

Desenvolvendo uma metodologia pedométrica integrada para predição digital de mapas de detalhados de solo

Leonardo Ramirez-López
lrlopez@esalq.usp.br

José Alexandre M. Demattê
jamdtmat@esalq.usp.br

Departamento de Ciência do Solo, Universidade de São Paulo,
Escola Superior de Agricultura "Luiz de Queiroz" USP/ESALQ
Av. Pádua Dias, 11 CP 9 CEP 13418-900 Piracicaba - SP

Abstract The aim of this study was to predict detailed digital soil maps units by pedometric methods using remote sensing information. The study area is located in the southeast region of São Paulo State, and comprised an area of 473 ha. The area was covered by a regular grid sampling sites with spacing of 100 x 100 m. In each point was collected soil samples at two depths, and performed a 946 soil samples data bank. Only 206 samples extracted from transect sections were submitted to soil analysis. The following parameters were obtained: clay, Al_2O_3 , Fe_2O_3 , SiO_2 TiO_2 , and weathering indexes. First of all it was developed two maps following the field traditional survey used in Brazil as ground truth information in tow detailed levels. For the elaboration of the digital soil maps we used a landsat image, hyperspectral data form laboratory lectures of all soil samples and a digital elevation model. This digital mapping strategy estipulate a new methodology for digital mapping of soil classes. The data was divided into three groups: *i*) Predicted soil attributes of the layer B (related to the soil weathering) from hiperespectral information using a local soil spectral library; *ii*) Terrain parameters; *iii*) Spectral reflectance data extracted from the landsat image. This information was reduced by principal component analysis and used for a maximum likelihood classification using trainee information extracted from five toposequences and ground truth maps. The results shown that using the developed methodology, we can predict relatively accurate detailed digital soil maps.

Palavras chave: Mapeamento digital de solos, toposequência, classificação supervisionada, sensoriamento remoto. Digital soil mapping, toposequence, supervised classification, remote sensing

1. Introdução

Recentemente uma crise mundial de alimentos tem surgido, e necessidade de incrementar a produção agrícola é muito importante sobre tudo para países em desenvolvimento. A comunidade internacional vem formulado varias propostas para a adoção de políticas agrícolas e ambientais para reduzir o impacto deste problema. Levando em conta que a base do qualquer sistema agrícola sustentável é o planejamento do uso da terra, o primeiro passo importante é a determinação de um mapa de solos que possa indicar onde ocorrem diferentes características do solo que possam interferir na produção das culturas. Os mapas detalhado de solos no Brasil são muito poucos e a demanda de informação referente a levantamentos de solo é alta em muitas regiões do Brasil (Mendonça-Santos and dos Santos, 2007). Recentes conferencias internacionais mostram a importância dos mapas de solos como apoio na diminuição da fome no mundo. Incluso autores como. Hoje, poucos são os trabalhos sendo desenvolvidos. Aqueles que ocorrem são esporádicos e em regiões restritas, quando não em caráter de empresas particulares, diminuindo consideravelmente o poder que apresentam no desenvolvimento de um país (Mendonça-Santos e dos Santos, 2007). Atualmente com ferramentas de sensoriamento remoto se tem um grande potencial para ser implementado um mapeamento digital de solos sobre grandes áreas de forma rápida e econômica, desta forma o mapeamento digital de solos pode contribuir de forma significativa no planejamento agrícola do Brasil. A falta de métodos de mapeamento de solos tem bastantes implicações importantes, como as dificuldades atuais para estabelecer limites de solos, muito trabalho de campo, muito tempo empregado e sobre

tudo altos custos. Baseados nestas observações, o objetivo deste trabalho foi desenvolver uma metodologia de baixo custo com a que possam ser preditas e mapeadas as diferentes classes de solos dentro de uma área específica usando diferentes fontes de sensoramento remoto e diferentes técnicas de geoprocessamento, levando em conta também que o atual desafio em mapeamento digital de solos é gerar precisamente mapas digitais detalhados com alta acurácia

2. Materiais e Métodos

2.1 Caracterização da área de estudo e amostragem de solos

A área de encontra-se localizada no estado de São Paulo e ocupa 473 ha. Os solos da area são principalmente derivados de rochas basálticas intercaladas com arenito. A área foi coberta por uma grade de amostragem com espaçamento de 100 x 100 m. Em cada ponto foi coletada uma amostra na camada de 0 - 0.20 m (camada A) e outra na camada de 0.8 - 1.0 m de profundidade (camada B). Em total foram obtidas 946 amostras de solo. Unicamente 206 amostras extraídas de toposequências demarcadas em campo (Figura 2b) foram submetidas a análise de solo. As amostras de solo foram analisadas por métodos e os seguintes parâmetros do solo foram obtidos: soma de bases (BS), argila, silte, areia, Al_2O_3 , Fe_2O_3 , sílica SiO_2 , TiO_2 e índices de intemperismo ($K_i = SiO_2/Al_2O_3$; $K_r = SiO_2/Fe_2O_3 + Al_2O_3$).

2.2 Mapeamento tradicional de solos - obtenção dos mapas reais de solos

Foram elaborados dois mapas seguindo os métodos tradicionais de levantamento de solos usados no Brasil. Estes mapas foram designados como mapa detalhado de solos nível de alta intensidade (CSM1a, Figura 1a), mapa detalhado de solos de nível de baixa intensidade (CSM1b, Figura 1b), ambos os dois mapas na escala de 1:25000. Estes mapas foram assumidos como a informação das verdadeiras unidades de mapeamento de solos.

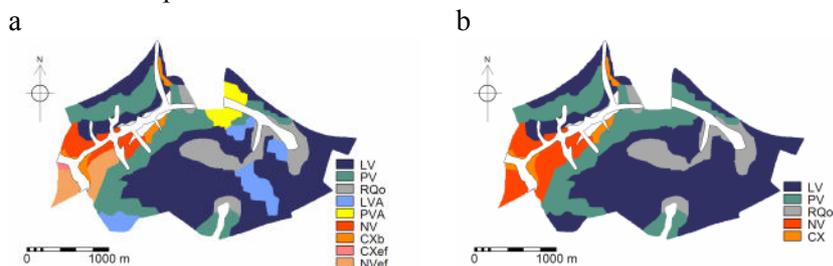


Figura 1. Mapas reais de solos. a. Detalhado de alta intensidade. b. Detalhado de baixa intensidade

2.3 Estratégia de mapeamento digital

2.3.1 Base de dados usada

Para a elaboração dos mapas digitais de solos foram usadas informações espectrais e de atributos do terreno. Foi usada uma imagem da área de estudo obtida do sensor TM do landsat sobre a qual realizarm-se processos de georeferenciamento além disso foi feita a correção atmosférica. Finalmente as informações de reflectancia espectral foram extraídas. Além das informações espectrais obtidas da imagem de satélite, as quais fornecem uma resolução espectral muito limitada foram obtidas leituras hiperespectrais para cada uma das amostras de solo através de um sensor de laboratório. Para a obtenção das leituras espectrais de todas as amostras de solo foi usado o sensor IRIS que cobre a região entre 350 - 2500 nm. A informação altimétrica da área foi obtida na forma de mapa de segmentos. O intervalo das isolinhas de contorno deste mapa foi de cada 5 metros sobre o nível do mar. O modelo digital de terreno (MDT) foi obtido por a interpolação dos contornos com um tamanho de pixel de 5 m.

2.3.2 Etapas da predição digital das classes de solo

A estratégia de mapeamento propõe um nova metodologia para o mapeamento digital das classes de solo. Os dados são inicialmente analisados em três grupos separados dos que são extraídos os componentes mais importantes da informação. Estes grupos são: a) Atributos

do solo na camada B relacionados com o intemperismo preditos a partir de dados hiperespectrais usando uma biblioteca espectral (informação sub-superficial); b) Parâmetros do terreno (curvatura meia, inclinação e altitude) extraídos do MDT (informação da paisagem); c) dados da reflectancia espectral extraídos da imagem landsat (informação superficial). Desta forma a estratégia é descrita a seguir:

Passo a. Desenvolvimento de uma biblioteca espectral local baseada na informação hiperespectral de laboratório usando metodologias de quimiometria analítica para a predição de atributos do solo. Foi feita uma análise de componentes principais (PCA) de todos os dados espectrais obtidos no laboratório. Foram identificados *ouliers* usando a distancia de malahanobis. O mesmo procedimento foi realizado com os dados das análises de solos. Depois da identificação e eliminação dos *ouliers* a PCA dos dados espectrais foi novamente executada usando unicamente as 206 amostras extraídas das toposequências (Figura 2b). Para a calibração de modelos de quantificação, assim como para a validação destes modelos, as amostras foram separadas em dois grupos usando uma amostragem estratificada através do método de amostragem por hipercubo latino condicionado (cLHS) (Minasny and McBratney, 2006) usando as duas primeiras componentes principais. Desta forma o grupo de calibração foi formado por 156 amostras e o grupo de validação dos modelos foi formado por 50 amostras (Figure 2b). As curvas espectrais foram analisados com o objetivo de identificar o tipo de preprocessamento requerido para estes dados. Posteriormente foram construídos modelos de quantificação de argila, soma de bases, SiO_2 , Al_2O_3 , TiO_2 e Fe_2O_3 a traves do método de regressão por mínimos quadrados parciais (PLS). Estes modelos foram selecionados com base na raiz quadrada do erro meio quadrático (RMSE), erro meio (ME), coeficiente de determinação (R^2), o desvio padrão do erro (SDE) Foi feita uma validação cruzada (sempre com as 50 amostras de validação) para testar o desempenho do modelo. Estes modelos foram inseridos na biblioteca espectral a qual foi usada para a predição de atributos em todas as amostras da camada B (incluindo as amostras de calibração). Desta forma a quantificação de atributos do solo da camada B (horizonte diagnostico mais importante) foi feita usando unicamente informação espectral.

Passo b. Todos os atributos do solo foram analisados através de métodos geostatísticos usando o pacote GeoR do software estatístico R. Foi usado a função de do semi-variograma para a construção dos semi-variogramas experimentais e identificação das estruturas espaciais. Estes semi-variogramas foram ajustados a modelos de autocorrelação espacial e as suas características principais foram usadas para a construção de mapas de variabilidade espacial de cada atributo a través do método de interpolação de krigagem ordinária. Desta forma foram obtido mapas raster para SB, SiO_2 , Al_2O_3 , TiO_2 e Fe_2O_3 , mapas de Ki e Kr foram determinados a partir das informações dos anteriores mapas. Finalmente para resumir e diminuir a informação redundante produto da correlação entre atributos contida na no conjunto de mapas gerados, o numero de mapas raster foi reduzido a través do método de PCA. De esta forma foram gerados novos mapas de componentes principais do solo (SPCs)

Passo c. A partir do DEM foram extraídas as informações de inclinação e curvatura meia usando o software ILWIS 3.5 open. A informação foi resumida usando o método PCA com o objetivo de gerar um mapas raster de componetes principais do terreno (TPCs) com a informação mais importante e diminuir a redundância.

Passo d. Levando em conta que o tamanho do pixel dos mapas de atributos do solo e de parâmetros de terreno foi de 5 m, o tamanho do pixel das imagens de satélite foi reduzido para 5 m com a finalidade de que os três grupos d e informação (mapas raster de atributos do solo, mapas raster dos parametros do terreno e as bandas das imagens de satelite), tivessem o mesmo tamanho de pixel e desta forma não perder detalhamento nos mapas de terreno e de atributos do solo.

Para as bandas 1, 2, 3, 4, 5 e 7 da imagem TM uma PCA foi realizada, gerando assim uma menor quantidade de novas bandas com a capacidade de representar de forma eficiente o conjunto original de 6 bandas. Em este caso só a nova primera banda (TMPC1) gerada com a PCA foi levada em conta já

que ela representa em grande parte o albedo (Saldanha et al., 2004) o qual está relacionado com a textura do solo (Demattê, 2002). Comumente o primeiro PC (nesta caso TMPC1) explica mais do que 80% da variância total original do conjunto de imagens.

Passo e. Em este passo foram usados os conjuntos de mapas de componentes principais gerados nas etapas (SPCs, TPCs e TMPC1) para coletar informação de treinamento para uma classificação supervisionada do solo a través do método de máxima verossemelhança. Foram demarcadas 5 toposequências na área de estudo ao longo as quais foram coletadas 260 pixels ou amostras em cada mapa de componentes principais. Para cada um destes pixels foi extraída a informação de componentes principais dos atributos do solo, da imagem landsat e dos parâmetros do terreno. Para cada pixel foi atribuído o seu correspondente classe de solo do mapa detalhado de alta intensidade. Finalmente com o algoritmo de classificação treinado nas toposequências foi feita a predição das classes de solo na área inteira gerando assim o mapa ML1. O mesmo procedimento foi feito para a obtenção do mapa digital detalhado de baixa intensidade ML2.

2.3.2 Avaliação da qualidade dos mapas digitais gerados

Para a avaliação da qualidade dos mapas digitais detalhados de classes de solos foi realizada uma comparação entre estes e os mapas reais. Foi avaliada a correspondência espacial (Sc) que indica a percentagem coberta de cada área de classe de solo por cada classe predita a partir da seguinte equação,

$$Sc = \frac{\sum_{i=1}^k \hat{p}_i \cap p_i}{n} \cdot 100$$

onde \hat{p}_i são os pixels de cada classe no mapa predito que estão dentro da área ocupada por os pixels de cada classe de solo no mapa real (p_i). Também foi avaliado o grau de correspondência espacial (DSC),

$$DSC = 2 \frac{\sum_{i=1}^k \hat{p}_i \cap p_i}{n + m} \cdot 100$$

onde m é o numero total de pixels da classe de solo predita. A DSC é um indicador de correspondência espacial que leva em consideração o tamanho de ambos os dois, a área o numero de pixels da classe de solo predita e a área o numero de pixels da classe de solo real. Em outras palavras elimina a superestimação da correspondência espacial causada por classes preditas de solo com grandes áreas cobrindo por sua vez grandes áreas nas classes de solo real. Adicionalmente nesta estratégia foi calculada a acurácia global e o índice kappa (κ).

3. Resultados e Discussão

Esta estratégia integra vários produtos do sensoriamento remoto, incorporando importantes variáveis de sub-superfície que estão relacionadas como o intemperismo dos solos e a sua classificação. Neste caso grande parte da acurácia das predições está relacionada com a qualidade dos mapas de atributos químicos do solo, e por sua vez a qualidade deste mapas está relacionada com a qualidade das estimações (desempenho dos modelos da biblioteca espectral).

No *passo a*, através da análise dos PCs foram identificados 50 *outliers* do total de dados espectrais e químicos. Para os dados usados para as calibrações e validações de modelos, os três primeiros PCs (PC1, PC2 e PC3) explicaram o 94.7, 4.2 e 0.5% da variância total respectivamente. Os dados espectrais extraídos dos transectos foram representativos dos dados espectrais da area inteira (Figura 2). Para a calibração dos modelos foi necessária a transformação para absorbância ($\log 1/R$) e não foi necessário nenhum tipo de pré-processamento. Os modelos apresentaram um bom desempenho na predição dos atributos do solo avaliados (Tabela 1).

O uso de técnicas quimiométricas para a quantificação de atributos do solo com dados de sensoriamento remoto possibilita que um grande numero de amostras de solos possa ser analisado sem acarretar grandes custos. Neste caso a clara identificação da estrutura espacial

dos atributos químicos avaliados e o bom desempenho da krigagem (Tabela 2) pode estar relacionado com a alta densidade de amostragem. O alto grau de dependência espacial (indicado pela proporção $C/(C_0+C)$) mostra que esta característica é forte em todos os atributos preditos (Tabela 4). Por outra parte todos os semi-variogramas tem um padrão espacial semelhante o qual é controlado pela topografia, assim uma alta correlação dos atributos do solo com o relevo foi observada (Tabela 3) o que é consistente com várias pesquisas que indicam que em solos derivados de basalto, a variabilidade espacial dos atributos do solo em grande parte controlada pela topografia, especialmente em solos tropicais (Thanachit et al, 2006).

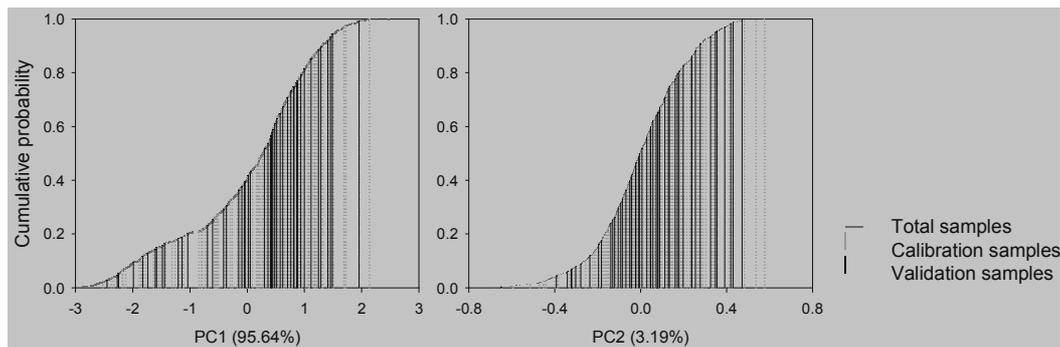


Figura 2. Posição na probabilidade acumulada dos PCs das amostras espectrais de solo extraídas dos transectos (amostras para a calibração e validação de modelos de estimativa de atributos).

Tabela 1. Resultados da calibração e validação de modelos de estimativa de atributos do solo da biblioteca espectral.

Attribute	PLS Factors	Cross validation of calibration set (n=155)				Validation set (n=50)			
		$R^2_{adjusted}$	RMSE	ME	SDE	$R^2_{adjusted}$	RMSE _p	ME _p	SDE _p
Fe ₂ O ₃ g kg ⁻¹	9	0.88	18.99	-1.11	1.12	0.85	23.02	3.28	0.65
Al ₂ O ₃ g kg ⁻¹		0.81	16.58	0.37	-0.38	0.77	19.05	5.28	-2.55
SiO ₂ g kg ⁻¹	4	0.77	15.07	0.87	0.12	0.71	18.72	-1.94	5.02
TiO ₂ g kg ⁻¹	9	0.91	4.14	-0.22	0.22	0.87	4.93	0.69	-0.32
Clay %	9	0.93	4.26	0.22	-0.22	0.90	5.07	0.53	-0.69
*BS mmol _c kg ⁻¹	6	0.76	8.24	-0.35	0.35	0.76	6.81	-0.63	-0.03

*BS: Base Sum

p_i: indicates a prediction

Tabela 2. Resultados da análise geostatística usada para o mapeamento de atributos do solo

Soil Attribute	Model	Semivariogram characteristics				Cross validation of kriging		
		Nugget (C ₀)	Sill (C ₀ +C)	Range (m)	$C/(C_0+C)$	$R^2_{adjusted}$	RMSE	ME
Fe ₂ O ₃ g kg ⁻¹	Spherical	241.11	998.88	868.01	0.76	0.87	20.01	-0.21
Al ₂ O ₃ g kg ⁻¹	Spherical	222.95	512.78	801.24	0.57	0.78	18.58	-0.40
SiO ₂ g kg ⁻¹	Spherical	102.60	205.21	895.11	0.50	0.84	10.73	0.67
TiO ₂ g kg ⁻¹	Spherical	8.31	73.91	832.78	0.89	0.87	5.08	-0.03
Clay %	Spherical	17.94	89.68	801.38	0.80	0.87	5.95	-0.01
*BS mmol _c kg ⁻¹	Spherical	7.98	90.43	898.01	0.91	0.88	5.29	0.10

*BS: Base Sum

O alto grau de correlação observado entre os mapas raster dos atributos do solo preditos (Tabela 4) indica que existe informação redundante que pode ser resumida. Assim então, o número destes mapas foi reduzido para um mapa raster (SPC1) que explica o 98% da variância total do conjunto total de mapas originais. Da mesma forma, as bandas da imagem TM foram

reduzidas para uma única banda (TMPC1) que representa o 91% da variância total entre as bandas originais. A PCA não foi aplicada aos dados do MDT por que eles apresentaram baixos graus de correlação entre eles (Tabela 3) e desta forma a informação não pode ser resumida. Então estes parâmetros foram usados diretamente no processo de classificação.

Tabela 3. matriz de correlação dos atributos do solo preditos e os parâmetros do MDT

	Al ₂ O ₃	Clay	Ki	Kr	Fe ₂ O ₃	SiO ₂	TiO ₂	*BS	**Alt.	***MC	Slope
Al ₂ O ₃	1	0.99	-0.59	-0.76	0.98	0.94	0.97	0.97	-0.84	-0.01	0.37
Clay		1	-0.5	-0.70	0.99	0.97	0.98	0.98	-0.86	-0.01	0.38
Ki			1	0.93	-0.53	-0.32	-0.48	-0.41	0.29	-0.01	-0.12
Kr				1	-0.74	-0.55	-0.71	-0.64	0.51	0.00	-0.23
Fe ₂ O ₃					1	0.94	0.99	0.97	-0.85	-0.01	0.38
SiO ₂						1	0.96	0.98	-0.90	-0.02	0.42
TiO ₂							1	0.98	-0.88	-0.02	0.41
BS								1	-0.89	-0.02	0.42
Altimetry									1	0.09	-0.55
MC										1	0
Slope											1

*BS: Base Sum; **MC: Mean curvature; ***Alt: Altimetry

A classificação supervisionada dos SCP1, TMPC1 e os parâmetros do terreno gerou um mapa predito detalhado de alta intensidade (ML1) (Figura 3a) com um índice kappa de 0.45 e com acurácia global de 62%. Para o mapa predito detalhado de baixa intensidade (ML2) (Figura 3b) o índice kappa foi de 0.52 e a acurácia global foi de 69%. Os níveis de confusão entre classes de solos na classificação foram relativamente baixos (Tabela 4) e os valores de DSC foram satisfatórios (Tabela 5). Comparando os mapas reais e os digitais visualmente a semelhança entre eles é alta.

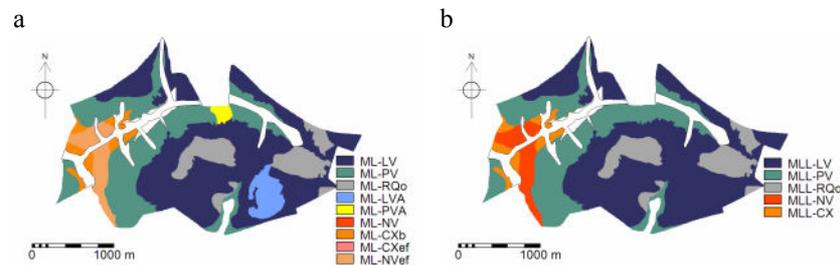


Figura 3. Mapa digital detalhado de solos preditos a) de alta densidade. b) de baixa intensidade.

Tabela 4. Porcetagem de cada area de classe de solo coberta por cada classe de solo predita (Sc).

Predicted soil classes	Detailed high density									Detailed low density				
	LV	LVA	PV	PV	RQ	NV	NVe	CXb	CXef	LV	PV	RQ	NV	CX
	<i>Strategy 1</i>													
ML1-LV	73.	35.8	21.	20.9	42.9	0.0	0.0	17.3	0.0	-	-	-	-	-
ML1-LVA	4.1	31.6	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-	-	-	-	-
ML1-PV	6.2	25.3	76.	46.6	12.2	20.8	49.2	42.1	99.2	-	-	-	-	-
ML1-PVA	0.1	0.0	0.2	32.5	0.0	0.0	0.0	0.0	0.0	-	-	-	-	-
ML1-RQo	13.	2.5	0.2	0.0	44.9	0.0	0.0	0.0	0.0	-	-	-	-	-
ML1-NV	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-	-	-	-	-
ML1-NVef	1.4	4.8	2.1	0.0	0.0	44.5	39.4	0.0	0.0	-	-	-	-	-
ML1-CXb	1.1	0.0	0.1	0.0	0.0	34.7	11.4	33.7	0.8	-	-	-	-	-
ML1-CXef	0.0	0.0	0.0	0.0	0.0	0.0	0.0	7.0	0.0	-	-	-	-	-
	<i>Strategy 5</i>													
ML2-LV	-	-	-	-	-	-	-	-	-	76.	19.	35.	0.0	10.
ML2-PV	-	-	-	-	-	-	-	-	-	11.	76.	26.	23.7	32.
ML2-RQo	-	-	-	-	-	-	-	-	-	9.7	0.1	37.	0.0	0.0
ML2-NV	-	-	-	-	-	-	-	-	-	2.5	3.8	0.0	54.8	23.
ML2-CX	-	-	-	-	-	-	-	-	-	0.3	0.1	0.0	21.5	32.

O LV do mapa digital cobriu algumas das areas do RQo real, isto é possivelmente devido ao fato de que a fração argila do LV nesta área é baixa (15 - 20%) e neste caso estes solos

têm valores próximos de argila. Grande parte das confusões do mapa predito de alta densidade ocorreram entre subgrupos da mesma classe de solo. O classe CX foi predita com baixa acurácia, isto é atribuído ao pequeno tamanho das unidades de mapeamento do CX e a sua dispersão dentro da área de estudo.

Tabela 5. Grau de correspondências espaciais (DSC)

Degree of Spatial Correspondence - DSC (%)			
Detailed - High density		Detailed - Low density	
LV - LV	73.9	LV - LV	76.5
LVA - LVA	40	PV - PV	76.1
PV - PV	66.4	RQo - RQo	37.8
PVA - PVA	48.2	NV - NV	54.9
RQo - RQo	42.5	CX - CX	32.8
NV - NV	0	-	-
NVef - NVef	36.3	-	-
CXb - CXb	25.1	-	-
CXef - CXef	0	-	-

Em relação à confusão entre o NV e o PV, a diferenciação entre estes dois solos na camada B a partir de suas características químicas e granulométricas é praticamente impossível, então o peso do SPC1 na discriminação destes solos é muito baixo já que ele não fornece suficiente informação que permita esta discriminação. Não obstante com as informações da superfície do solo da imagem de satélite a sua diferenciação pode resultar menos complexa.

Por outra parte os mapas de solo convencionais derivados da experiência dos pedólogos não estão isentos de erro. Muitas vezes o mapeador de solos afronta complexos problemas que deve resolver se baseando no seu conhecimento. Por exemplo Dobos (1998) estimou que a pureza taxonômica da base de dados de solos e de terreno da Hungria (desenvolvida usando o convencional conhecimento experto) é de 49.5%. Algumas pesquisas indicam que no mapeamento convencional de solos a pureza das unidades de solos é freqüentemente baixa (Ziadat, 2007). Burrough et al.(1971) achou que a faixa de pureza de unidades de mapeamento de solos pna escala de 1:25000 é normalmente de 65 - 86%. Neste caso assumindo que a pureza dos mapas reais seja de 100% (o que é pouco provável) e levando em conta a acurácia global dos mapas digitais preditos neste trabalho, é possível afirmar que o valor de acurácia do mapa digital de baixa intensidade encontra-se dentro dos faixas normais e que a acurácia global do mapa detalhado de alta intensidade encontra-se perto do limite inferior deste rango. É provável que a acurácia dos mapas digitais seja muito maior, mas a única referencia com a que se conta é a dos mapas reais o dos mapas derivados de conhecimento experto. Além disso é claro que erros nos mapas reais interferem no processo de treinamento do algoritmo de classificação derivando em um decréscimo do desempenho de predição.

4. Conclusões e considerações finais

Neste caso os mapas preditos usando metodologias de extração e de redução de dimensionalidade da informação favoreceu a predição dos mapas de solos, assim os mapas preditos foram semelhantes com os reais. O desempenho preditivo do método em geral foi satisfatório, especialmente na predição do mapa detalhado de baixa intensidade. No Brasil é comum o uso de SiO₂, Al₂O₃, TiO₂ e Fe₂O₃ como informação importante na classificação do solo. O custo destas análises é de 89 reais, neste caso por simples análises a redução dos custos destas análises na camada B neste trabalho foi de aproximadamente 50%.

A qualidade e a quantidade das informações relacionadas com os fatores de formação do solo favorecem a sua classificação, embora muita desta informação pode ser redundante o que pode representar um problema de multicolinearidade (Mendonça-Santos et al., 2007),

neste sentido o mapeador de solos deve extrair e prover ao algoritmo de interpolação do solo a informação mais importante. Qi (2004) indica que uma grande quantidade de informação redundante causa efeitos negativos no tempo de computo requerido e na qualidade das predições. Por outra parte, no mapeamento digital de classes de solos McBratney et al., (2003) tem proposto o modelo *scorpan* que considera que a classe de solo pode ser definida em função do clima, organismos, topografia, material parental, idade e espaço. Através do sensoriamento remoto é possível extrair informação importante sobre parâmetros deste fatores. Na estratégia usada neste trabalho focou-se unicamente em três destes fatores (solo, topografia e espaço), embora também tenha levado em conta indicadores de intemperismo que podem estar associados com o fator tempo. É possível que a incorporação de mais fatores do modelo scorpan e outras metodologias pedométricas chave, o desempenho das predições de classes de solo para o mapeamento digital de solos possa ser melhorado significativamente.

Agradecimentos

À Fundação de Amparo à Pesquisa do Estado de São Paulo, pelo auxílio financeiro e na concessão da bolsa a Leonardo Ramírez-López (proc. n. 07/58656-8).

Referências Bibliográficas

Burrough, P.A., P.H.T. Beckett & H.G. Jarvis, **The relation between cost and utility in soil survey (I-III)**. Journal of Soil Science 22: 368-381. 1971.

Demattê, J.A.M. **Characterization and discrimination of soils by their reflected electromagnetic energy**. Pesq. Agropec. Bras., Brasília, v. 37, 2002

Dobos, E., 1998. **Quantitative analysis and evaluation of AVHRR and terrain data for small scale soil pattern recognition**. PhD thesis. Purdue University, West Lafayette, ID.

McBratney A.B.; Mendonça Santos ML.; Minasny, B. **On digital soil mapping**. Geoderma 117, pp 3-52. 2003

Minasny, B.; McBratney, A.B. **A conditioned Latin hypercube method for sampling in the presence of ancillary information**. Computers & Geosciences 32, pp 1378-1388. 2006.

Mendonça-Santos, M.L.; McBratney, A.B.; Minasny B. **Soil Prediction with Spatially Decomposed Environmental Factors**. In: P Lagacherie, A.B. McBratney and M. Voltz (Editors), Digital Soil Mapping, an introductory perspective. Developments in soil science, volume 31. Elsevier, 2007 Amsterdam Pp 269-278.

Mendonça-Santos, M.L.; dos Santos H.G. **The State of the Art of Brazilian Soil Mapping and Prospects for Digital Soil Mapping..** In: P Lagacherie, A.B. McBratney and M. Voltz (Editors), Digital Soil Mapping, an introductory perspective. Developments in soil science, volume 31. Elsevier, 2007. Amsterdam Pp 39-54, 601

Qi, F. **Knowledge discovery from area-class resource maps: data preprocessing for noise reduction**. Transactions in GIS 8/3, pp. 297-308. 2004

Saldanha, D. L.; Lima, M. C.; Cunha E.; Haertel, V. **Spectral analysis of soils from mafic/ultramafic rocks of Cerro Mantiqueira, south-west of Rio Grande do Sul, Brazil**. Int. J. Remote Sensing, 20 October, 2004

Thanachit, S.; Suddhiprakarn, A.; Kheoruenromne, I.; Gilkes, R.J. **The geochemistry of soils on a catena on basalt at Khon Buri, northeast Thailand**. Geoderma 135 pp 81-96. 2006

Ziadat, F.M. **Land suitability classification using different sources of information: Soil maps and predicted soil attributes in Jordan**. Geoderma 140 73-80. 2007