na faixa de 0,65 de R^2 , porém, com visualização precária, e com alta contribuição da geologia (49%) para as condicionais do modelo. A associação relevo+imagem+geologia+geomorfologia, retirou toda a contribuição da geologia (com zero de participação no modelo) e baixa para geomorfologia (3%). De fato, apesar do mapa de geologia apresentar um ótimo resultado visual com o mapa de argila (Figura 8 a, 10 b), o mesmo não contribui quando se insere no modelo as imagens de satélite.

Para o caso de relevo+geologia, obteve-se boa correlação, porem com visualização inadequada, apesar da contribuição da argila atingir 49%. Em todos os casos, a introdução das imagens de satélite melhorou a visualização dos aspectos do mapa, ao contrário do relevo individualmente. Sabe-se da estreita correlação entre geologia e teores de argila é também da relação entre imagens e geologia (GENU et al., 2011). De fato, estes autores também

encontraram boa correlação entre mapa de argila e imagens de satélite Aster. Entretanto, para o presente caso, as imagens de satélite de uma área com solo exposto, exprime melhor as relações com a granulometria. Ao introduzir no modelo o mapa de geologia, o mesmo não agrega informação, pois esta já foi inserida via imagens de satélite. Isso corrobora o observado por Genu et al. (2011), para os quais existe estreita correlação entre mapas de geologia e imagens de satélite. Logo, a inserção deste mapa não contribuiu nos modelos conforme observado na tabela 4. O mapa de geologia, porém, contribuiu muito ao ser associado ao de relevo. Isso pois, o de relevo não conseguiu substituir as informações de geologia. Tal fato levou ao melhor modelo no qual entraram a imagem de satélite, relevo e geomorfologia (Figura 8). A geomorfologia agregou apenas 3% no modelo, mas foi o suficiente para melhorar o modelo, fato que o de geologia não foi capaz devido a presença da imagem de satélite.

Tais resultados mostram que o uso dos produtos como variáveis dependentes, depende da sua relação com o atributo avaliado. Logo, nem todos os mapas podem contribuir na melhoria dos modelos.

3.4 Conclusões

É possível determinar o teor de argila e areia via relevo atingindo R^2 de 0,65 e 0,62, respectivamente. A utilização de imagens de satélite multiespectral como o TM/Landsat 5 permitiu atingir R^2 ao nível 0,64 e 0,63, respectivamente. Por outro lado, a associação entre parâmetros do relevo com imagens de satélite e mapa geomorfológico atingiu um valor de 0,72 e 0,71 de R^2 , demonstrando que existe sinergia para o modelo.

As imagens de satélite suplantaram as informações de geologia. As principais bandas que agregaram a quantificação nas regressões de argila para o modelo imagem + relevo foram a TM5 (1550-1750 nm) e TM7 (2080-2350 nm) com 44 e 89%, respectivamente. Os parâmetros do relevo com maior contribuição foram a latitude (57%), modelo numérico de elevação (70%) e CNBL (72%). A quantificação por imagens de satélite é realizada via informação do espectro do alvo, o que denota a informação in situ via satélite. Em contrapartida, os dados de relevo são por extrapolação dos padrões gerenciados pelo modelo.

O método proposto de modelagem via *Cubist*, contendo dados de relevo associados aos aspectos espectrais de imagens de satélite e outros como geomorfologia, permitiu quantificar os teores de argila de maneira contínua em grande área de abrangência, no caso com 636.464,07 ha e grau de assertividade com R^2 0,72.

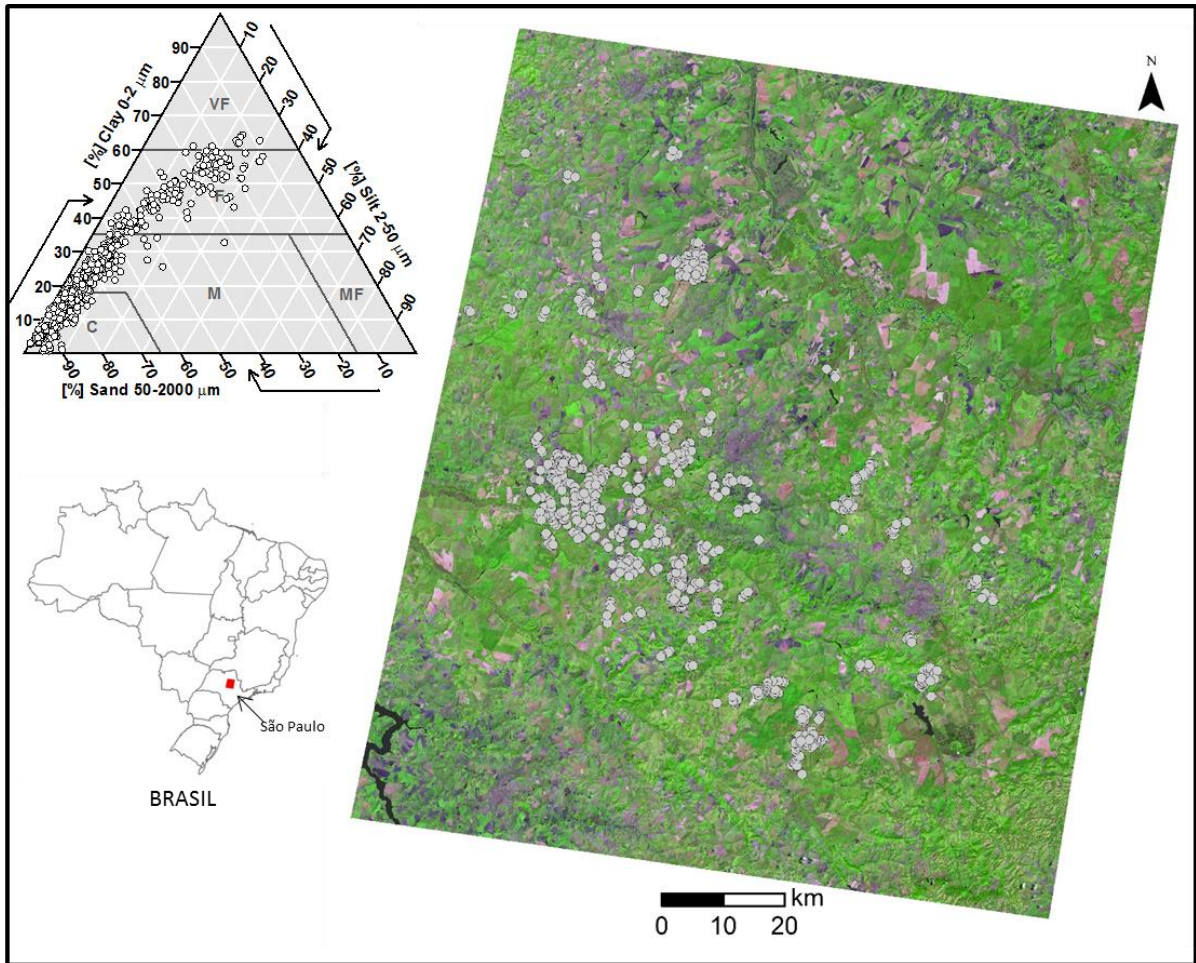


Figura 1 - Ilustração da área de estudo, da distribuição das análises de solo no diagrama textural e dos locais com pontos de observação no campo

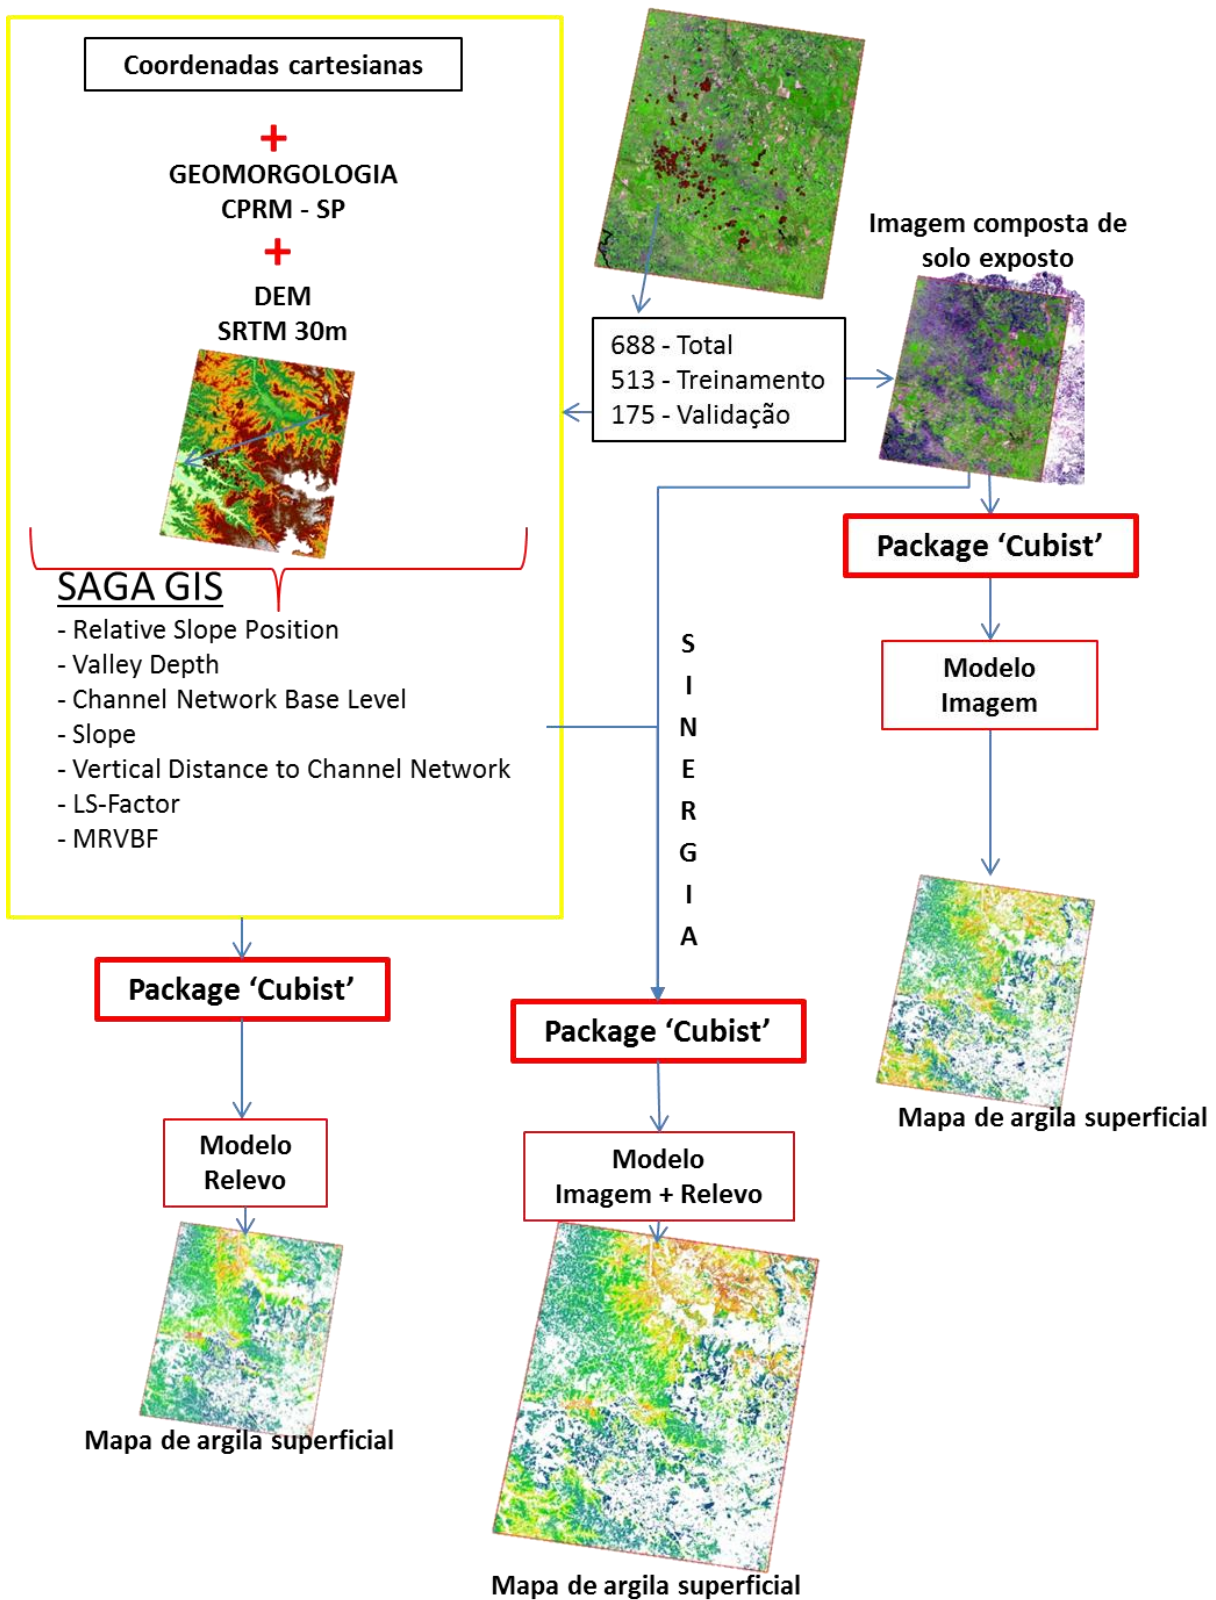


Figura 2 - Sequência metodológica




Figura 3 - Distribuição dos valores de análise granulométrica, de um total de 688 amostras

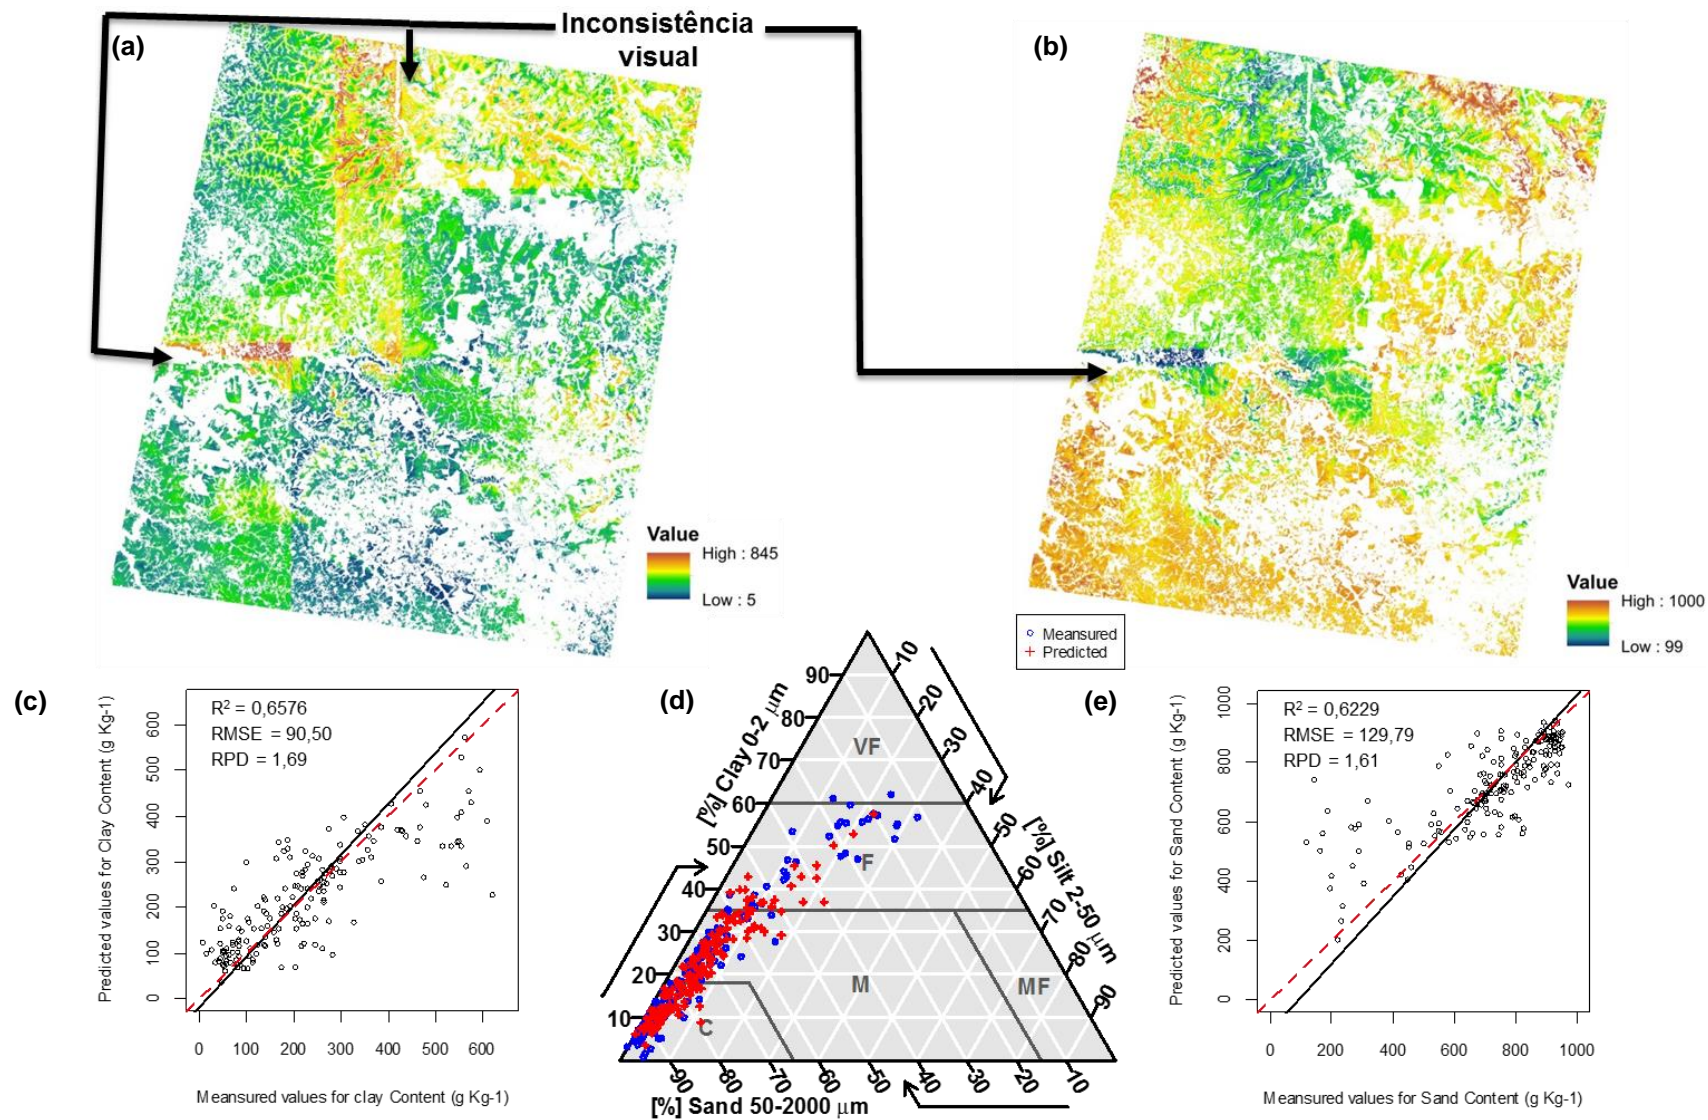


Figura 4 - Predições modelo relevo (a) mapa de argila, (b) mapa de areia, (c) predição argila, (d) triângulo textural com dados mensurados e preditos, onde C = Arenosa, MF = Siltosa, M = Média, F= Argilosa e VF = Muito Argilosa (e) predição areia

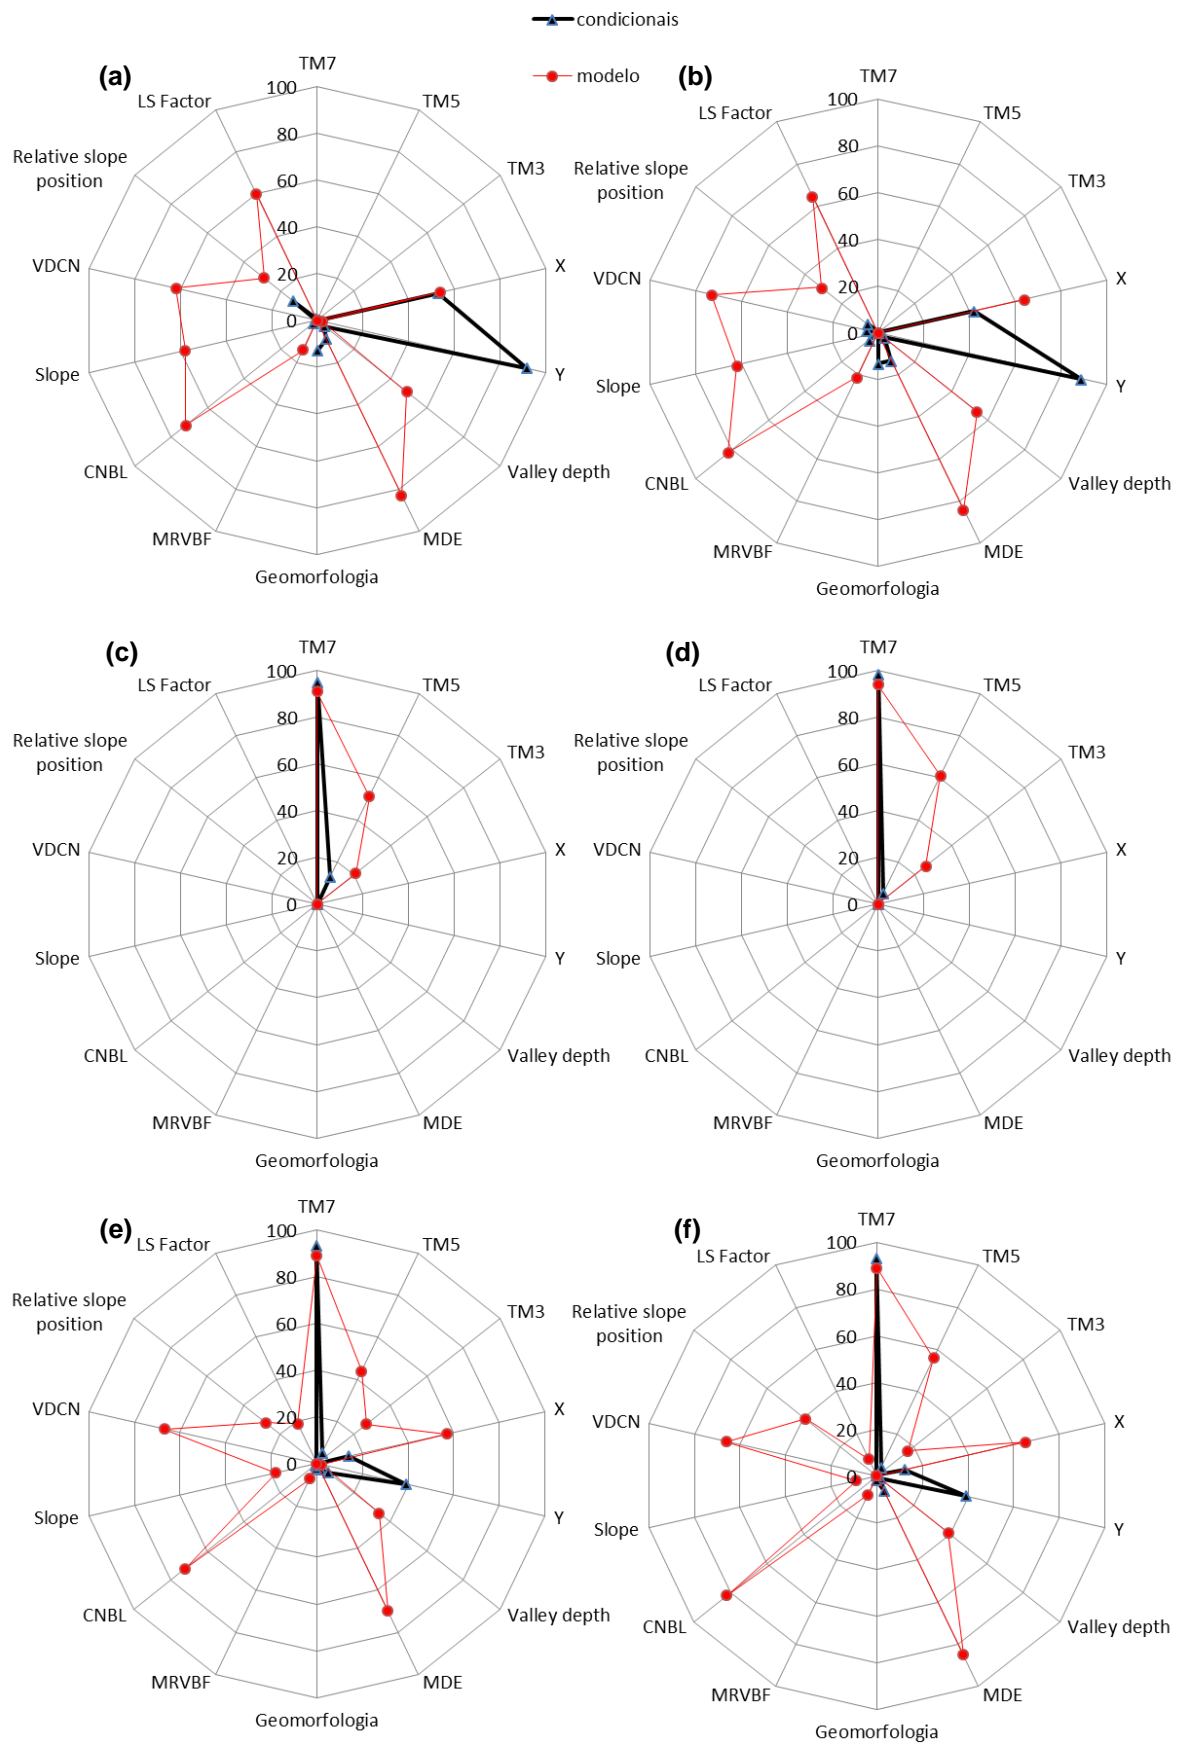


Figura 5 - Contribuição das variáveis para os modelos, para as condicionais e regressões (a) Argila relevo, (b) areia relevo, (c) argila imagem, (d) areia imagem, (e) argila imagem + relevo, (f) areia imagem + relevo

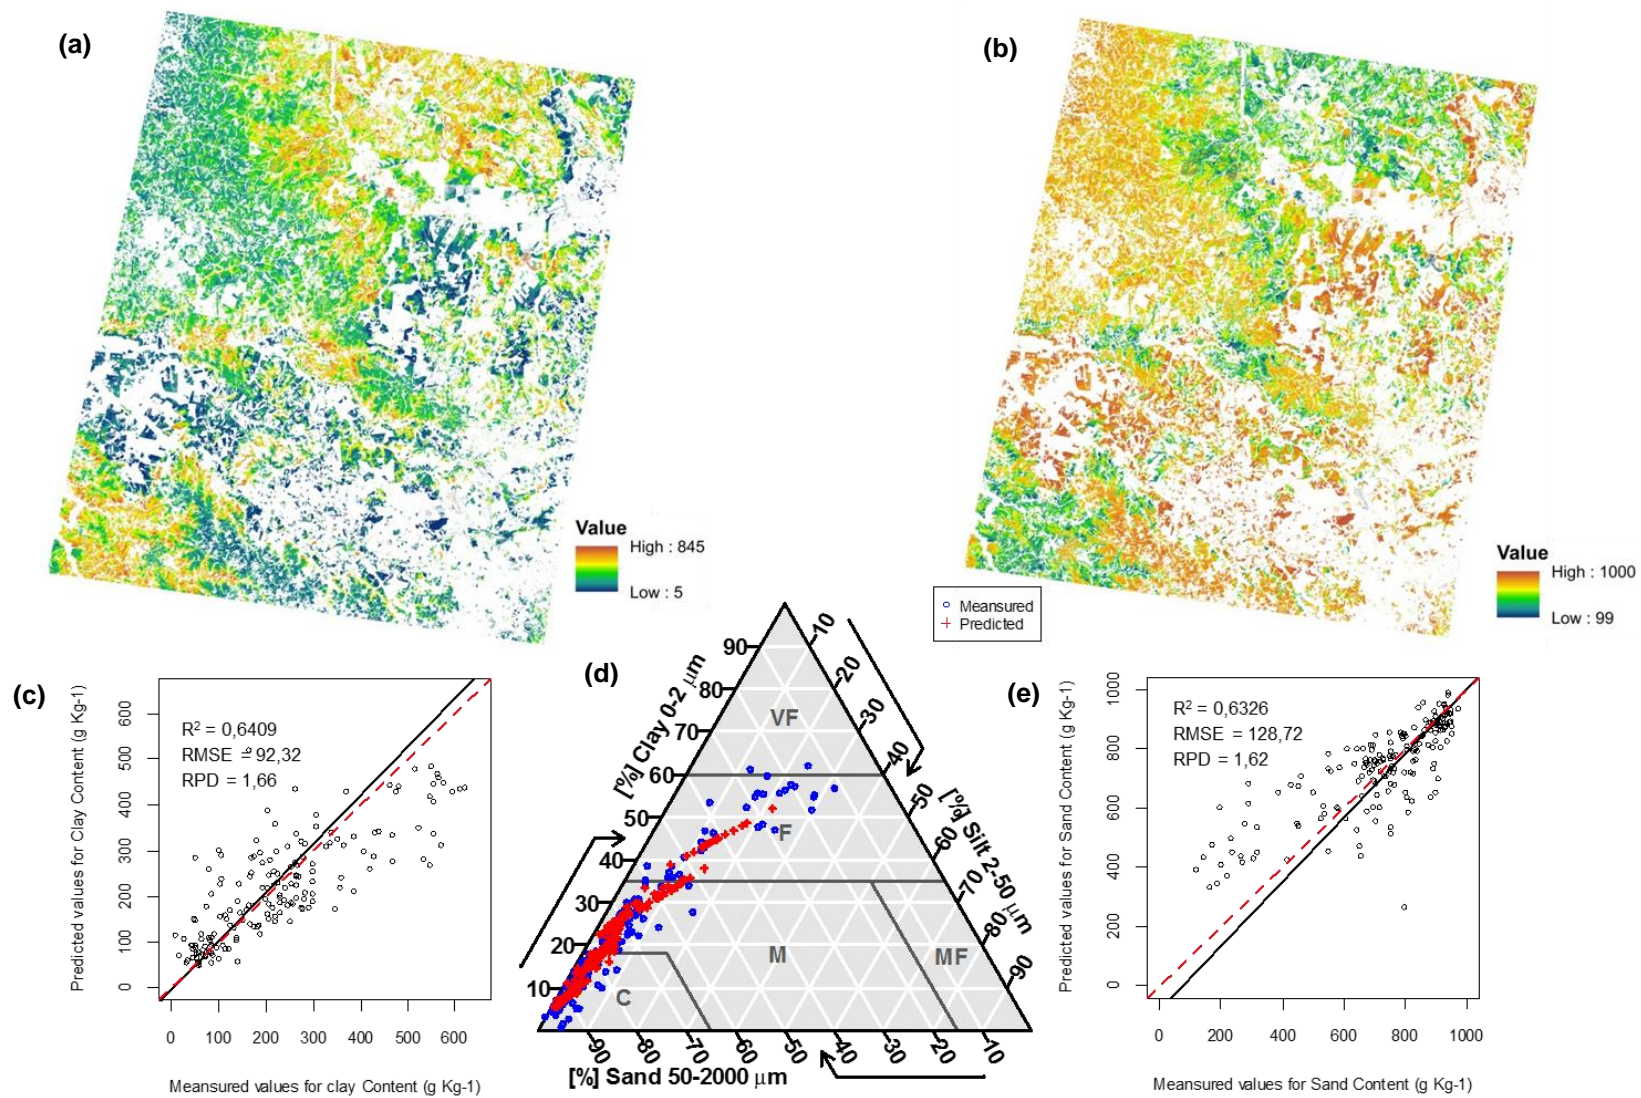


Figura 6 - Predições modelo imagem (a) mapa de argila, (b) mapa de areia, (c) predição argila, (d) triângulo textural com dados mensurados e preditos, onde C = Arenosa, MF = Siltosa, M = Média, F = Argilosa e VF = Muito Argilosa (e) predição areia

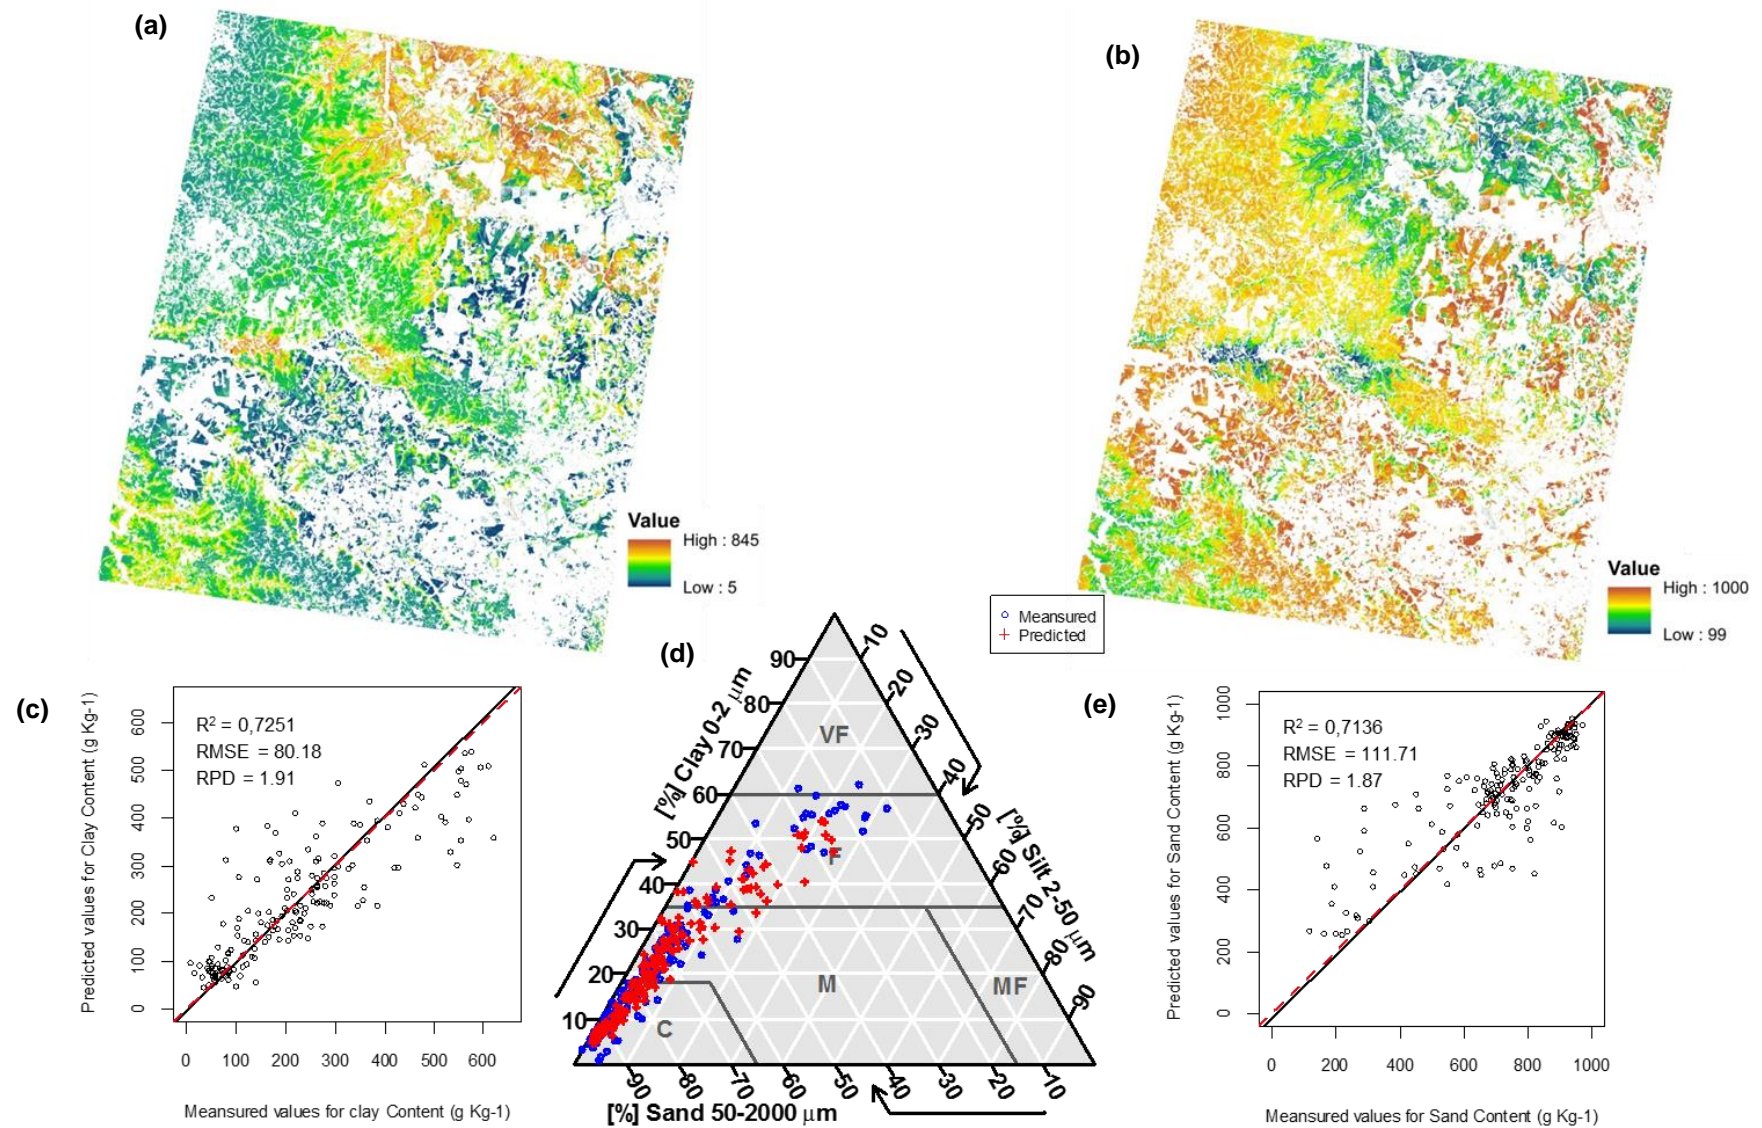


Figura 7 - Predições modelo imagem + relevo (a) mapa de argila, (b) mapa de areia, (c) predição argila, (d) triângulo textural com dados mensurados e preditos onde C = Arenosa, MF = Siltosa, M = Média, F = Argilosa e VF = Muito Argilosa (e) predição areia

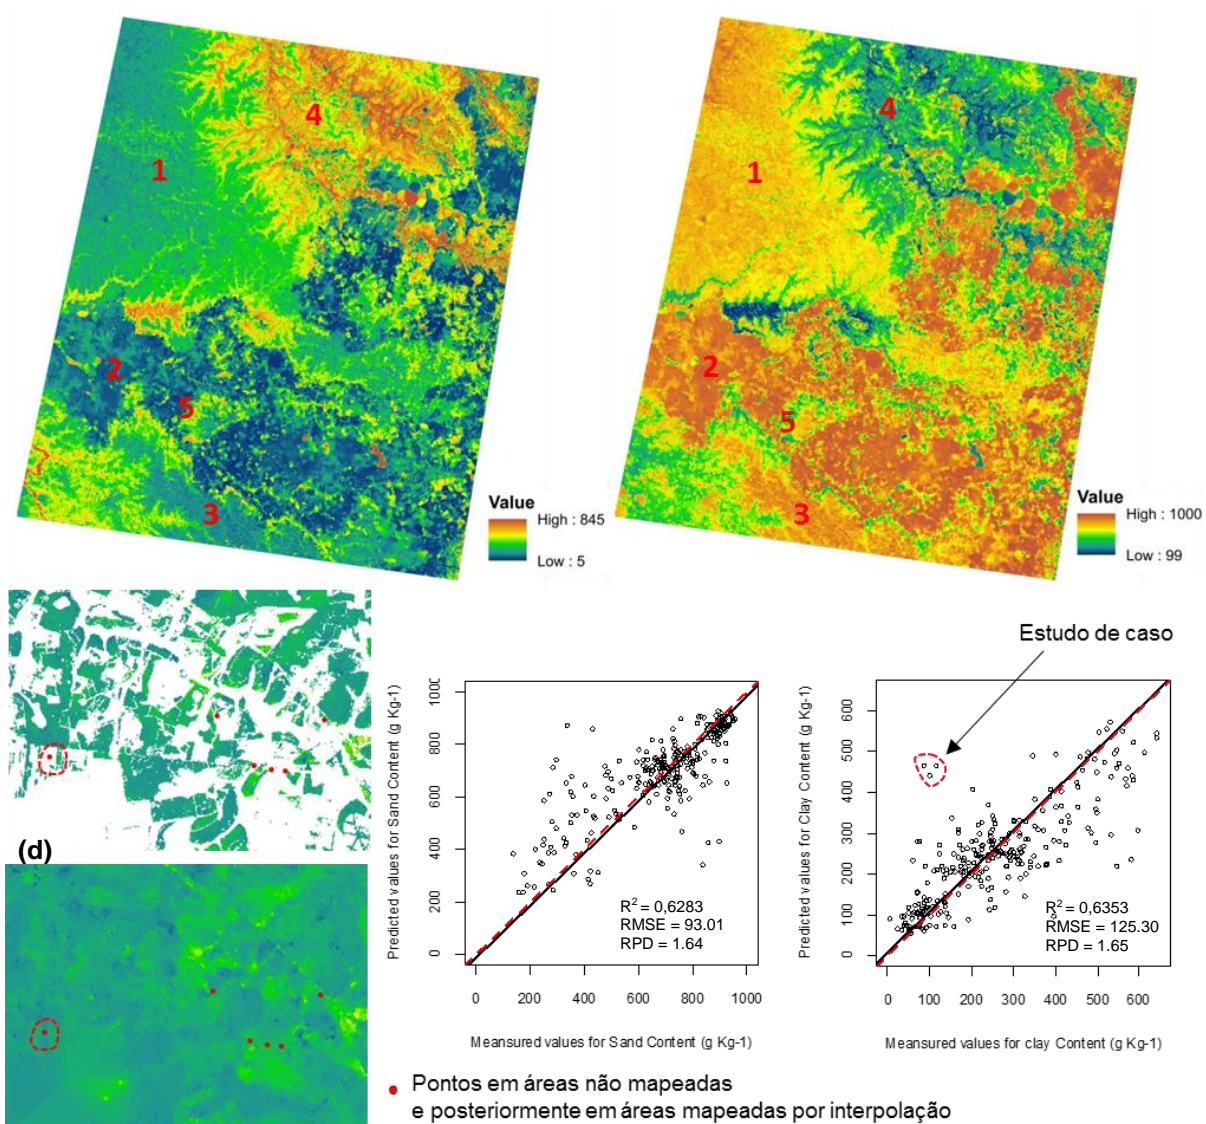


Figura 8 - Modelagem a partir dos dados de imagens de satélite Landsat associados aos atributos do relevo e geomorfologia, e ainda com mapeamento interpolado em áreas não agraciadas (a) mapa dos teores de argila, (b) mapa dos teores de areia, (c) exemplo de área com parte mapeada e parte não mapeada (áreas em branco), juntamente com pontos de localização de amostragem no campo para validação (em vermelho), (d) mesma área do item c, porém inteiramente mapeada por interpolação das áreas em branco, (e) correlação entre os pontos de campo das áreas mapeadas via interpolação para argila, (f) correlação entre os pontos de campo das áreas mapeadas via interpolação para areia

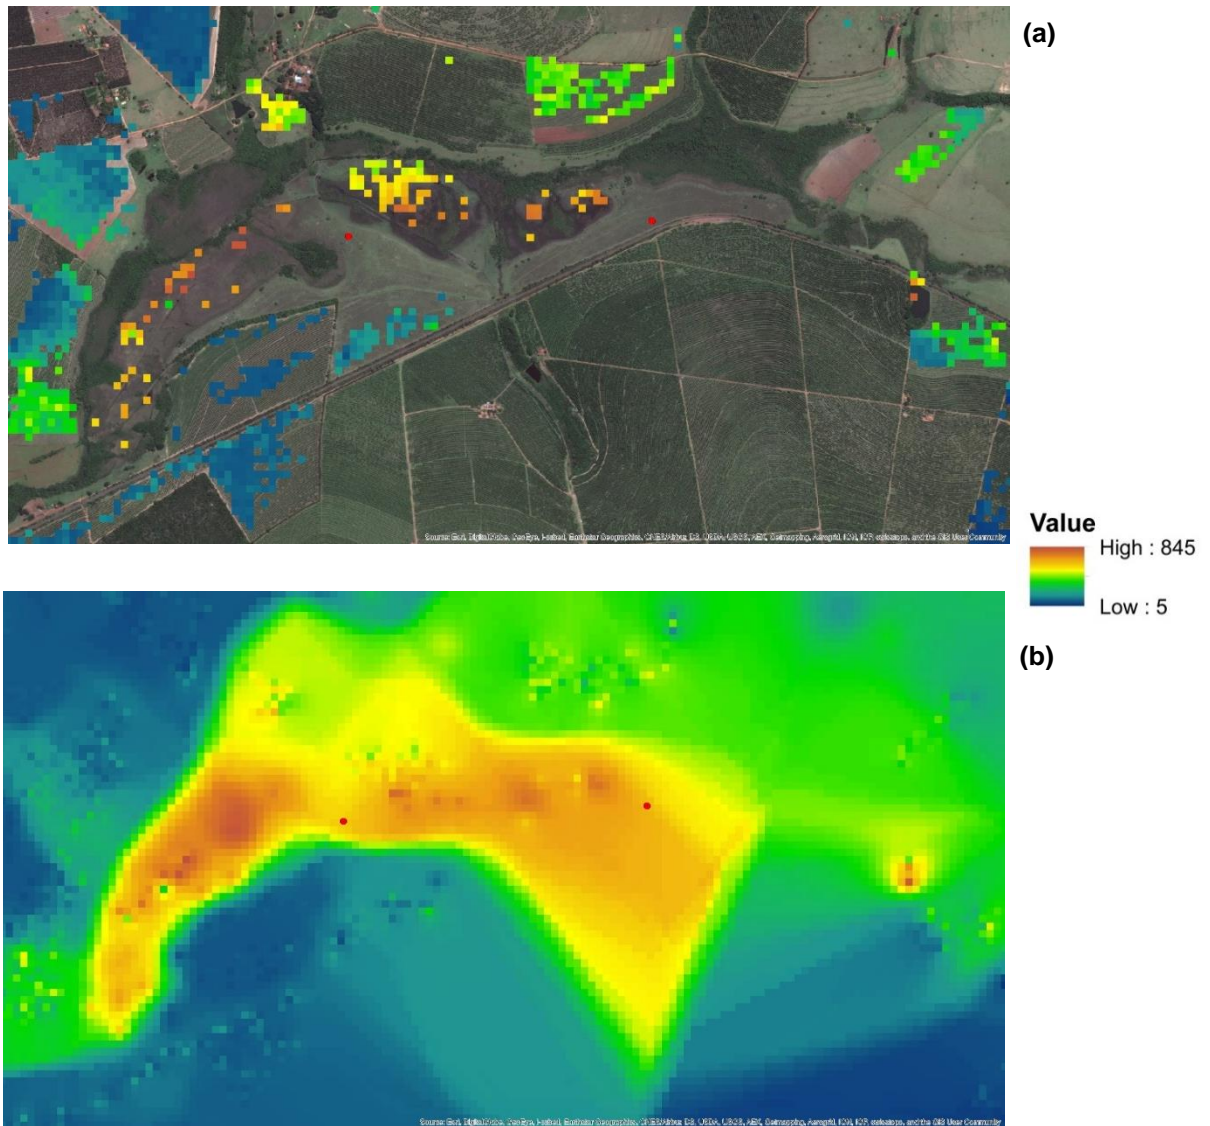


Figura 9 - Estudo de caso. (a) área com imagem de satélite de alta resolução, cor verdadeira, indicando a classificação textural. Áreas não indicadas não puderam ser mapeadas, (b) áreas mapeadas por interpolação usando modelo imagem + relevo. Pontos em vermelho indicam locais de solos com textura arenosa validados no campo

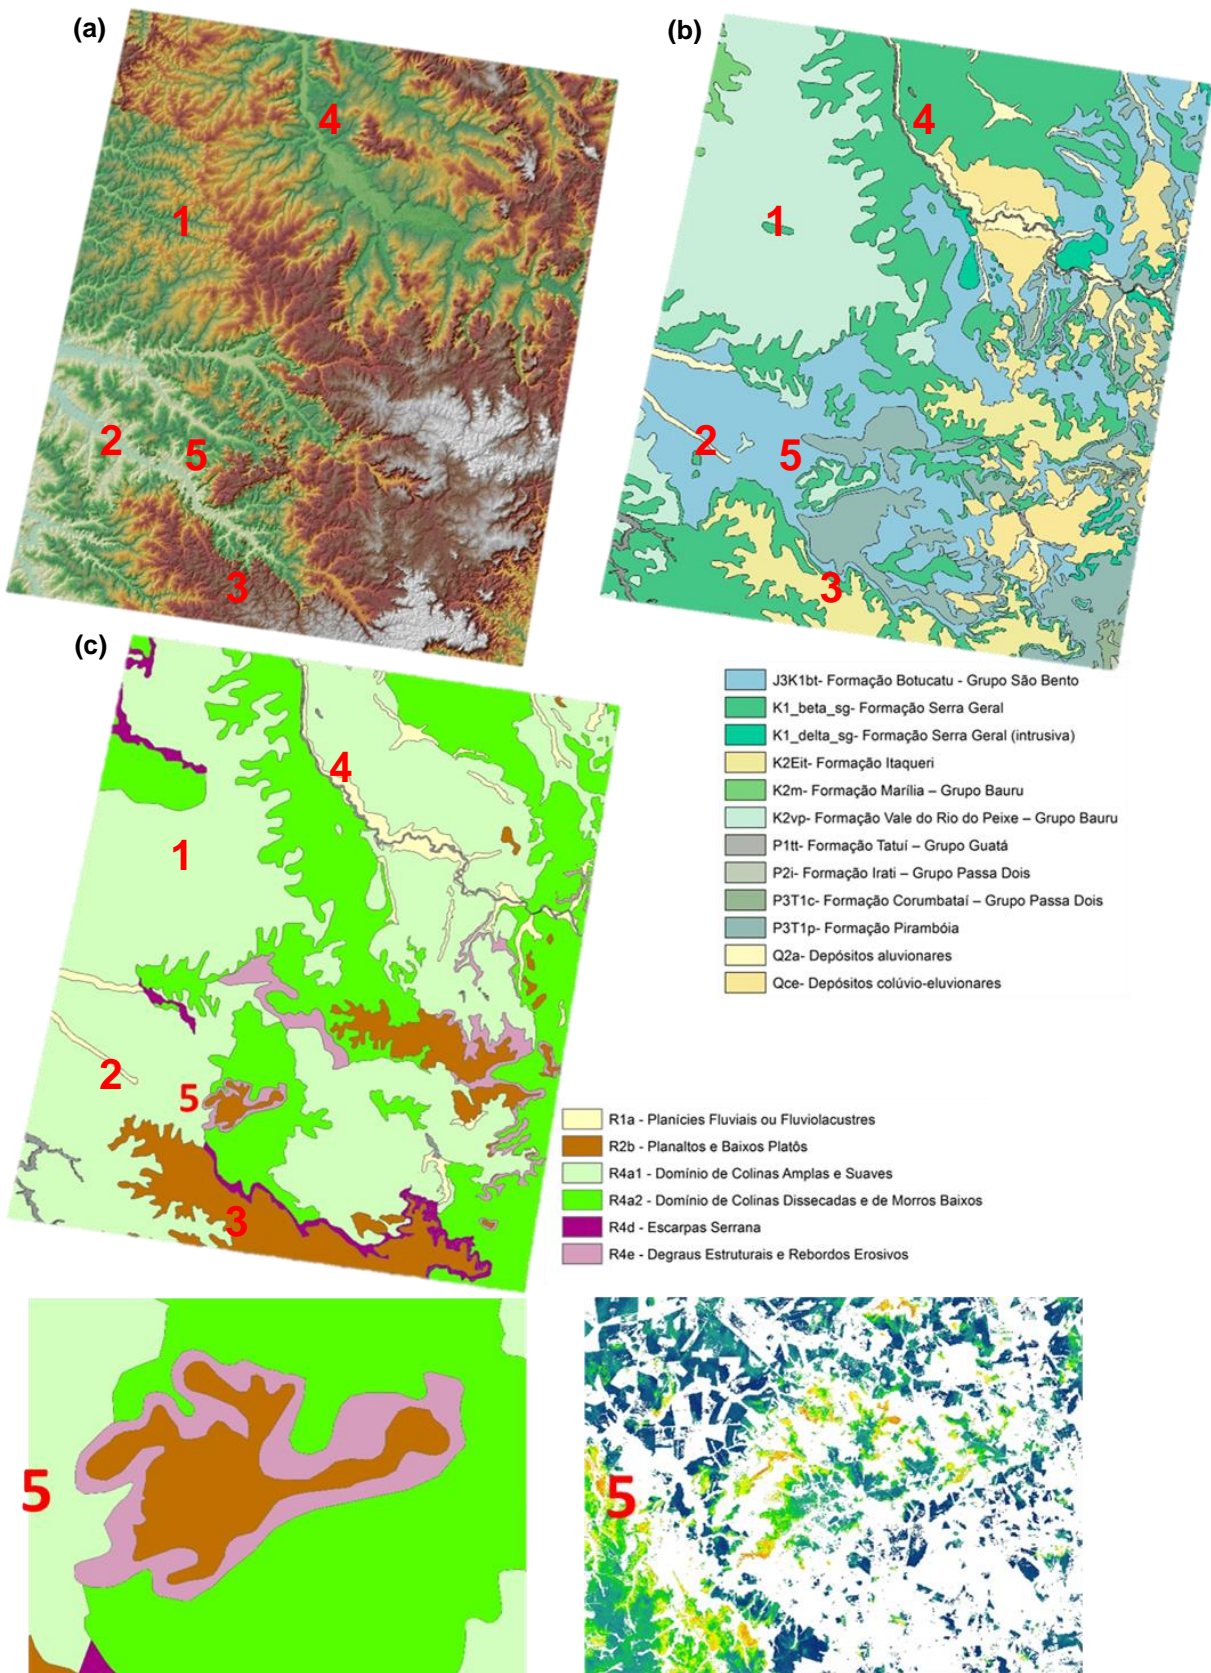


Figura 10 - Estudo de caso. (a) imagem do modelo numérico de elevação, (b) imagem do mapa geológico (CPRM, 2006), (c) imagem do mapa geomorfológico (CPRM, 2009), com detalhamento comparativo com mapa textural

Tabela 1 - Análise estatística dos dados granulométricos

Atributo	n	Média	σ	Soma	Mínimo	Máximo
Areia	688	710.1	205.5	487159	86	968
Silte		62.2	63.6	42664	2	347
Argila		227.7	150.7	156177	7	643

n. número de amostras; σ . desvio padrão

Tabela 2 - Percentagem de ocorrência das classes texturais

1 - Muito Argiloso	8	1
2 - Argiloso	123	18
3 - Médio-argiloso	132	19
4 - Médio-arenoso	169	25
5 - Arenoso	81	12
6 - Muito arenoso	175	25
Total	688	100

Tabela 3 - Resumo da quantificação de atributos do solo via espectroradiômetro (Resumido de DEMATTE et al., 2015)

Elemento*	Faixa Espectral**	Elemento Espectral***	N. cal.	Cal. Escala	R ²			RMSEP/RMSECV, SEP/SECV (%)			Autores
					Comp. de onda	Média	N	Comp. de onda	Média	N	
Lab – Seco											
Argila (%)	UV-vis-NIR	70-90	121-207	R/N	0.61-0.72	0.67	2	12.3, 8.9	12.3, 8.9	2	(Islam et al., 2003; Pirie et al., 2005)
	Vis-NIR	70->90	457-4184	G	0.73-0.78	0.77	3	7.5-12	9.5	3	(Brown et al., 2006; Ramirez-Lopez et al., 2013; Shepherd and Walsh, 2002)
	Vis-NIR	20->90	30->1000	R/N	0.02-0.91	0.78	22	2-8.5, 4.9-13.7	5.3, 7.8	26	(Demattê and Garcia, 1999; Nanni and Demattê, 2006; Bricklemyer and Brown, 2010; Chang et al., 2005; Curcio et al., 2013; Genot et al., 2011; Gogé et al., 2014; Gogé et al., 2012; Islam et al., 2003; Kinoshita et al., 2012; Knadel et al., 2013; Ramirez-Lopez et al., 2013; Ramirez-Lopez et al., 2014; Sankey et al., 2008; Stenberg, 2010; Summers et al., 2011; Thomsen et al., 2009; Waiser et al., 2007; Vendrame et al., 2012; Viscarra Rossel and Behrens, 2010; Viscarra Rossel et al., 2009; Viscarra Rossel and Lark, 2009; Viscarra Rossel and Webster, 2012)
	Vis-NIR	<5-80	16->100	F	0.39-0.82	0.70	11	0.36-6.3	1.8	11	(Debaene et al., 2014; Mahmood et al., 2012; McCarty and Reeves, 2006; Ramirez-Lopez et al., 2014; Wetterlind and Stenberg, 2010)
	NIR	30-90	35->400	R/N	0.50-0.94	0.71	10	3.9-16, 5-10.3	5.3, 8.6	11	(Ben-Dor and Banin, 1995; Chang et al., 2001; Islam et al., 2003; Malley et al., 2000; Stenberg et al., 2002; Wang et al., 2013b; Waruru et al., 2014)
	NIR	20-50	20-52	F	0.47-0.86	0.63	6	1.9-5.7	3.1	6	(Igne et al., 2010; Sudduth et al., 2010; Wetterlind et al., 2008; Viscarra Rossel et al., 2006)
	MIR	30->90	60-663	R/N	0.55-0.94	0.86	11	3.7-10.5	6.6	8	(D'Acqui et al., 2010; Ge et al., 2014b; Janik et al., 2009; Janik and Skjemstad, 1995; Minasny and McBratney, 2008; Minasny et al., 2008; Minasny et al., 2009; Pirie et al., 2005; Viscarra Rossel and Lark, 2009)
MIR	20	116-209	F	0.67-0.77	0.70	3	1.6~2	1.7	3	(Igne et al., 2010; McCarty and Reeves, 2006; Viscarra Rossel et al., 2006)	
Em campo (incluindo medições no local e “on the go”)											
Argila (%)	Vis-NIR	40-60	311->1000	R/N	0.17-0.83	0.78	3	6.1-7.9, 9.0	7.0, 9.0	3	(Bricklemyer and Brown, 2010; Waiser et al., 2007; Viscarra Rossel et al., 2009)
	Vis-NIR	20	209	F	~0.7	~0.7	1	~2	~2	1	(Igne et al., 2010)

Tabela 4 - Resumo da quantificação de atributos do solo via plataformas espaciais (Resumido de Demattê et al., 2015)

Propriedades do Solo	Sensor	Nr.Amostras (total/validação)	Modelo Abordado	Validação	Validação / Resultados de Calibração			Autores
					R ² (P) / R ² (CV)	RMSEP / RMSECV	SEP / SECV	
Multispectral								
Argila	LANDSAT 5 ^b	378/95	MLR	Pred.	0.61	-	-	Fiorio et al. (2010)
	LANDSAT 5 ^b	184	MLR	-	0.675	-	-	Nanni & Demattê, (2006a)
	LANDSAT 7 ^b	110/155	MLR	Pred.	0.63	-	-	Demattê et al. (2007a)
Areia	LANDSAT 5 ^b	378/95	MLR	Pred.	0.63	-	-	Fiorio et al. (2010)
	LANDSAT 5 ^b	184	MLR	-	0.525	-	-	Nanni & Demattê (2006a)
	LANDSAT 7 ^b	110/155	MLR	Pred.	0.67	-	-	Demattê et al. (2007a)
	ASTER ^b	22/5	ER	Pred.	0.63	19,33 g kg ⁻¹	-	Breunig et al. (2008)
Silte	LANDSAT 5 ^b	378/95	MLR	Pred.	0.54	-	-	Fiorio et al. (2010)
	LANDSAT 5 ^b	184	MLR	-	0.508	-	-	Nanni & Demattê, (2006a)
	LANDSAT 7 ^b	110/155	MLR	Pred.	0.29	-	-	Demattê et al. (2007a)
Argila	MIVIS ^a	80/29	PLSR	Pred.	0.48	7.20%	-	Casa et al. (2013b)
	CHRIS-PROBA ^b				0.52	6.87%	-	
	CHRIS-PROBA ^b	132 / 44	RK / PLSR / PLSR-K	Pred.	-	5.33 - 5.82%	-	Casa et al. (2013a)
	AVNIR ^a	321	MLR	-	0.6708	3.23%	-	DeTar et al. (2008)
	SIM-GA ^a	40 / 11	Regression with band depth (2210 nm)	Pred.	0.5994	-	-	Garfagnoli et al. (2013)
	HyMap ^a	67 / 29	PLSR	Pred.	0.85	-	19.41 / 20.34 g kg ⁻¹	Gerighausen et al. (2012)
	HyMap ^a	52	PLSR	CV (LOO)	0.64	49.60 g kg ⁻¹	-	Gomez et al. (2008a)
	HyMap ^a	95	PLSR	CV (LOO)	0.67	42.15 g kg ⁻¹	-	Gomez et al. (2012)
	SpecTIR ^a	269	PLSR	CV (LOO)	0.66	2.2%	-	Hively et al. (2011)
		33			0.61	54 g kg ⁻¹	-	
	HyMap ^a	19	Regression with CR data (2206 nm)	CV (LOO)	0.60	130 g kg ⁻¹	-	Lagacherie et al. (2008)
		33 + 19			0.58	82 g kg ⁻¹	-	
	AISA-Dual Vis-NIR ^a	152/30	PLSR / Regression trees	CV (LOO) and Pred.	0.81 / 0.78 / 0.78 / 0.77	87 / 67 / 93 / 69 g kg ⁻¹	-	Lagacherie et al. (2013)
	HyMap ^a	72	PLSR / MLR	CV (LOO)	0.71 / 0.65	4.2 / 3.8%	-	Selige et al. (2006)
	EO-1 Hyperion ^b	28 / 08	PLSR	Pred.	0.51 / 0.83	5.46 / 2.21%	-	Zhang et al. (2013)
Areia	EO-1 Hyperion ^b	18	PLSR	CV (LOO)	0.58	7.02%	-	Anne et al. (2014)
	MIVIS ^a	80/29	PLSR	Pred.	0.64	7.82%	-	Casa et al. (2013b)
	CHRIS-PROBA ^b				0.45	9.32%	-	
	CHRIS-PROBA ^b	132 / 44	RK / PLSR / PLSR-K	Pred.	-	6.80 - 7.40%	-	Casa et al. (2013a)
	AVNIR ^a	321	MLR	-	0.8063	4.83%	-	DeTar et al. (2008)
	HyMap ^a	95	PLSR	CV (LOO)	0.20	90.47 g kg ⁻¹	-	Gomez et al. (2012)
	SpecTIR ^a	269	PLSR	CV (LOO)	0.79	7.9%	-	Hively et al. (2011)
	AISA-Dual Vis-NIR ^a	152/30	PLSR / Regression trees	CV (LOO) and Pred.	0.75 / 0.83 / 0.78 / 0.77	119 / 97 / 111 / 107 g kg ⁻¹	-	Lagacherie et al. (2013)
	HyMap ^a	72	PLSR / MLR	CV (LOO)	0.95 / 0.87	9.7 / 12.9%	-	Selige et al. (2006)
	Silte	MIVIS ^a	80/29	PLSR	Pred.	0.32	3.28%	-
CHRIS-PROBA ^b					0.23	3.43%	-	
CHRIS-PROBA ^b		132 / 44	RK / PLSR / PLSR-K	Pred.	-	3.12 - 3.67%	-	Casa et al. (2013a)
AVNIR ^a		321	MLR	-	0.7518	3.34%	-	DeTar et al. (2008)
HyMap ^a		95	PLSR	CV (LOO)	0.17	74.84 g kg ⁻¹	-	Gomez et al. (2012)
Silte + Argila	SpecTIR ^a	269	PLSR	CV (LOO)	0.79	6.9%	-	Hively et al. (2011)
	EO-1 Hyperion ^b	18	PLSR	CV (LOO)	0.82	1.95%	-	Anne et al. (2014)

Referências

- ALVES, M.R.; DEMATTE, J.A.M.; BARROS, P.P.S. Multiple Geotechnological Tools Applied to Digital Mapping of Tropical Soils. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 39, p.1-15, 2015
- ARAÚJO, S.R.; WETTERLIND, J.; DEMATTÊ, J.A.M.; STENBERG, B. Improving the prediction performance of a large tropical vis-NIR spectroscopic soil library from Brazil by clustering into smaller subsets or use of data mining calibration techniques. **European Journal of Soil Science**, Hoboken, v. 65, n. 5, p. 718-729, 2014.
- ARRUDA, G.P.; J.A.M.; DEMATTÊ & CHAGAS, C.S. MAPEAMENTO DIGITAL DE SOLOS POR REDES NEURAIS ARTIFICIAIS COM BASE NA RELAÇÃO SOLO-PAISAGEM. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 37, p.327-338, 2013.
- BAND, L.E. Extraction of channel networks and topographic parameters from digital elevation data. **Channel Network Hydrology**, Chichester, v.19, n7, p. 13-42, 1993.
- BELLINASSO, H.; DEMATTÊ, J.A.; ROMEIRO, M. ; ARAUJO, S. Soil spectral library and its use in soil classification. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 34, n. 3, p. 861-870, 2010.
- BEN DOR, E.; TAYLOR, R.G.; HILL, J.; DEMATTÊ, J.A.M.; WHITING, M.L.; CHABRILLAT, S.; SOMMER, S. Imaging spectrometry for soil applications. **Remote Sensing Environment**, New York, v.113, p.535-558, 2009.
- BEN-DOR, E.; BANIN, A. Near-infrared analysis as a rapid method to simultaneously evaluate several soil properties. **Soil Science Society of America Journal**, Madison, v. 59, n. 2, p. 364-372, 1995.
- BISHOP, T. F.A.; MINASNY, B.; MCBRATNEY, A.B. Uncertainty analysis for soil-terrain models. **International Journal of Geographical Information Science**, Oxon, v. 20, n. 2, p. 117-134, 2006.
- BOEHNER, J.; CONRAD, O. **Module Relative Heights and Slope Positions**. 2008. Disponível em: http://www.saga-gis.org/saga_module_doc/2.1.4/ta_morphometry_14.html. Acesso em: 14 nov. 2015.
- BOEHNER, J.; KOETHE, R. ; CONRAD, O.; GROSS, J.; RINGELER, A.; SELIGE, T. Soil Regionalisation by Means of Terrain Analysis and Process Parameterisation. In: MICHELI, E.; NACHTERGAELE, F.; MONTANARELLA, L. Ed. **Soil Classification** 2001. Luxembourg:European Soil Bureau, 2002. , p.213-222, Research Report No. 7, EUR 20398).
- BOWERS, S.A.; HANKS, R.J. Reflection of radiant energy from soils. **Soil Science**, Philadelphia, v. 100, n. 2, p. 130-138, 1965.
- BRICKLEMYER, R. S.; BROWN, D. J. On-the-go VisNIR: Potential and limitations for mapping soil clay and organic carbon. **Computers and Electronics in Agriculture**, Oxon, v. 70, n. 1, p. 209-216, 2010.

C.W. CHANG, D.A. ;LAIRD, M.J.; MAUSBACH, C.R. ;HURBURGH Near-infrared reflectance spectroscopy-principal components regression analyses of soil properties **Soil Science Society of America Journal**, Madison, 65, p. 480–490, 2001.

CAMARGO, O.; MONIZ, A.; JORGE, J.; VALADARES, J. Métodos de análise química, mineralógica e física de solos do Instituto Agronômico de Campinas. Campinas, Instituto Agronômico de Campinas, 1986. 94p. (Boletim Técnico, v. 106.)

CARR, M.B. Determining the optimum number of predictors for a linear prediction equation. **Monthly Weather Review**. Boston, v. 116, n.8, 1623–1640, 1988.

CASA, R.; CASTALDI, F.; PASCUCCI, S.;PALOMBO, A.; PIGNATTI, S. A comparison of sensor resolution and calibration strategies for soil texture estimation from hyperspectral remote sensing. **Geoderma**, Amsterdam, v. 197, p. 17-26, 2013

CEDDIA, M.B. ; VIEIRA, S. R. ; VILELLA, A. L. O. ; MOTA, L.Santos ; CARVALHO, D. . de ; ANJOS, L. H. C. dos . Topography and spatial variability of soil physical properties. **Scientia Agrícola**, Piracicaba, v. 66, p. 338-352, 2009.

CHEN, F.; KISSEL, D.E.; WEST, L.T.; ADKINS, W.; RICKMAN, D.;LUVALL, J. C. Mapping soil organic carbon concentration for multiple fields with image similarity analysis. **Soil Science Society of America Journal**, Madison, v. 72, n. 1, p. 186-193, 2008.

COLEMAN, T.L.;AGBU, P.A.; MONTGOMERY, O.L.; GAO, T.; PRASAD, S. Spectral band selection for quantifying selected properties in highly weathered soils. **Soil Science**, Baltimore v. 151, n. 5, p. 355-361, 1991.

CONRAD, O. **Module Inverse Distance Weighted**. 2003. Disponível em: http://www.saga-gis.org/saga_module_doc/2.1.3/grid_gridding_1.html. Acesso em: 13 nov. 2015.

CONRAD, O. Module Valley Depth. 2012. Disponível em: http://www.saga-gis.org/saga_module_doc/2.1.3/ta_channels_7.html. Acesso em 13 nov. 2015.

CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; ... BÖHNER, J. System for Automated Geoscientific Analyses (SAGA) v. 2.1. 4. **Geoscientific Model Development Discussions**, Göttingen, v. 8, n. 2, p. 2271-2312, 2015.

CPRM , Serviço Geológico DO BRASIL. **Mapa Geológico do Estado de São Paulo**. SIG Brasil, v. 1, n. 2006, Escala: 1:750.000. 1 CD ROM.

CPRM, SERVIÇO GEOLÓGICO DO BRASIL. **Mapa Geodiversidade do Estado de São Paulo**. 2009, Escala: 1:750.000.

DE OLIVEIRA, D.P.; FERREIRA, T.O.;ROMERO, R.E.; FARIAS, P.R.S.; COSTA, M.C.G. Microrrelevo e a distribuição de frações granulométricas em Cambissolos de origem calcária, **Revista Ciência Agronômica**, Fortaleza , v. 44, n. 4, p. 676-684, Dec. 2013 .

DEMATTE, J.A.M.; GALDOS, M.V.; GUIMARÃES, R.V. GENÚ, A.M. NANNI, M. R.; ZULLO JR, J. Quantification of tropical soil attributes from ETM+/LANDSAT-7 data. **International Journal of Remote Sensing**, Oxon, v. 28, n. 17, p. 3813-3829, 2007.

DEMATTÊ, J.A.M.; HUETE, A.R. FERREIRA JÚNIOR, L.G.; NANNI, M.R.; ALVES, M.C.; FIORIO, P.R. Methodology for bare soil detection and discrimination by Landsat TM image. **Open Remote Sensing Journal**, Sharjah, v. 2, p. 24-35, 2009a

DEMATTÊ, J.A.M. HUETE, A.R. FERREIRA JÚNIOR, L.G. NANNI, M.R.; ALVES, M.C.; FIORIO, P.R. Methodology for bare soil detection and discrimination by Landsat TM image. **Open Remote Sensing Journal**, Sharjah, v. 2, p. 24-35, 2009b

DEMATTÊ, J.A.M.; MORETI, D.; VASCONCELOS, A.D.; GENÚ, A.M. Uso de imagens de satélite na discriminação de solos desenvolvidos de basalto e arenito na região de Paraguaçu Paulista. **Pesquisa Agropecuária Brasileira**, Brasília, v. 40, n. 7, p. 697-706, July 2005.

DEMATTÊ, J.A.M.; NANNI, M.R. Weathering sequence of soils developed from basalt as evaluated by laboratory (IRIS), airborne (AVIRIS) and orbital (TM) sensors. **International Journal of Remote Sensing**, Oxon, v. 24, n. 23, p. 4715-4738, 2003

DEMATTÊ, J.A.; ALVES, M.R.; GALLO, B.C.; FONGARO, C.T. Detection of soil class boundaries based on spectral and relief data. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 38, n. 3, p. 718-729, 2014.

DEMATTÊ, J.L.I.; DEMATTÊ, J.A.M. Ambientes de produção como estratégia de manejo na cultura de cana-de-açúcar. **Informações Agronômicas**, Piracicaba, n.127, p.10-18, 2009.

DEMATTE, J. A. M.; CAMPOS, R. C.; ALVES, M. C. Avaliação espectral de solos desenvolvidos em uma toposeqüência de diabásio e folhelho da região de Piracicaba, SP. **Pesquisa Agropecuária Brasileira. bras.**, Brasília, v. 35, n. 12, p. 2447-2460, Dec. 2000

DEMATTÊ, J. A.M.; RIZZO, R.; BORTOLETTO, M. A. M. Método geotecnológico integrativo na caracterização de solos desenvolvidos de diferentes materiais de origem. **Bragantia**, Campinas, v. 70, n. 3, p. 638-648, 2011.

DEMATTÊ, J. A.M.; RIZZO, R.; BOTTEON, V. W. Pedological mapping through integration of digital terrain models spectral sensing and photopedology. **Revista Ciência Agronômica**, Fortaleza v. 46, n. 4, p. 669-678, 2015.

DESMET, P.J.J.; GOVERS, G.. A GIS procedure for automatically calculating the USLE LS factor on topographically complex landscape units. **Journal of Soil And Water Conservation**, Ankeny, v. 51, n. 5, p. 427-433, 1996.

DETAR, W.R.J.H. ;CHESSON, J.V.;PENNER, ;J.C. OJALA. Detection of soil properties with airborne. **Transactions of the ASABE**, St Joseph, v. 51, n. 2, p. 463-470, 2008.

FARR, T.G.; ROSEN, P.A.; CARO, E.; CRIPPEN, R.; DUREN, R.; HENSLEY, S. ;ALSDORF, D. The shuttle radar topography mission. **Reviews of Geophysics**, Washington, v. 45, n. 2, p. 1-33,2007.

FIORIO, P.R.; DEMATTÊ, J.A.; NANNI, M.R.; FORMAGGIO, A.R. Diferenciação espectral de solos utilizando dados obtidos em laboratório e por sensor orbital. **Bragantia**, Campinas, v. 69, n. 2, p. 453-466, 2010.

FIORIO, P. R.; DEMATTÊ, J. A. M. Orbital and laboratory spectral data to optimize soil analysis. **Scientia Agricola**, Piracicaba, v. 66, n. 2, p. 250-257, 2009.

FLORINSKY, I. V. **Digital terrain analysis in soil science and geology**. Oxford: Academic Press, 2012. 373p.

FRANCESCHINI, M.H.D. DEMATTÊ, J.A.M. DA SILVA TERRA, F.; VICENTE, L. E.; BARTHOLOMEUS, H.; DE SOUZA FILHO, C.R. Prediction of soil properties using imaging spectroscopy: Considering fractional vegetation cover to improve accuracy. **International Journal of Applied Earth Observation and Geoinformation**, Amsterdam, v. 38, p. 358-370, 2015.

FRANCESCHINI, M.H.D.; DEMATTÊ, J.A.M.; SATO, M.V.; VICENTE, L.E. ; GREGO, C.R. Semiquantitative and quantitative approaches for soil texture evaluation through VIS-NIR-SWIR bidirectional reflectance spectroscopy. **Pesquisa Agropecuária Brasileira**, Brasília, v. 48, n. 12, p. 1569-1582, 2013.

FREEMAN, T. Graham. Calculating catchment area with divergent flow based on a regular grid. **Computers & Geosciences**, Oxford, v. 17, n. 3, p. 413-422, 1991.

GALLANT, J. C.; DOWLING, T. I. A multiresolution index of valley bottom flatness for mapping depositional areas. **Water Resources Research**, Washington, v. 39, n. 12, 2003.

GALLANT, J. C.; WILSON, J. P. TAPES-G: a grid-based terrain analysis program for the environmental sciences. **Computers & Geosciences**, Oxford, v. 22, n. 7, p. 713-722, 1996.

GENU, A.M.; DEMATTE, J.A.M. Espectrorradiometria de solos e comparação com sensores orbitais. **Bragantia**, Campinas, v. 71, n. 1, p. 82-89, 2012

GENÚ, A.M.; DEMATTÊ, J.A.M.; NANNI, M.R. Geoprocessing for spatial evaluation of soil variables from Rafard-SP. **Applied Research & Agrotechnology**, Guarapuava, v. 4, n. 1, p. 07-29, 2012.

GESSLER, P.E.; MOORE, I.D.; MCKENZIE, N.J.; RYAN, P.J. Soil-landscape modelling and spatial prediction of soil attributes. **International Journal of Geographical Information Science**, Oxon, v. 9, p.421-432, 1995.

GOMEZ, C.; LAGACHERIE, P.; COULOUMA, G. Continuum removal versus PLSR method for clay and calcium carbonate content estimation from laboratory and airborne hyperspectral measurements. **Geoderma**, Amsterdam, v. 148, n. 2, p. 141-148, 2008.

GOMEZ, C.; LAGACHERIE, P.; COULOUMA, G. Regional predictions of eight common soil properties and their spatial structures from hyperspectral Vis-NIR data. **Geoderma**, Amsterdam, v. 189, p. 176-185, 2012.

- HAUBROCK, S.N.; CHABRILLAT, S.; LEMMNITZ, C.; KAUFMANN, H. Surface soil moisture quantification models from reflectance data under field conditions. **International Journal of Remote Sensing**, Oxon, v. 29, n. 1, p. 3-29, 2008.
- HEERDEGEN, R.G.; BERAN, M.A. Quantifying source areas through land surface curvature and shape. **Journal of Hydrology**, Amsterdam, v. 57, n. 3, p. 359-373, 1982.
- HENDERSON, B.L.; BUI, E.N.; MORAN, C.J.; SIMON, D.A.P. Australia-wide predictions of soil properties using decision trees. **Geoderma**, Amsterdam, v. 124, n. 3, p. 383-398, 2005.
- HENDERSON, T.L.; BAUMGARDNER, M.F.; FRANZMEIER, D.P.; STOTT, D.E.; COSTER, D.C. High dimensional reflectance analysis of soil organic matter. **Soil Science Society of America Journal**, Madison, v. 56, n. 3, p. 865-872, 1992.
- HEWSON, R.D.; CUDAHY, T.J.; JONES, M. THOMAS, M. Investigations into soil composition and texture using infrared spectroscopy (2–14 m). **Applied and Environmental Soil Science**, Cairo, vol. 2012, Article ID 535646, 12 p.
- HIVELY, W.D.; MCCARTY, G.W.; REEVES, J.B.; LANG, M.W.; OESTERLING, R. A.; DELWICHE, S.R. Use of airborne hyperspectral imagery to map soil properties in tilled agricultural fields. **Applied and Environmental Soil Science**, Cairo, v. 2011, Article ID 358193, p. 13, 2011.
- HORN, B.K.P. Hill shading and the reflectance map. **Proceedings of the IEEE**, Piscataway, v. 69, n. 1, p. 14-47, 1981.
- HUNT, G.R.; SALISBURY, J.W.; LEMHOFF, C.J. Visible and near-infrared spectra of minerals and rocks: III. Oxides and hydroxides. **Modern Geology**, Belfast, v.2, p.195-205, 1971
- JENNY, Hans. **Factores of Soil Formation: A System of Quantitative Pedology**. New York: McGraw-Hill, 1942. 320 p.
- KOTHE, R.; LEHMEIER, F. SARA—**System zur Automatischen Relief-Analyse, Benutzerhandbuch – buch UNIX-Version**. Göttingen: Department of Geography, University of Göttingen, 1996.
- LANDRUM, C.; CASTRIGNANÒ, A.; MUELLER, T.; ZOURARAKIS, D.; ZHU, J.; DE BENEDETTO, D. An approach for delineating homogeneous within-field zones using proximal sensing and multivariate geostatistics. **Agricultural Water Management**, Amsterdam, v. 147, p. 144-153, 2014.
- LOBELL, D.B.; ASNER, G.P. Moisture effects on soil reflectance. **Soil Science Society of America Journal**, Madison, v. 66, n. 3, p. 722-727, 2002.
- LOVELAND, T. R.; DWYER, J. L. Landsat: Building a strong future. **Remote Sensing of Environment**, New York v. 122, p. 22-29, 2012.
- MADEIRA, N.J. **Etude Quantitative des Relations Constituants Minéralogiques-Réfectance Diffuse des Latosols Brésiliens: Application à l'utilisation Pédologique des**

Données Satellitaires TM (Région de Brasilia). Paris, France: Université Pierre et Marie Curie: 1993. 250p.

MARTZ, L. W.; GARBRECHT, J. An outlet breaching algorithm for the treatment of closed depressions in a raster DEM. **Computers & Geosciences**, Oxford, v. 25, n. 7, p. 835-844, 1999.

MAX K., STEVE W., CHRIS K. ; NATHAN C. C code for Cubist by Ross Quinlan (2014). **Cubist: Rule- and Instance-Based Regression Modeling**. R package version 0.0.18. <http://CRAN.R-project.org/package=Cubist>

MAX K, Contributions from Jed Wing, Steve Weston, Andre Williams, Chris Keefer, Allan Engelhardt, Tony Cooper, Zachary Mayer, Brenton Kenkel, the R Core Team, Michael Benesty, Reynald Lescarbeau, Andrew Ziem, Luca Scrucca, Yuan Tang and Can Candan. (2015). **caret: Classification and Regression Training**. R package version 6.0-58. <http://CRAN.R-project.org/package=caret>

MCBRATNEY, A.B.; SANTOS, M.L. Mendonça; MINASNY, B. On digital soil mapping. **Geoderma**, Amsterdam, v. 117, n. 1, p. 3-52, 2003.

MCKENZIE, N. J.; RYAN, P. J. Spatial prediction of soil properties using environmental correlation. **Geoderma**, Amsterdam, v. 89, n. 1, p. 67-94, 1999.

MEIRVENNE, M.V.; CLEEMPUT, I.V. **Pedometrical techniques for soil texture mapping at different scales**. In, Environmental soil landscape modeling, Geographic information technologies and pedometrics, ed. Sabine Grunwald, Ed. Taylor and Francis, p.488. p. 323-341, 2006.

MILLER, B.A. KOSZINSKI, S.; WEHRHAN, M.; SOMMER, M. Impact of multi-scale predictor selection for modeling soil properties. **Geoderma**, Amsterdam, v. 239, p. 97-106, 2015.

MINASNY, B.; MCBRATNEY, A.B.; TRANTER, G.; MURPHY, B.W. Using soil knowledge for the evaluation of mid-infrared diffuse reflectance spectroscopy for predicting soil physical and mechanical properties. **European Journal Of Soil Science**, Hoboken, v. 59, n. 5, p. 960-971, 2008

MINASNY, B.; MCBRATNEY, A. B. Digital soil mapping: A brief history and some lessons. **Geoderma**, Amsterdam, (prelo) 2015.

MÖLLER, M.; KOSCHITZKI, T.; HARTMANN, K.; JAHN, R. Plausibility test of conceptual soil maps using relief parameters. **Catena**, Amsterdam, v.88, p.57-67, 2012.

MORAN, C. J.; BUI, E. N. Spatial data mining for enhanced soil map modelling. **International Journal of Geographical Information Science**, Oxon, v. 16, n. 6, p. 533-549, 2002.

MUSICK, H.B.; PELLETIER, R. E. Response to soil moisture of spectral indexes derived from bidirectional reflectance in thematic mapper wavebands. **Remote Sensing Of Environment**, New York, v. 25, n. 2, p. 167-184, 1988.

- NANNI, M.R.; DEMATTÊ, J.A.M.; CHICATI, M.L.; FIORIO, P.R. CÉZAR, E.; OLIVEIRA, R.B.D. Soil surface spectral data from Landsat imagery for soil class discrimination. **Acta Scientiarum Agronomy**, Maringá v. 34, n. 1, p. 103-112, 2012.
- NANNI, M.R. DEMATTE, J.A.M.; DA SILVA JUNIOR, C.A.; ROMAGNOLI, F.; DA SILVA, A.A.; CEZAR, E.DE CARVALHO GASPAROTTO, A. Soil Mapping by Laboratory and Orbital Spectral Sensing Compared with a Traditional Method in a Detailed Level. **Journal of Agronomy**, New York, v. 13, n. 3, p. 100, 2014
- NANNI, M. R.; DEMATTÊ, J. A. M. Spectral reflectance methodology in comparison to traditional soil analysis. **Soil Science Society of America Journal**, Madison, v. 70, n. 2, p. 393-407, 2006a.
- NANNI, M.R.; DEMATTÊ, J.A.M. Soil line behavior obtained by laboratorial spectroradiometry for different soil classes. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 30, n. 6, p. 1031-1038, 2006b.
- ODEH, I.O.A.; MCBRATNEY, A.B.; CHITTLEBOROUGH. Further results on prediction of soil properties from terrain attributes, heterotopic cokriging and regression-kriging. **Geoderma**, Amsterdam, 67, 215-225, 1995
- ODEH, I.O.A.; MCBRATNEY, A.B.; SLATER, B.K. **Predicting soil properties from ancillary information, non-spatial models compared with geostatistical and combined methods**. In, *Geostatistics Wollongong*, 96, v. 2, EY Baafi, NA Schofield, Eds Kluwer Academic Publishers, Netherlands, 1997. p.1008-1019.
- PADARIAN, J.; MINASNY, B.; MCBRATNEY, A.B., DALGLIESH, N. Predicting and mapping the soil available water capacity of Australian wheatbelt. **Geoderma Regional**, Amsterdam, v. 2, p. 110-118, 2014.
- QUINLAN, J.R. Induction of decision trees. **Machine Learning**, Gz Dorcrecht, v.1, n.1, p.81-106, 1986.
- QUINLAN, J.R. Learning with continuous classes. AUSTRALIAN JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE, 5., 1992. Singapore. **Proceedings...** Singapore, 1992. v. 92, p. 343-348
- QUINLAN, J.R. Combining instance-based and model-based learning. In: UTGOFF, P. **Machine Learning- Proceedings of the Tenth International Conference, 1993**. San Mateo: MORGAN KAUFMANN,1993. cap. 13, p. 236-243.
- R Core Team (2015). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. URL, <https://www.R-project.org/>.
- BRASIL. Ministério das Minas e Energia. Secretaria Geral. **Projeto RADAM Brasil**. Folha SD-23 Brasília: mapa de capacidade de uso dos recursos naturais renováveis. Rio de Janeiro, 1982. 1 mapa, color., 91 cm x 71 cm. Escala 1:1.000.000. (Levantamento de Recursos Naturais, 29).

RADAM, Projeto. **Levantamento de recursos naturais**. Programa de Integração Nacional, Brasília, 1970-1985.

ROBERT J. H. (2015). **raster**: Geographic Data Analysis and Modeling. R package version 2.4-20. Disponível em: <http://CRAN.R-project.org/package=raster> Acesso em:

ROLIM, G.D.S.; CAMARGO, M.D.; LANIA, D G.; MORAES, J.D. Classificação climática de Köppen e de Thornthwaite e sua aplicabilidade na determinação de zonas agroclimáticas para o estado de São Paulo. **Bragantia**, Campinas, v. 66, n. 4, p. 711-720, 2007.

ROSSEL, R.V.; WALVOORT, D.J.J.; MCBRATNEY, A.B.; JANIK, L.J. SKJEMSTAD, J.O Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. **Geoderma**, Amsterdam, v. 131, n. 1, p. 59-75, 2006.

ROSSEL, RA Viscarra; MCGLYNN, R.N.; MCBRATNEY, A.B. Determining the composition of mineral-organic mixes using UV-vis-NIR diffuse reflectance spectroscopy. **Geoderma**, Amstredam, v. 137, n. 1, p. 70-82, 2006.

SELIGE, T.; BÖHNER, J.; SCHMIDHALTER, U. High resolution topsoil mapping using hyperspectral image and field data in multivariate regression modeling procedures. **Geoderma**, Amsterdam, v. 136, n. 1, p. 235-244, 2006.

SHEPARD, D.. A two-dimensional interpolation function for irregularly-spaced data.: In: ACM NATIONAL CONFERENCE. ACM, 23., 1968. Cincinnati: ACM, 1968 .p. 517-524.

SHEPHERD, K. D.; WALSH, M.G. Development of reflectance spectral libraries for characterization of soil properties. **Soil Science Society of America Journal**, Madison, v. 66, n. 3, p. 988-998, 2002.

SHERMAN, D. M.; WAITE, T. David. Electronic spectra of Fe³⁺ oxides and oxide hydroxides in the near IR to near UV. **American Mineralogist**, Chantilly, v. 70, n. 11-12, p. 1262-1269, 1985.

SOLOS, Embrapa. **Sistema brasileiro de classificação de solos**. Rio de Janeiro: Centro Nacional de Pesquisa de Solos, 2013. 353p.

SOUSA JUNIOR, J. G. de Abreu; DEMATTE, J. A. M. Modelo digital de elevação na caracterização de solos desenvolvidos de basalto e material arenítico. **Revista Brasileira de Ciência do Solo**, Viçosa , v. 32, n. 1, p. 449-456, Feb. 2008 .

STENBERG, B.; ROSSEL, R.A.V.; MOUAZEN, A.M.; WETTERLIND, J. Chapter five-visible and near infrared spectroscopy in soil science. **Advances in Agronomy**, Newark, v. 107, p. 163-215, 2010.

STEPIEN, M.; SAMBOSRKI, S. ;GOZDOWSKI, D.Ç DOBERS, E.S.Ç; CHORMANSKI, J. Assessment of soil texture class on agricultural fields using ECa, Amber NDVI, and topographic properties. **Journal Plant Nutrition and Soil Science**, Temuco, v. 178, p. 523-536, 2015.

STONER, E. R.; BAUMGARDNER, M.F. Characteristic variations in reflectance of surface soils. **Soil Science Society of America Journal**, Madison, v. 45, n. 6, p. 1161-1165, 1981.

SULLIVAN, D.G.; SHAW, J.N.; RICKMAN, D. IKONOS imagery to estimate surface soil property variability in two Alabama physiographies. **Soil Science Society of America Journal**, Madison, v. 69, n. 6, p. 1789-1798, 2005

TERRA, F.S.; DEMATTÊ, J.A.M.; ROSSEL, R.A. Viscarra. Spectral libraries for quantitative analyses of tropical Brazilian soils: Comparing vis-NIR and mid-IR reflectance data. **Geoderma**, Amsterdam, v. 255, p. 81-93, 2015.

VASQUES, G.M.; DEMATTÊ, J.A.M.; VISCARRA ROSSEL, R.A.; RAMÍREZ LÓPEZ, L.; TERRA, F.S.; RIZZO, R.; SOUZA FILHO, C.R. Integrating geospatial and multi-depth laboratory spectral data for mapping soil classes in a geologically complex area in southeastern Brazil. **European Journal of Soil Science**, Roboken, v. 66, p. 767-779, 2015.

VINK, A.D.A. **Fografias aereas y las ciencias del suelo**. Delf: International Training Centre for Aerial Survey, 1963. 200p.

VISCARRA ROSSEL, R.A. Fine-resolution multiscale mapping of clay minerals in Australian soils measured with near infrared spectra. **Journal of Geophysical Research: Earth Surface**, Washington, v. 116, F04023, 2011.

WAISER, T.H.; MORGAN, C.L., BROWN, D.J.; HALLMARK, C.T. In situ characterization of soil clay content with visible near-infrared diffuse reflectance spectroscopy. **Soil Science Society of America Journal**, Madison, v. 71, n. 2, p. 389-396, 2007.

YOËLI, P. Analytical hill shading. **Surveying and Mapping**, London, v. 25, n. 4, p. 573-579, 1965.

ZHANG, T.; LI, L.; ZHENG, B.. Estimation of agricultural soil properties with imaging and laboratory spectroscopy. **Journal of Applied Remote Sensing**, San Diego, v. 7, n. 1, p. 073587-073587, 2013.