

Sensoriamento remoto aplicado à predição de classes de solo em Floresta Tropical Seca: comparação entre tipos, fontes e épocas de aquisição

Ricardo de Oliveira Dart^{1,2}
Gustavo M. Vasques¹
Maurício Rizatto Coelho¹
Nelson Ferreira Fernandes²

¹ Empresa Brasileira de Pesquisa Agropecuária - Embrapa Solos
Rua Jardim Botânico, 1024 – Rio de Janeiro - RJ, Brasil
ricardo.dart@embrapa.br

² Programa de Pós-Graduação em Geografia Universidade Federal do Rio de Janeiro - UFRJ
Avenida Athos da Silveira, 274 – Ilha do Fundão- RJ, Brasil

Abstract. Digital Elevation Models (DEM) and satellite images are frequently used as environmental covariates for the prediction of soil classes in Digital Soil Mapping (DSM) procedures. In order to evaluate the input remote sensing image as covariates for soil class prediction, we applied a classification tree (CT) algorithm to predict soil classes at the great group level in a tropical dry forest area with 102 km² in Brazil. We built 17 CT models using as three sources of DEM (SRTM90m, SRTM30m and Ikonos), two sources of satellite images (Landsat 8 and RapidEye) from two seasons, and airborne gamma radiometrics images, with different spatial (10-m, 30-m and 90-m) resolutions, as predictors, and, 296 and 128 model training and validation observations, respectively. The results showed that freely available environmental covariates with coarser spatial resolution can produce as good or better great group predictions than more expensive covariates with finer resolution.

Palavras-chave: *digital soil mapping, classification tree, mapeamento digital de solos, árvore de classificação.*

1. Introdução

Atualmente existe grande disponibilidade de variáveis ambientais representando os fatores de formação do solo, incluindo mapas históricos e imagens de sensores orbitais e Modelos Digitais de Elevação (MDE), oferecendo boas oportunidades para desenvolver novas pesquisas em Mapeamento Digital de Solos (MDS). No entanto, como e quanto a qualidade dos dados de entrada afeta na acurácia dos mapas finais de solo precisa ser melhor compreendida. Pesquisas anteriores mostraram que dados com menor resolução espacial possibilitam obter mapas de solo de qualidade igual ou superior que os com maior detalhe (Samuel-Rosa et al., 2015, Cavazzi et al., 2013, Grinand et al., 2008), provavelmente, a uma fração do custo. Embora pareça contraditório, é possível que dados com resoluções espaciais mais detalhadas adicionem ruído ao em vez de informações úteis para melhorar as estimativas. No entanto, esse comportamento não se repete em todas as situações (por exemplo, Vasques et al., 2012; Cavazzi et al., 2013). Ao contrário, refere-se às características da paisagem, incluindo a variabilidade de solos e fatores ambientais, a densidade e o período das observações de solo, escala nominal ou resolução espacial, acurácia dos dados de entrada, históricos e de sensoriamento remoto.

Poucas pesquisas em MDS compararam fontes de dados de entrada para estimar atributos de solos (Samuel-Rosa et al., 2015; Kim et al., 2014; Behrens et al., 2014; Vasques et al., 2012). Inclusive, testando a influência no tamanho do grid de MDE e atributos do terreno (Behrens et al., 2014; Vasques et al., 2012), diferentes fontes de sensores orbitais (Kim et al., 2014) e diferentes fontes de variáveis ambientais (Samuel-Rosa et al., 2015).

No entanto, pouco tem sido feito para avaliar a influência das fontes de dados de entrada e sua qualidade associada para estimar classes de solos. Basicamente, dois tipos de abordagens têm sido testados, baseada em observações de perfis modais de solos (Brungard et al., 2015) e pela desagregação de polígonos de mapas de solos convencionais (Cavazzi et al., 2013). Com relação ao procedimento de desagregação de polígonos (Behrens et al., 2010 e Cavazzi et al.,

2013) testaram diferentes ajustes no grid do modelo digital de elevação (MDE) e avaliou qual mais ajuste mais adequado em três tipos de ambientes (Cavazzi et al., 2013).

Portanto, nosso objetivo foi: 1) avaliar três tipos de variáveis ambientais com diferentes resoluções espaciais (10, 30 e 90-m) e fontes, a fim de estimar classes de solos a nível de grande grupo de acordo com o Sistema Brasileiro de Classificação de Solos (SiBCS; Embrapa, 2006) em uma área plana com Floresta Tropical seca no Brasil, utilizando algoritmo de árvore de classificação (AC); 2) validar os resultados utilizando amostras independentes para validação; e 3) comparar os mapas resultantes dos modelos de AC com o mapa de solos convencional (Coelho et al., 2013).

2. Metodologia de Trabalho

2.1. Área de Estudo

O Parque Estadual da Mata Seca (PEMS), localizado no município de Manga no norte do estado de Minas Gerais, possui área de aproximadamente 102km² (Figura 1A). O clima é semiárido, com temperatura média anual de 24°C e precipitação média anual de 828mm, com estação seca de maio a setembro. A vegetação predominante é caducifólia, além de florestas perenifólias nos depósitos quaternários do Rio São Francisco (IEF, 2007). O relevo é predominante plano (64%) e suave ondulado (31%), e as altitudes variam de 440-500m.

As principais classes de solos que ocorrem no PEMS segundo o mapa de solos convencional Coelho et al., (2013) são, Gleissolo Háplico Ta Eutróficos (GXve), Neossolo Flúvico (RY) e Cambissolo Flúvico (CY) nos depósitos quaternários do Rio São Francisco, com floresta tropical pluvial perenifólia. Na parte oeste do parque sob a vegetação denominada de “Carrasco”, de pequeno porte que ocorre nos platôs secos, ocorrem Latossolos com textura média e baixa saturação de bases, Latossolo Amarelo distróficos (LAd) e Latossolo Vermelho-Amarelo Distróficos (LVAd), relacionados aos arenitos do grupo Urucuia. Entre os platôs do grupo Urucuia e os depósitos quaternários existe uma área de transição, associada a rochas pelítico-carbonáticas que compõem o Grupo Bambuí, segundo Coelho et al. (2013) influenciados pelas rochas calcárias, onde a presença de solos eutróficos associados à textura média em solos Latossolos Vermelho-Amarelos, Vermelhos, Chernossolos e Cambissolos (latossólicos), bem como a vegetação Caatinga Arbórea Densa são evidências. Na área de transição sob influência das rochas pelítico-carbonáticas e onde ocorrem Floresta Estacional Decidual Densa de porte alto (Mata Seca), são mais extensas e de maior complexidade. Nesta área predominam as classes de solos Latossolos Vermelho Eutróficos (LVe) e Cambissolos Háplicos Tb Eutróficos (CXbe), além da presença das classes Chernossolos Háplicos Carbonáticos e Órticos (MXk e MXo), Vertissolos Háplico (VX) e Gleissolos Háplicos e Melânicos (GX e GM; Figura 1B). O mapa de solos foi classificado de acordo com o SiBCS (Embrapa, 2006).

2.2. Amostras de Solos

Um conjunto de 424 observações foram inventariadas e classificadas no nível de grande grupo de acordo com SiBCS (Embrapa, 2006). O conjunto de observações de solos foi dividido em dois conjuntos de dados, treinamento com 70% (296 observações) e validação com 30% (128 observações; Figura 1A) para desenvolvimento da estimativa de classe de solos através do procedimento de árvore de classificação (AC). Para garantir proporção de classes de solos nos conjuntos, treinamento e validação, aplicou estratificação de classes de solos através do programa de estatística JMP® versão 12. Classes de solos com menos de três observações no conjunto de validação foram agrupadas com as de classes de solos similares, a classe GM com apenas duas observações foi agrupada com a classe mais próxima o MXo.

2.3. Variáveis Ambientais

Três tipos de variáveis ambientais foram avaliadas para estimar classes de solos. As variáveis testadas foram, imagens de satélite e índices de vegetação, denominadas *sat*, modelos digitais de elevação (MDE) e derivadas do terreno, denominados *topo*, imagens

gamaradiométricas como informações relativas material de origem, denominados *parent*. Essas variáveis ambientais foram preparadas em três conjuntos com diferentes resoluções espaciais, denominadas: alta (10m), média (30m) e baixa (90m). O conjunto de dados de alta resolução espacial foram obtidos através imagens de satélite RapidEye e Ikonos. Ao passo, que os dados de média resolução espacial obtidos através do MDE *shuttle radar topography mission* (SRTM 30 m; MDEs1) e imagens de satélite Landsat 8 (L8). Enquanto, no conjunto de baixa resolução espacial foram obtidos através de dados do MDE SRTM 90m (MDEs3) e dados de aerolevanteamento gamaradiométrico (125m). Todas as variáveis ambientais foram ajustadas para projeção UTM *datum* WGS84 e fuso 23 sul.

No conjunto de dados de alta resolução espacial (10-m), o MDE foi obtido através de um par *stereo* ortorretificado de imagens de satélite Ikonos 1-m (MDE-I), reamostrado para 10m e eliminando as depressões espúrias no SagaGIS®. Foram obtidas 25 derivadas do terreno partir do MDE-I no programa SagaGIS®: *Aspect, Catchment area, Channel Network Base Level, Convergence Index, Diffuse Insolation, Direct Insolation, LS-Factor, Mass Balance Index, MDE sem depressões espúrias, Multiresolution Ridgetop Flatness Index, Multiresolution Index of Valley Bottom Flatness, Mid Slope Position, Profile Curvature, Plan Curvature, Relative Slope Position, Slope Height, Slope Length, Slope, Total Insolation, Topographic Position Index, Terrain Ruggedness Index, Terrain Surface Texture, Topographic Wetness Index, Vertical Distance to Channel Network, Valley Depth*.

Duas imagens RapidEye (RE) foram selecionadas para os períodos seco (REDry, 05/08/2012) e úmido (REWet, 11/05/2013), através do site do Ministério do Meio Ambiente (MMA, <http://geocatalogo.mma.gov.br/>). Para auxiliar seleção de imagens representativas para os dois períodos, foi consultado o site (PROCLIMA, 2015) que proporciona informação do balanço hídrico para os estados do Nordeste. As imagens RE utilizadas, são ortorretificadas, possuem 5 bandas espectrais do visível ao infravermelho próximo (NIR) e resolução espacial de 5-m. Realizamos o procedimento correção atmosférica através do pacote FLAASH® no ENVI®, reamostramos de 5-m para 10-m no SagaGIS® e em seguida foram calculadas três razões de bandas, *Normalized Difference Vegetation Index* (NDVI), *Ratio Vegetation Index* (RVI) e *Soil Adjusted Vegetation Index* (SAVI).

O conjunto de dados de média resolução espacial (30-m) foi composto pelas mesmas variáveis de alta resolução (MDE-I e REWet e REDry), porém reamostrados de 10-m para 30m no SagaGIS®. Além destas, fez-se uso de variáveis obtidas através de imagens com média resolução, tais como, MDEs1 e duas imagens L8, obtidas através do site Serviço Geológico Americano (USGS; <http://earthexplorer.usgs.gov/>). A partir do MDEs1 foram obtidas 25 derivadas do terreno através do programa SagaGIS®. Duas imagens L8 foram selecionadas para os períodos seco (L8Dry, 02/07/2014) e úmido (L8Wet, 12/03/2014), a seleção do período das imagens realizada através de consulta ao PROCLIMA (2015). Nas imagens L8 utilizamos apenas as bandas 1 a 7, que abrangem os comprimentos de onda do visível ao infravermelho médio. Possuem resolução espacial de 30-m e são ortorretificadas. Realizamos correção atmosférica através do FLAASH® no ENVI, ajustamos o posicionamento das imagens L8 e calculamos três razões de bandas, NDVI, RVI, SAVI.

O conjunto de dados com baixa resolução espacial (90-m) foi composto pelas mesmas variáveis de alta (MDE-I e REWet e REDry) e média (MDEs1, L8Wet e L8Dry) resolução espaciais, porém reamostrados de 30-m para 90-m no SagaGIS®. Além destas, fez-se uso de imagens com baixa resolução espacial, tais como MDEs3, obtido através do site (CGIAR; <http://srtm.csi.cgiar.org/>) e 25 derivadas do terreno foram obtidas no SagaGIS®. As imagens gamma radiométrico e magnetométrico foram obtidos a partir de levantamento aéreo (Serviço Geológico do Brasil, 2009) com 125-m de resolução espacial, foram reamostradas de 125-m para 90-m no SagaGIS®. Estas imagens foram utilizadas como variáveis representando material de origem (*parent*) e resultaram em 10 planos de informação listados a seguir, 1°

Derivada Vertical do Campo Magnético Total 1DV, Taxa de Exposição da Contagem Total, Campo Magnético Total, Sinal Analítico do Campo Magnético Total, Concentração de Potássio, Concentração de Urânio, Concentração de Potássio, Razão Tório / Potássio, Razão Urânio / Tório e Razão Urânio / Tório.

2.4. Modelos e Validação

Modelos foram elaborados para estimar classes de solos no nível categórico de grande grupo (Embrapa, 2006). Seis modelos foram implementados utilizando as variáveis *topo*, três do MDE-I (10-m, 30-m e 90-m) de alta resolução, dois do MDEs1 (30-m e 90-m) de média e um do MDEs3 (90-m) de baixa. Dez modelos foram formulados utilizando as variáveis *sat*, seis com imagens RE nos períodos úmido (*Wet*) e seco (*Dry*) nas três resoluções (10-m, 30-m e 90-m) e quatro com imagens L8 nos dois períodos (*Wet* e *Dry*) e em duas resoluções (30-m e 90-m). Um modelo foi preparado utilizando a variável *parent* (90-m), totalizando, desta forma em dezessete modelos.

A relação entre classes de solos e variáveis ambientais foram implementadas através da utilização do algoritmo C5 (Quinlan, 1993) de AC. Para isso, foram utilizados o conjunto de dados de treinamento (296 observações) e um conjunto de dados independentes (128 observações) para validação. A poda (*pruning*) das AC foi mantida como *default* (25%) e número mínimo de casos foi ajustada para 2 casos.

Para avaliar a incerteza dos mapas gerados utilizamos a matriz de confusão, que segundo Congalton (1991), é eficiente para descrever erros de inclusão (comissão) e erros de exclusão (omissão). Com base na matriz de confusão, quatro índices foram calculados (Congalton, 1991) a fim de comparar os mapas, tais como, acurácia global (AG), acurácia do usuário, acurácia do produtor e índice kappa. O melhor modelo foi o com menor taxa de erro nos conjuntos de dados de treinamento e validação. O mapa de solos convencional (Coelho et al., 2013) foi generalizado a nível de grande grupo (Embrapa, 2006), a fim de uma comparar com os mapas gerados através dos 17 modelos em um Sistema de Informação Geográfica (SIG).

3. Resultados e Discussão

3.1. Avaliação dos Modelos e Validação

Em geral, os melhores modelos foram os que utilizaram variáveis topográficas (*topo*, Tabela 1). Todos os modelos *topo* e com material de origem (*parent*) conseguiram estimar todas as 13 classes de solos. No entanto, apenas três modelos *sat* conseguiram estimar todas as classes de solos, sendo dois com imagens no período seco (*Dry*) e um de imagens do período úmido (*Wet*; Tabela 1). De acordo com os erros na etapa de treinamento, os maiores índices de acurácia global e kappa ocorreram nos modelos *topo* e *parent* e os piores resultados nos modelos *sat*.

Em geral, os melhores resultados de AG do conjunto de dados de validação, ocorreram nos modelos com 90-m resolução espacial (Tabela 1), nos modelos *topo* variou de 53,1% para 44,5%. Os piores resultados de AG ocorreram nos modelos *sat* com imagens no período úmido (*wet*) e no modelo *topo* com MDE-I de alta resolução espacial (Tabela 1).

De acordo com a validação para o conjunto de dados independentes, o melhor kappa alcançado, (0,40), ocorreu no modelo *topo* com baixa resolução espacial (M90m_D_s3). Nossos melhores resultados foram semelhantes aos de pesquisas que utilizaram procedimento de AC com conjunto de amostras independentes (Kim et al., 2012; Grinand. et al., 2008) e no algoritmo C5 (Minansny e McBratney, 2007 e Mendonça-Santos et al., 2008). No entanto, Taghizadeh-Mehrjardi et al. (2015) obteve resultados superiores (0,71 de AG de e 0,69 de índice kappa) utilizou o algoritmo C5 para estimar classe de solo a nível de família (*soil taxonomy*) em ambiente semiárido. A diferença pode ter ocorrido, porque Taghizadeh-Mehrjardi et al. (2015) estimou 5 classes de solos enquanto o presente trabalho objetiva predizer 13 classes, onde provavelmente existem maiores confusões entre estas. Além disso,

os métodos MDS para a estimar classe, são limitados pelo número de classes de solo que podem ser gerenciadas (Brus et al., 2008).

Tabela 1. Resultados, classes previstas, acurácia global (AG) e índice kappa dos modelos ordenados pelo melhor resultado do índice kappa no conjunto de dados de validação.

Modelos	Classes previstas	Treinamento		Validação	
		A.G.	kappa	A.G.	kappa
M90m_D_s3	13 Classes	89.5	0.87	53.1	0.4
M90m_D_s1	13 Classes	88.9	0.86	49.2	0.34
M30m_D_s1	13 Classes	89.2	0.86	46.1	0.3
M90m_D_I	13 Classes	91.6	0.89	44.5	0.29
M90m_D_G	13 Classes	88.5	0.86	43.8	0.28
M90m_D_L8dry	12 (- RY)	78.4	0.72	45.3	0.27
M90m_D_REdry	12 (- RY)	77	0.7	43.8	0.23
M10m_D_REdry	13 Classes	77.4	0.7	40.6	0.22
M30m_D_L8dry	13 Classes	80.4	0.75	39.1	0.22
M30m_D_REdry	11 (- LVd e RY)	75.7	0.68	41.4	0.21
M30m_D_I	13 Classes	89.5	0.87	37.5	0.2
M30m_D_L8wet	12 (- RY)	76.7	0.7	39.8	0.19
M90m_D_L8wet	13 Classes	81.4	0.76	35.9	0.17
M10m_D_I	13 Classes	88.5	0.85	35.2	0.14
M10m_D_REwet	12 (- RY)	77.4	0.71	31.3	0.11
M90m_D_REwet	12 (- RY)	75.9	0.68	31.3	0.09
M30m_D_REwet	12 (- RY)	76	0.69	28.1	0.07

3.2. Variáveis Ambientais, Resolução Espacial

A melhor resolução espacial para estimar classes de solos com variáveis *topo* foi 90-m (Tabela 1). Esta pode ser observada nos modelos com alta resolução espacial (10-m) MDE-I e com média (30-m) MDEs1, em ambas as fontes, o melhor resultado foi obtido quando reamostrados para 90-m. O que nos faz pensar que a variação solo-paisagem no PEMS ocorre próximo de 90-m.

No entanto, não foi possível perceber um padrão claro sobre qual melhor resolução espacial para os modelos com variáveis *sat*. Não obstante, os modelos *sat* com resolução espacial de 90-m apresentou resultado ligeiramente melhor, porém não conseguiu estimar todas as 13 classes de solos (Tabela 1). Contudo, os modelos *sat* que utilizaram imagens no período seco (*dry*) apresentaram melhores resultados para estimar classes de solos em floresta tropical seca que imagens de período úmido (*wet*, Tabela 1).

Os resultados dos modelos *topo* são consistentes com os resultados de pesquisas anteriores (Cavazzi et al., 2013; Grinand et al., 2008). Cavazzi et al. (2013) analisou três áreas com relevos diferentes e observou que na área com relevo homogêneo as melhores estimativas de classes de solos ocorreram nas resoluções espaciais mais baixas (acima de 140 m), e o desempenho de validação foi comparável com os nossos melhores resultados, 53,1% a 45,3% de AG. Além disso, Grinand et al. (2008) observaram que a aplicação de filtro de média sobre a variável explicativa influencia na acurácia predição, aumentando as medidas de AG e índice kappa.

Considerando que nossos melhores resultados nos modelos *sat* ocorreram com imagens no período seco (*dry*) e com baixa resolução espacial, nossos resultados tendem a concordar com outras pesquisas, tais como, Kalacska et al. (2007), Brungard et al. (2015) e Kim et al. (2012). Kalacska et al. (2007) analisou imagens hiperespectrais de três períodos, a fim de acessar a descrição espacial da estrutura e diversidade da floresta tropical seca (FTS) e concluiu que as imagens da estação seca são melhores para estimar os parâmetros biofísicos do dossel e da biodiversidade florística. Brungard et al. (2015) estimou classes de solos em três áreas semiáridas e em duas destas razões de bandas espectrais Landsat no período seco

(*dormant season*) foram selecionadas como parte do melhor conjunto de variáveis ambientais preditoras.

No que diz respeito a resolução espacial em diferentes imagens de satélite, Kim et al. (2012) mapeou classes de solos a nível série e avaliou três sensores orbitais (SPOT, Landsat 7 e MODIS), observou que em modelos sem o uso de profundidade do solo, os melhores resultados foram das imagens com alta resolução espacial. Embora, quando a profundidade do solo foi utilizada nos modelos os melhores resultados foram aqueles com imagens de satélite com baixa resolução espacial, semelhante aos nossos resultados.

3.3. Modelos de Predição e Distinção Solo-Paisagem

Os modelos *topo* e *parent* representaram todas as 13 classes de solo em um padrão semelhante a ocorrência na paisagem, geralmente mais homogêneo como observado em mapas de solos convencionais. No entanto, os mapas gerados a partir dos modelos *sat* apresentou um padrão “*salt and pepper*”, comumente observado em classificação de uso e cobertura da terra baseada em procedimentos por *pixel*.

Tendo como referência o mapa de solos convencional (Coelho et al., 2013) para a área de estudo e as campanhas de campo realizadas, podemos observar que os modelos *sat* com imagens no período seco (*dry*), RE (Figura1C,D,G,H,L,M) e L8 (Figura1P,Q,S,T), em geral conseguiu distinguir os solos que ocorrem em depósitos quaternários (CY, GXve e RY), o que não foi possível nos modelos com imagens no período úmido (*wet*). Outro ponto relevante nos modelos com imagens no período seco foi a melhor distinção dos solos dominantes no Domínio Bambuí, os CXbe e LVe. No entanto, as modelos *sat* com imagens L8 (Figura1Q,T) no período úmido (*wet*) foram melhores para distinguir os solos que ocorrem nos domínios do Grupo Urucua, parte oeste do PEMS, onde os Latossolos (LVAd, LVd e LAd) com textura média e baixa saturação de bases foram representados.

Os modelos *topo*, com menor resolução espacial (30-m e 90-m) apresentaram melhores resultados (Tabela 1). Os modelos oriundos do MDE-I, de alta e média resolução espacial, foram melhores para separar os solos que ocorrem nos depósitos quaternários (Figura1E,I).

Os modelos que utilizaram o MDEs1 e MDEs3 caracterizaram bem os Latossolos (LVAd, LVd e LAd) na parte oeste do PEMS (Figura1J,O,R). Na área do Domínio Bambuí os solos dominantes, CXbe e LVe, foram em geral, melhor discriminados nos modelos MDEs1 e MDEs3 e no M30m_D_I (Figura1I,J,O,R). Na região sob influência das rochas pelítico-carbonáticas, onde ocorrem Floresta Estacional Decidual Densa de porte alto (Mata Seca), na porção sul do PEMS. Segundo Coelho et al. (2013), esta é uma área de grande complexidade para distinguir os limites das classes de solos e de maneira geral, três modelos (M30m_D_s1, M90m_D_s1 e M90m_D_s3) conseguiram identificar as principais classes CXbe, MXk e VX que ocorrem neste local (Figura1J,O,R).

O modelo *parent* (M90m_D_G) resultou no mapa de solos mais homogêneo (Figura1F), provavelmente devido a origem dos dados de gamaradiometria apresentarem a menor resolução espacial (125-m). Foi o melhor modelo para delimitar os Latossolos na parte oeste do PEMS (Figura1F). Quanto a área dos depósitos quaternários, as três classes de solos mais frequentes foram identificadas, porém, foi observado a presença da classe LVe neste ambiente onde não foi observado em campo e nem é esperado que ocorra este tipo de solo (Figura1F).

4. Conclusões

O procedimento de árvore de classificação (AC) apresentou resultados satisfatórios para classificar solos em ambiente de FTS. Dos três tipos de variáveis ambientais testadas para estimar solos, os modelos com variáveis topográficas (*topo*) apresentaram melhor desempenho e conseguiram estimar todas as 13 classes de solos.

Dentre os modelos com variáveis *topo* os com menor resolução espacial (90-m) obtiveram melhor desempenho que os mais detalhados (10-m), inclusive quando reamostrados para 90-m (MDEs1 e MDE-I), o que nos leva a pensar que as relações solo-

topografia no PEMS ocorrem próximo da resolução espacial de 90-m. Além destas, é notável observar que os MDE's obtidos sem custo obtiveram melhores resultados para estimar classes de solos. Quanto aos modelos *sat*, os que utilizaram imagens do período seco tiveram resultados mais acurados que os com imagens no período úmido para estimar classes de solos em FTS.

Agradecimentos

Apoio financeiro do projeto da Embrapa nº 03.10.06.013.00.00, do projeto da IAI CRNII_014, pelo apoio de campo pelo José Luiz do PEMS (IEF-MG) e pelo fornecimento da imagem gama radiométrica pelo Serviço Geológico do Brasil através do pesquisador Edgard Shinzato.

Referências Bibliográficas

- Behrens, T.; Schmidt, K.; Ramirez-Lopez, L.; Gallant, J.; Zhu, A. X.; Scholten, T. Hyper-scale digital soil mapping and soil formation analysis. **Geoderma**, v. 213, n. 0, p. 578-588, 2014.
- Behrens, T.; Zhu, A.-X.; Schmidt, K.; Scholten, T. Multi-scale digital terrain analysis and feature selection for digital soil mapping. **Geoderma**, v. 155, p. 175–185, 2010.
- Brungard, C. W.; Boettinger, J. L.; Duniway, M. C.; Wills, S. A.; Edwards Jr, T. C. Machine learning for predicting soil classes in three semi-arid landscapes. **Geoderma**, v. 239–240, n. 0, p. 68-83, 2015.
- Brus, D. J.; Bogaert, P.; Heuvelink, G. B. M. Bayesian Maximum Entropy prediction of soil categories using a traditional soil map as soft information. **European Journal of Soil Science**, v. 59, n. 2, p. 166-177, 2008.
- Cavazzi, S.; Corstanje, R.; Mayr, T.; Hannam, J.; Fealy, R. Are fine resolution digital elevation models always the best choice in digital soil mapping? **Geoderma**, v. 195–196, n. 0, p. 111-121, 2013.
- Coelho, M. R.; Dart, R. O.; Vasques, G. M.; Teixeira, W. G.; Oliveira, R. P. Mendonça-Santos, M. L.; Berbara, R. L. L. Levantamento Pedológico Semi-detalhado (1:30.000) do Parque Estadual da Mata Seca, Município de Manga - MG. **Boletim de Pesquisa e Desenvolvimento**, v. 217, p. 264, 2013.
- Congalton, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v. 37, n. 1, p. 35-46, 1991.
- Programa de Monitoramento Climático em Tempo Real da Região Nordeste (PROCLIMA). Disponível em: <<http://proclima.cptec.inpe.br/>>. Acesso em: 15.jan.2015.
- Embrapa. **Sistema Brasileiro de Classificação de Solos**. Embrapa, 2006. 306p.
- Grinand, C.; Arrouays, D.; Laroche, B.; Martin, M. P. Extrapolating regional soil landscapes from an existing soil map: Sampling intensity, validation procedures, and integration of spatial context. **Geoderma**, v. 143, n. 1–2, p. 180-190, 2008.
- Instituto Estadual de Florestas (IEF). Disponível em: http://www.ief.mg.gov.br/index.php?option=com_content&task=view&id=204&Itemid=37. Acesso em: 23.mai.2007.
- Kalacska, M.; Sanchez-Azofeifa, G. A.; Rivard, B.; Caelli, T.; White, H. P.; Calvo-Alvarado, J. C. Ecological fingerprinting of ecosystem succession: Estimating secondary tropical dry forest structure and diversity using imaging spectroscopy. **Remote Sensing of Environment**, v. 108, n. 1, p. 82-96, 2007.
- Kim, J., Grunwald, S.; Rivero, R. G. Soil phosphorus and nitrogen predictions across spatial escalating scales in an aquatic ecosystem using remote sensing images. **IEEE Trans. on Geoscience and Remote Sensing J.**, 52, n. 10, p. 6724-6737, 2014.
- Kim, J.; Grunwald, S.; Rivero, R. G.; Robbins, R. Multi-scale modeling of soil series using remote sensing in a wetland ecosystem. **Soil Sci. Soc. Am. J.**, v.76, n. 10, p. 2327-2341, 2012.
- Mendonça-Santos, M. L.; Santos, H. G.; Dart, R. O.; Pares, J. G. Digital Mapping of Soil Classes in Rio de Janeiro State, Brazil: Data, Modelling and Prediction. In: Hatermink, A. E.; McBratney, A. B.; Mendonça-Santos, M. L. (Org.) **Digital Soil Mapping with Limited Data**. Springer, 2008. cap.34, p. 381-396.
- Minasny, B.; McBratney, A. B. Incorporating taxonomic distance into spatial prediction and digital mapping of soil classes. **Geoderma**, v.142, n. 3–4, p. 285-293, 2007.
- Quinlan, J. R. **See5: An Informal Tutorial**. 1993. Disponível em: <<https://www.rulequest.com/see5-win.html>>. Acesso em: 14.mai.2015.
- Samuel-Rosa, A.; Heuvelink, G. B. M.; Vasques, G. M.; Anjos, L. H. C. Do more detailed environmental covariates deliver more accurate soil maps? **Geoderma**, v. 243-244, p. 214-227, 2015.
- Taghizadeh-Mehrjardi, R.; Nabiollahi, K.; Minasny, B.; Triantafyllis, J. Comparing data mining classifiers to predict spatial distribution of USDA-family soil groups in Baneh region, Iran. **Geoderma**, v. 253–254, n. 0, p. 67-77, 2015.
- Vasques, G. M.; Grunwald, S.; Myers, D. B. Influence of the spatial extent and resolution of input data on soil carbon models in Florida, USA. **Journal of Geophysical Research: Biogeosciences**, v. 117, n. G4, p. 1-12, 2012.

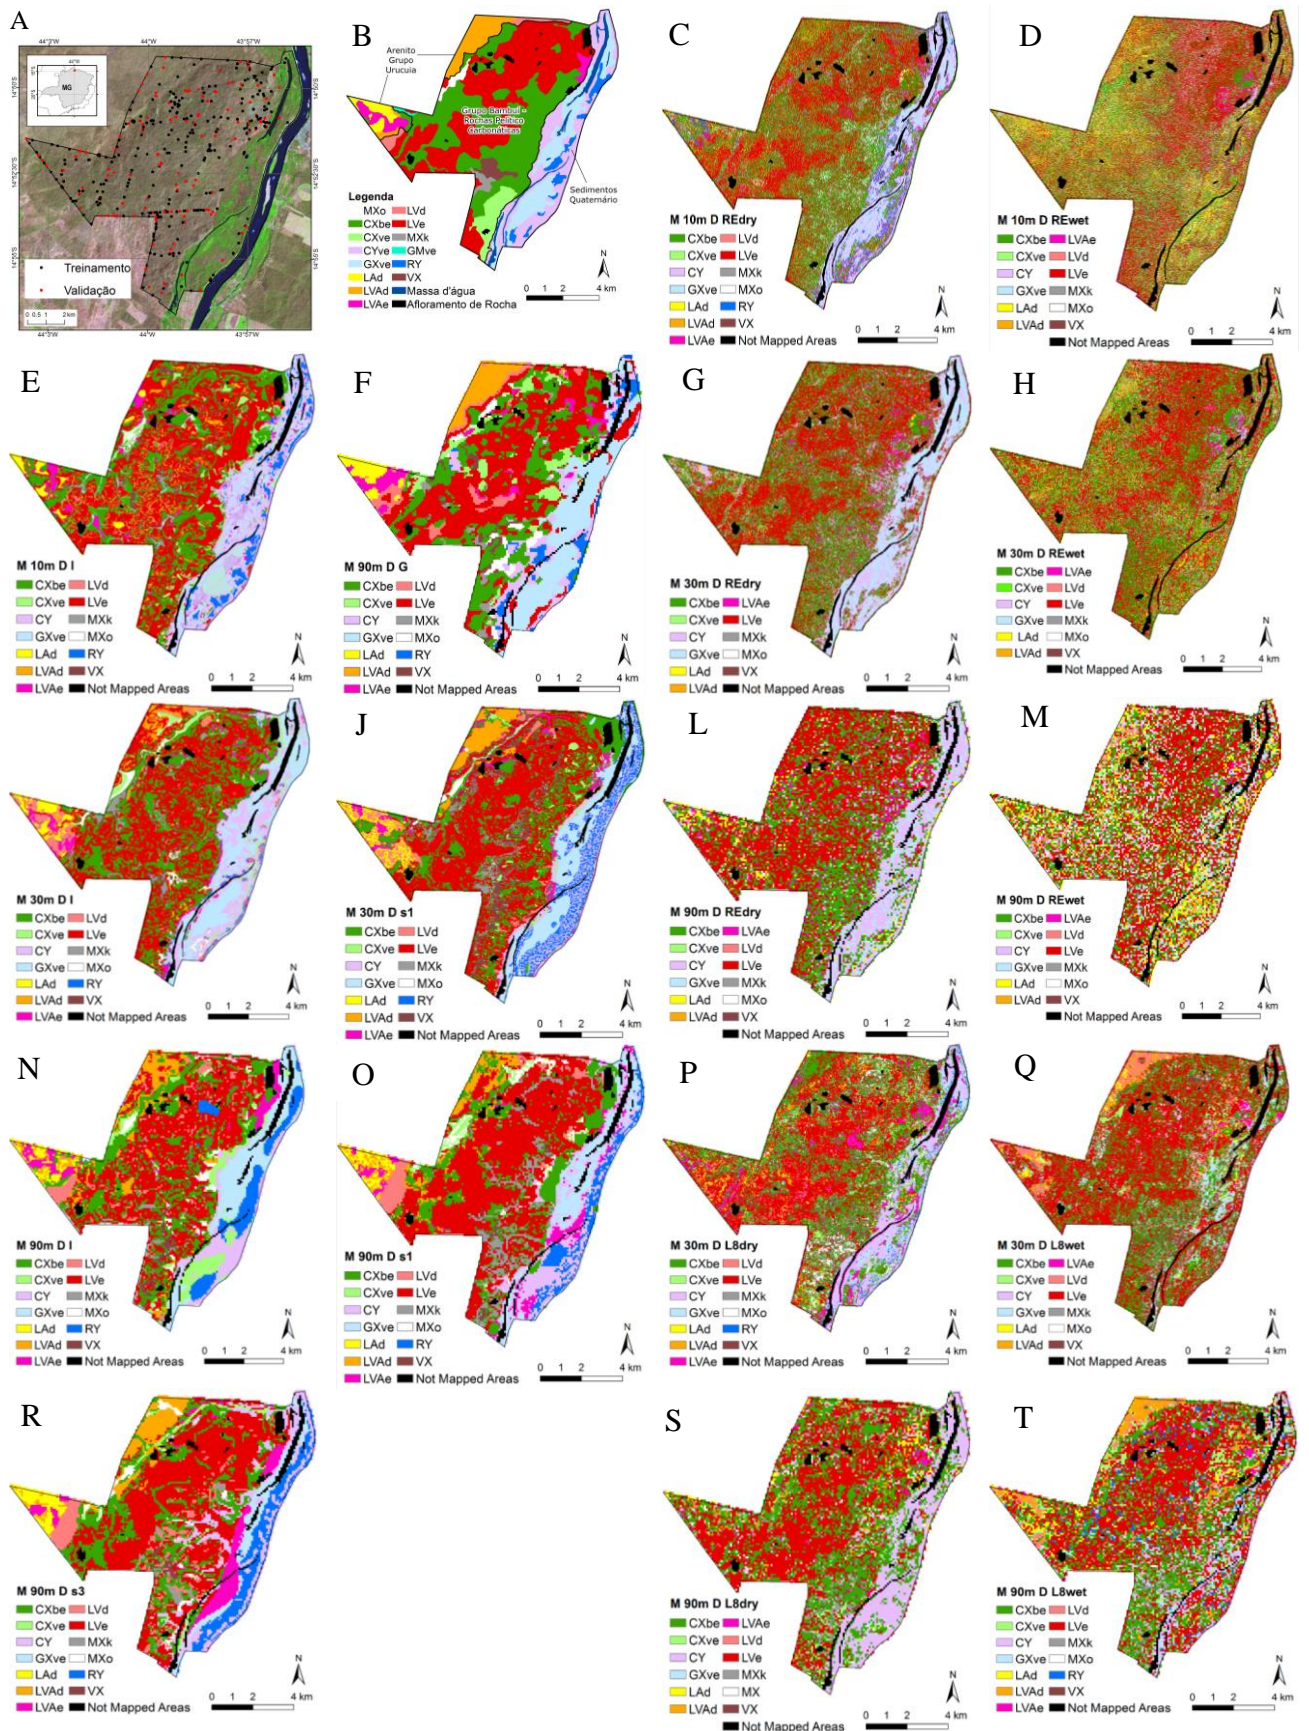


Figura 1. Mapas A) localização PEMS; B) Mapa convencional de solos (Coelho et al., 2013); C)M10mD_REdry; D)M10mD_REwet; E)M10mD_I; F)M90mD_G; G)M30mD_REdry; H)M30mD_REwet; I)M30mD_I; J)M30mD_s1; L)M90mD_REdry; M)M90mD_REwet; N)M90mD_I; O)M90mD_s1; P)M90mD_L8dry; Q)M30mD_L8wet; R)M90mD_s3; S)M90mD_L8dry; T)M90mD_L8wet.