

# DELINEAMENTO DAS UNIDADES DE MAPEAMENTO DE SOLOS UTILIZANDO O GOOGLE EARTH

Ândrea Machado Pereira FRANCO<sup>1</sup>, Ricardo Simão Diniz DALMOLIN<sup>1</sup>, Luis Fernando Chimello RUIZ<sup>2</sup>, Alexandre TEN CATEN<sup>3</sup>, Júlio Wincher SOARES<sup>1</sup>

(1) Departamento de solos. Universidade Federal de Santa Maria. Av. Rorãima, 1000, Bairro Camobi, 97105-900, Santa Maria – RS.

Endereço eletrônico: pfranco20@hotmail.com; dalmolin@ufsm.br; juliowincher@gmail.com.

(2) Universidade Federal do Rio Grande do Sul. Endereço eletrônico: ruiz.ch@gmail.com.

(3) Universidade Federal de Santa Catarina- Campus Curitibanos. Endereço eletrônico: tencaten@gmail.com.

Introdução

Material e Métodos

Área de treinamento

Obtenção e processamento das covariáveis ambientais

Seleção das covariáveis preditoras

Mineração de dados e obtenção do MDS

Acurácia do MDS

Resultados e Discussão

Formalização das relações solo-paisagem

Definição das covariáveis ambientais preditoras

Mapeamento digital das classes de solo na área de estudo

Conclusões

Referências bibliográficas

**RESUMO** - O Mapeamento Digital de Solos (MDS) contribui para a obtenção e disponibilização de informações sobre solos. A utilização do conhecimento tácito de um pedólogo experiente e das imagens disponíveis no Google Earth (GE) permite que se faça a identificação de classes de solos através da separação de feições da paisagem. O trabalho teve como objetivo utilizar o conhecimento tácito para estabelecer polígonos uniformes de relação solo-paisagem no GE e utilizar os polígonos vetorizados para o estabelecimento das relações entre as covariáveis ambientais e classes de solos. O estudo foi em uma área de 18,92 km<sup>2</sup> na região central do Rio Grande do Sul (RS). As covariáveis ambientais foram obtidas do MDE e da base cartográfica vetorial contínua do RS. A acurácia do MDS foi classificada como razoável com Kappa = 0,3 e a exatidão global de 53,64%. As covariáveis DECL, ELEV e IUT com maior potencial preditivo conferiram melhor confiabilidade ao MDS gerado. As classes de solos Neossolo Litólico, Argissolo Bruno-Acinzentado, Argissolo Vermelho e associação Cambissolo Háptico + Neossolo Litólico favoreceram as representações das relações solo-paisagem para obtenção do mapa de treinamento no GE, por serem mais representativas, enquanto que as classes de solos menos representativas foram reconhecidas predominantemente como inclusões.

**Palavras-chave:** conhecimento tácito, sensoriamento remoto, mineração de dados, levantamento de solos, pedologia

**ABSTRACT-** The Digital Soil Mapping (DSM) have contributed to the collection and provision of information on soils. The use of tacit knowledge of an experience pedologist and images available on Google Earth (GE) allows to do the identification of soil classes by separating landscape features. The objective of this work was to use the tacit knowledge to make uniform polygon soil-landscape relationship in GE and use vectorized polygons for the relations between environmental covariates and soil classes. The study was an area of 18.92 km<sup>2</sup> in central region of Rio Grande do Sul state (RS). Environmental covariates were obtained from MDE and continuous vector cartographic base of RS. The accuracy of DSM was classified as reasonable with Kappa = 0.3 and the overall accuracy of 53.64%. The covariates DECL, ELEV and IUT with greater potential predictive gave better reliability to the generated DSM. The soil classes Neossolo Litólico, Argissolo Bruno-Acinzentado, Argissolo Vermelho and Cambissolo Háptico + Neossolo Litólico association favored representations of soil-landscape relationship to getting the training map of GE to be more representative, while the less representative soil classes were predominantly recognized as inclusions.

**key-words:** tacit Knowledge, remote sensing, data mining, soil survey, pedology

## INTRODUÇÃO

No Brasil os levantamentos de solos em escala compatível para o planejamento agrícola são insuficientes, sendo necessários levantamentos em escalas mais detalhadas. Grande parte das informações sobre a distribuição espacial dos solos está disponível em escalas pequenas, dificultando a utilização prática dos mesmos (Dalmolin et al., 2005).

No mapeamento de solos tradicional, ao fazer a fotointerpretação, o pedólogo usa seu conhecimento tácito para fazer a separação de polígonos homogêneos na foto, estabelecendo a relação solo-paisagem deduzindo quais tipos de solos estão associados àquele polígono o que depois é conferido a campo. A posição espacial dos polígonos do solo implica nas relações entre

diferentes tipos de solo e as suas condições ambientais subjacentes. A delimitação de polígonos integra múltiplos conhecimentos inerentes ao pedólogo (Qi & Zhu, 2003). Esses autores ainda afirmam que a ideia base de extrair conhecimento a partir de polígonos marcados nos mapas do solo é reverter o processo de mapeamento. As relações entre o solo e características da paisagem pode ser revelada através da abordagem da descoberta do conhecimento (conhecimento tácito) por análise de mapas de solos juntamente com as características da paisagem capturados utilizando SIG.

A estruturação do conhecimento tácito nas relações solo-paisagem está baseada nas covariáveis ambientais que efetivamente descrevem os fatores de formação do solo. Em escala de bacia hidrográfica, as covariáveis ambientais utilizadas no modelo relação solo-paisagem são geralmente geologia, características topográficas e índices relacionados à vegetação (Qi & Zhu, 2003). Conforme esses autores, o conhecimento do local com relações solo-paisagem, uma vez extraído e devidamente formulado, pode ser utilizado para automatizar o mapeamento de solos, a modelagem e a classificação. Contudo, de acordo com Brabyn (1998) as covariáveis extraídas do MDE e utilizadas como parâmetros para a classificação não tem capacidade de padronização para todos locais, mas podem ser utilizadas e testadas para outras áreas que tenham topografia e geomorfologia semelhantes.

Existem vários trabalhos no âmbito do MDS que estão baseados no conhecimento tácito do pedólogo (Zhu & Band, 1994; Moran & Bui, 2003), que realizam inferências sobre os solos de um determinado local baseado principalmente na relação solo-paisagem. Como exemplo da aplicação do conhecimento tácito para a geração de MDS tem-se o programa SoLIM (Zhu et al., 2001) e os estudos e conceitos desenvolvidos por esses autores. Esse software faz inferências sobre os solos de um determinado local baseado no conhecimento tácito de pedólogos experientes que tenham o conhecimento necessário sobre o local que se deseja mapear.

A aplicação de novas tecnologias e abordagens para os levantamentos de solos tem se dado, principalmente, dentro do escopo do Mapeamento Digital de Solos (MDS) (McBratney et al., 2003). O MDS pode ser caracterizado como o conjunto de ferramentas que contribui para a disponibilização de informações espaciais de solos, através de dados obtidos no campo e laboratório, além de inferências realizadas com base nos fatores de formação do solo e covariáveis ambientais (Lagacherie & McBratney et al., 2007).

Dentro dessa ótica, há a possibilidade de integrar imagens do Google Earth (GE) a um SIG para mapear áreas onde as informações de solo não existem ou estão em escala incompatíveis para planejamento de uso. O GE é um aplicativo gratuito e de amplo acesso que pode auxiliar na separação das feições da paisagem em trabalhos de caracterização dos diferentes ambientes de formação do solo e formalização das relações solo-paisagem. O programa ainda permite visualizações em 3D, as imagens são coloridas, facilitando a interpretação dos dados de relevo e é mais econômico em comparação às fotografias aéreas (Moravej et al., 2012). Além disso, as imagens são de alta resolução espacial (Hamilton et al., 2009; Torlay & Oshiro, 2010; Hengel, 2011) e contém ferramentas que podem facilitar o trabalho de campo e planejamento de uso das terras (Hamilton et al., 2009; Guimarães et al., 2009; Frankl et al., 2013). Moravej et al. (2012) utilizaram imagens de satélite associado a um SIG e obtiveram resultados mais detalhados e precisos quando comparado com os levantamentos convencionais. Além disso, esses autores afirmam que se for utilizando um algoritmo adequado na mineração de dados, pode resultar em MDS mais precisos.

Porém, ainda são muito poucos os estudos que extraem informações desse aplicativo, já que através do mesmo pode-se estabelecer as relações solos paisagem em nível de bacia hidrográfica através do relevo e vegetação conforme estabelecido por Qi & Zhu (2003). No estado do Rio Grande do Sul, por exemplo, existe um levantamento de solos na escala 1:750.000 recobrando todo o estado, sendo os

demais levantamentos existentes em nível de detalhe ou semidetalhe (escalas maiores que 1:100.000), cobrem menos de 20% da área do estado (Streck et al., 2014). A utilização de informações extraídas do GE, combinada com técnicas de MDS poderiam auxiliar a confecção de mapas de solos mais detalhados em nível de bacia hidrográfica.

## MATERIAL E MÉTODOS

A área de estudo foi a sub-bacia do Rio Vacacaí-Mirim de 18,92 Km<sup>2</sup>, localizada na zona de transição entre o Planalto e a Depressão Central, denominada Rebordo do Planalto do Rio Grande do Sul, a qual está delimitada pelas coordenadas W53°35'/W54°00' e S29°32'/S29°40', no município de Santa Maria-RS (Figura 1A). A área apresenta um relevo que oscila de ondulado a montanhoso, com declividades entre 13 e 45%, podendo em alguns locais ocorrer declividades superiores a 100% e altitude variando entre 200 a 475 metros.

### Área de treinamento

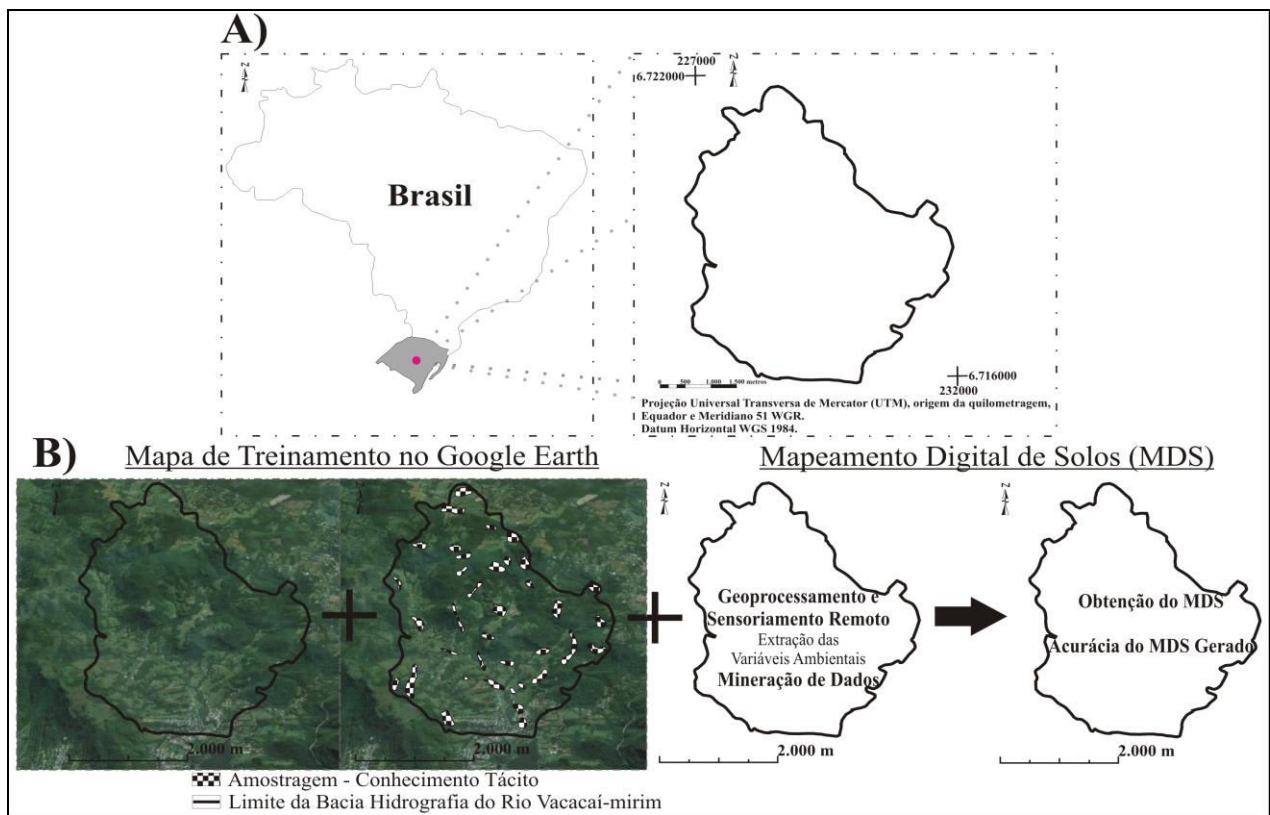
A área de treinamento foi obtida de informações visuais a partir do GE, onde foram delimitados polígonos com classe de solos (Figura 1B) baseado no conhecimento tácito de um Pedólogo experiente que possui o modelo mental da relação solo-paisagem da área de estudo (Zhu & Band, 1994) utilizando informações da área em nível de bacia hidrográfica, tais como geologia, características topográficas e condições de vegetação (uso da terra) (Qi & Zhu, 2003). Cada polígono irá representar uma unidade de mapeamento ou um grupo de classes de solo (Zhu et al., 2001). Para área de treinamento foi utilizada 100% da área da Bacia, 18,92 km<sup>2</sup>. Detalhes da Geologia, relevo e uso da terras nas diferentes superfícies geomórficas da região onde se encontra a área de estudo podem ser obtidas em Pedron & Dalmolin (2011). A metodologia aplicada para obtenção do mapa de treinamento é o que Qi & Zhu (2003) chamam de “descoberta do conhecimento inicial” (*tacit knowledge*). A partir dos polígonos com diferentes classes de

Com base no exposto acima, esse trabalho teve como objetivos: i) utilizar o conhecimento tácito de um pedólogo experiente para estabelecer polígonos uniformes de relação solo-paisagem no programa Google Earth. ii) utilizar os polígonos vetorizados para o estabelecimento das relações entre as covariáveis ambientais e classes de solos na abordagem MDS.

solos demarcados no mapa da área de treinamento foram extraídas as covariáveis ambientais.

### Obtenção e processamento das covariáveis ambientais

O modelo digital de elevação (MDE) foi obtido a partir das curvas de nível, disponíveis na base cartográfica vetorial contínua do Rio Grande do Sul na escala de 1:50.000 (Hasenack & Weber, 2010). Essas curvas foram interpoladas através da função *Thin Plate Spline (TIN)* do programa SAGA-GIS, gerando um MDE com resolução espacial 20 metros (Barbosa et al., 2008). A partir do MDE obteve-se as covariáveis ambientais: elevação (ELEV), curvatura planar (CPLAN), curvatura de perfil (CPRF), fator topográfico (LS), índice de umidade topográfica (IUT), declividade do terreno (DECL), distância do ponto cotado (DCOT) e distância à drenagem (DIST) obtidas de acordo com a metodologia descrita em Willson & Gallant (2000). A partir das covariáveis DCOT e DIST foi efetuado o cálculo da distância euclidiana. Esse procedimento foi realizado no programa GRASS-GIS. A variável incidência da radiação solar na superfície (ILUS) foi obtida a partir da simulação de iluminação na superfície do MDE utilizando o programa Heliotec no qual foi possível obter os valores de azimute e inclinação do sol. Com esses dados e a ferramenta *Hillshading* do SAGA-GIS foi possível gerar os quatros mapas de simulação de iluminação da superfície, que foram somados originando o atributo ILUS.



**Figura 1.** A) Localização da área de estudo e Mapa de validação; B) Mapa de treinamento e MDS.

A variável desvio padrão dos índices de vegetação por diferença normalizada (DPNDVI) foi gerada a partir das quatro imagens de satélite Landsat 5, com datas de 21/01/2009, 02/09/2010, 08/11/2012 e 26/12/2012. Essas imagens foram corrigidas geometricamente a partir de quinze pontos de controle, utilizando a função polinomial de segunda ordem para interpolação espacial, obtendo-se o erro médio quadrático menor que um pixel. Foi utilizada a interpolação bilinear na reamostragem dos valores dos pixels. A correção atmosférica das imagens foi efetuada por meio do método de subtração do objeto escuro (Chavez, 1996).

### Seleção das covariáveis preditoras

A seleção das covariáveis com maior potencial preditivo das classes de solos para área de estudo foi realizada por ACP. As componentes principais (CP) foram obtidas de uma matriz com 1426 amostras, representando a população de dez covariáveis, que com a aplicação da ACP foi reduzida em uma matriz quadrada de dimensão de 10x10. A obtenção das CP e da variabilidade das dez CP foram

realizadas utilizando o software livre R (R Development Core Team, 2011).

### Mineração de dados e obtenção dos MDS

A árvore de decisão (AD) utilizando o algoritmo J48 foi gerada no programa Weka 3.7 (Hall et al., 2009). A AD foi gerada para dois grupos de covariáveis, o primeiro com as dez e a segunda com as covariáveis com maior potencial preditivo, ou seja, oito covariáveis ambientais. Entre as configurações internas para da AD foi especificado o número mínimo de objetos (*minNumObj*) por folha igual a dois e selecionada a opção verdadeira para a poda da árvore (*reducedErrorPruning=True*), que é necessária para diminuir a extensão e complexidade da mesma.

A conversão da AD para o entendimento no Sistema de Informações Geográficas (SIG) foi realizada no programa ADtoSIG (Ruiz et al., 2012). O arquivo de saída do ADtoSIG gera o MDS. No programa Quantum GIS 1.8.0, utilizou-se a ferramenta *Accuracy Assesment* para gerar a matriz de confusão, oriunda da relação entre o MDS gerado e o de validação. O

mapa de validação utilizado como referência foi o mapa obtido pelo levantamento de solos convencional (Miguel, 2010).

### Acurácia do MDS predito

A partir da matriz de confusão com um total de 266 amostras identificadas no mapa de referência foi possível obter a acurácia dos MDS's gerados através da análise de

concordância entre o MDS gerado e o MDS de validação (Figura 1), utilizando o índice kappa, exatidão global, exatidão do produtor e exatidão do usuário (Congalton & Green, 2008). O índice Kappa pode ser classificado de acordo com Landis & Koch (1977):  $k \leq 0,2$ : ruim;  $0,2 < k \leq 0,4$ : razoável;  $0,4 < k \leq 0,6$ : bom;  $0,6 < k \leq 0,8$ : muito bom e  $k \geq 0,8$ : excelente.

## RESULTADOS E DISCUSSÕES

### Formalização das relações solo-paisagem

O uso do GE na escala de bacia hidrográfica foi eficiente, pois auxiliou no estabelecimento das relações solo-paisagem em função da alta resolução das suas imagens (Hamilton et al., 2009; Torlay & Oshiro, 2010; Hengel, 2011) e da visualização das formações do relevo em 3D. Na área de estudo foi possível identificar sete classes de solos (Figura 1B). As classes Neossolo Litólico, Argissolo Bruno-Acinzentado, Argissolo Vermelho e associação Cambissolo Háptico + Neossolo Litólico tiveram melhores representações das relações solo-paisagem por ocuparem posições bem definidas e serem as mais representativas. As classes de solos Planossolo Háptico, Neossolo Flúvico e Neossolo Regolítico, por serem menos representativas, foram mais difíceis de serem identificadas através das visualizações e relação-solo paisagem.

### Definição das covariáveis ambientais preditoras

A análise de componentes principais (ACP) avaliou a correlação existente entre as covariáveis ambientais. Na Figura 2A visualiza-se a relação entre os autovalores de cada componente principal (CP), em que as quatro primeiras componentes apresentam autovalores maiores que 1. Nesse caso, somente essas CP são significativas, provavelmente apresentam maior influência na predição de classes de solos (ten Caten et al., 2011a), explicando 68,87% da variabilidade acumulada das covariáveis, enquanto que os resultados de variabilidade acumulada superior a 80% estão distribuídos entre as seis primeiras componentes. Resultados semelhantes foram encontrados por Hengl & Rossiter (2003) e ten Caten et al.(2011a).

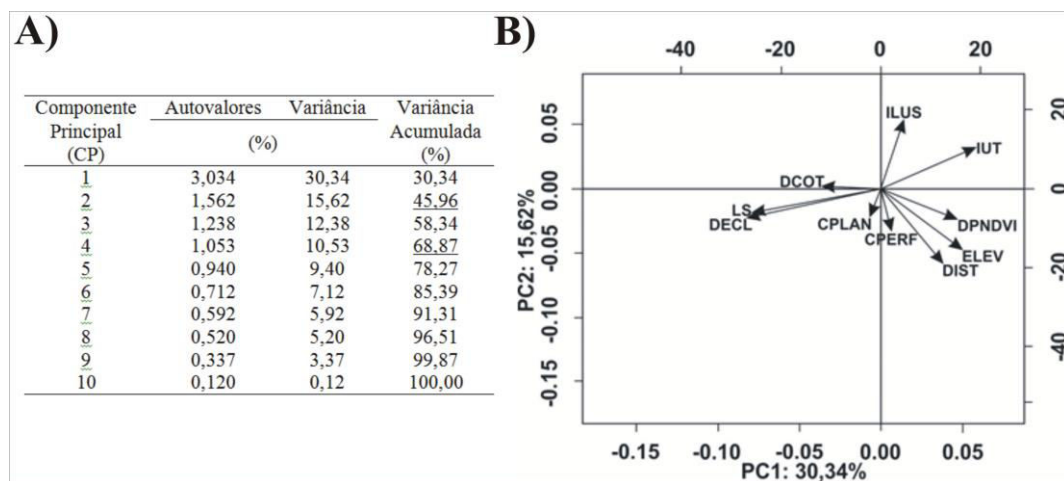


Figura 2. A) Distribuição da variabilidade nas dez componentes principais. B) Diagrama de ordenação unitário

A Figura 2 mostra que a CP1 é responsável por aproximadamente um terço da variância dos dados, apresentando valores e variabilidade próximos aos encontrados por ten Caten et al. (2011a,b), enquanto que a CP1 e CP2 juntas representam 45,96% da variabilidade total.

Com auxílio do diagrama de ordenação unitário para as duas primeiras CP (Figura 2B) afirma-se que as covariáveis com maior influência na variabilidade da primeira CP foram DECL, LS e DCOT, porém LS e DECL apresentaram-se quase que sobrepostas, ou seja, colineares entre si. Em sentido oposto, formando um ângulo de aproximadamente 180°, observa-se a covariável IUT, que tem relação inversa e positiva com as covariáveis da CP1, porém com uma menor contribuição na porcentagem de variância da CP1 (30,34%). A covariável CPLAN também está no mesmo quadrante de contribuição da CP1, porém verificou-se que a mesma tem pouca influência na variabilidade dessa primeira componente, bem como, na variabilidade das demais CP.

As covariáveis DPNDVI, ELEV, CPERF e DIST apresentam-se praticamente equidistantes entre si, diante a observação do diagrama de ordenação (Figura 2B), o que reflete praticamente a ausência de colinearidade e consequentemente contribuem de forma significativa na variância da CP2. Também é possível inferir que as covariáveis IUT e ILUS formam pares ortogonais, respectivamente, com as covariáveis CPERF e DPNDVI, estando essas covariáveis em posição simétrica no diagrama de ordenação (Figura 2B) e contribuem de forma considerável para a variabilidade da CP2 (15,62%), embora não forme pares ortogonais.

Entre os dois grupos de covariáveis ambientais que influenciam nos maiores valores de variância, podem-se excluir LS e CPLAN. A covariável LS foi excluída em função da sua expressiva colinearidade com DECL (Figura 2B), pois ambas estão relacionadas ao relevo. A covariável CPLAN foi excluída por apresentar baixa influência na variabilidade de todas as CP (Figura 2). Hengl et al. (2007) afirmam que a exclusão de covariáveis do modelo pode ocorrer de forma a evitar os efeitos de multicolinearidade.

## **Mapeamento digital das classes de solos na área de estudo**

Com isso, as covariáveis ambientais selecionadas (preditoras) são: DECL, DCOT, CPERF, DIST, ELEV, DPNDVI, IUT e ILUS, em função da maior variabilidade apresentada até a oitava componente principal e por não haver efeitos representativos de colinearidade entre elas, conferindo-lhes maior aptidão para constituir modelos preditivos de classe de solo. Isso pôde ser comprovado ao avaliar a acurácia do modelo, em que os valores de kappa utilizando oito e dez covariáveis ambientais foram 0,30 e 0,26, respectivamente. Esses valores confirmam que não houve perda do potencial preditivo do modelo com a redução do número de covariáveis, estando de acordo com os resultados encontrados por Hengl et al. (2007) e ten Caten et al. (2011a). Entretanto, ten Caten et al. (2011b) obteve perda do potencial preditivo quando diminuiu o número de covariáveis utilizadas, pois as mesmas já eram correlacionadas naturalmente entre si.

Os valores de kappa encontrados foram classificados como razoáveis conforme escala de Landis & Koch (1977). Essa informação pode estar relacionada com o relevo acidentado da área, onde ocorrem muitas associações de solos e pela ocorrência de classes de solos pouco representativas segundo o trabalho realizado por Miguel (2010), dificultado sua identificação na marcação dos polígonos no GE para a obtenção do mapa de treinamento.

O treinamento de amostras (polígonos) através de relações solo-paisagem no programa GE apresentou valores de Kappa semelhantes aos encontrados por Giasson et al. (2006) e Coelho & Giasson (2010) que treinaram pontos aleatórios gerados a partir dos planos de informação obtidos do MDE e por Silva et al. (2013), que utilizaram mapa de treinamento obtido através da amostragem aleatória de pontos no campo.

A partir de 266 amostras identificadas no mapa de referência, 153 são de Neossolo Litólico e 70 de Argissolo Bruno-Acinzentado, considerando também as inclusões (Tabela 1). Estas classes representam respectivamente 57% e 26% da totalidade dos pontos amostrados.

Essas duas classes de solos apresentam juntas uma área de aproximadamente 1236 ha, representando 65 % da área total da bacia. As demais amostras estão distribuídas entre as outras classes de solo identificadas (Figura 3).

A proporção de observações corretamente classificadas em relação ao número total de

observações (266) é expressa pela exatidão global (EG) (53,76%), com valor de EG entre 50 e 70%. Valores de EG dentro deste intervalo de valores também foram encontrados por Coelho & Giasson (2010) e Giasson et al. (2011), Silva et al. (2013) e Nanni et al. (2010).

**Tabela 1.** Matriz de confusão e parâmetros que avaliam acurácia do MDS.

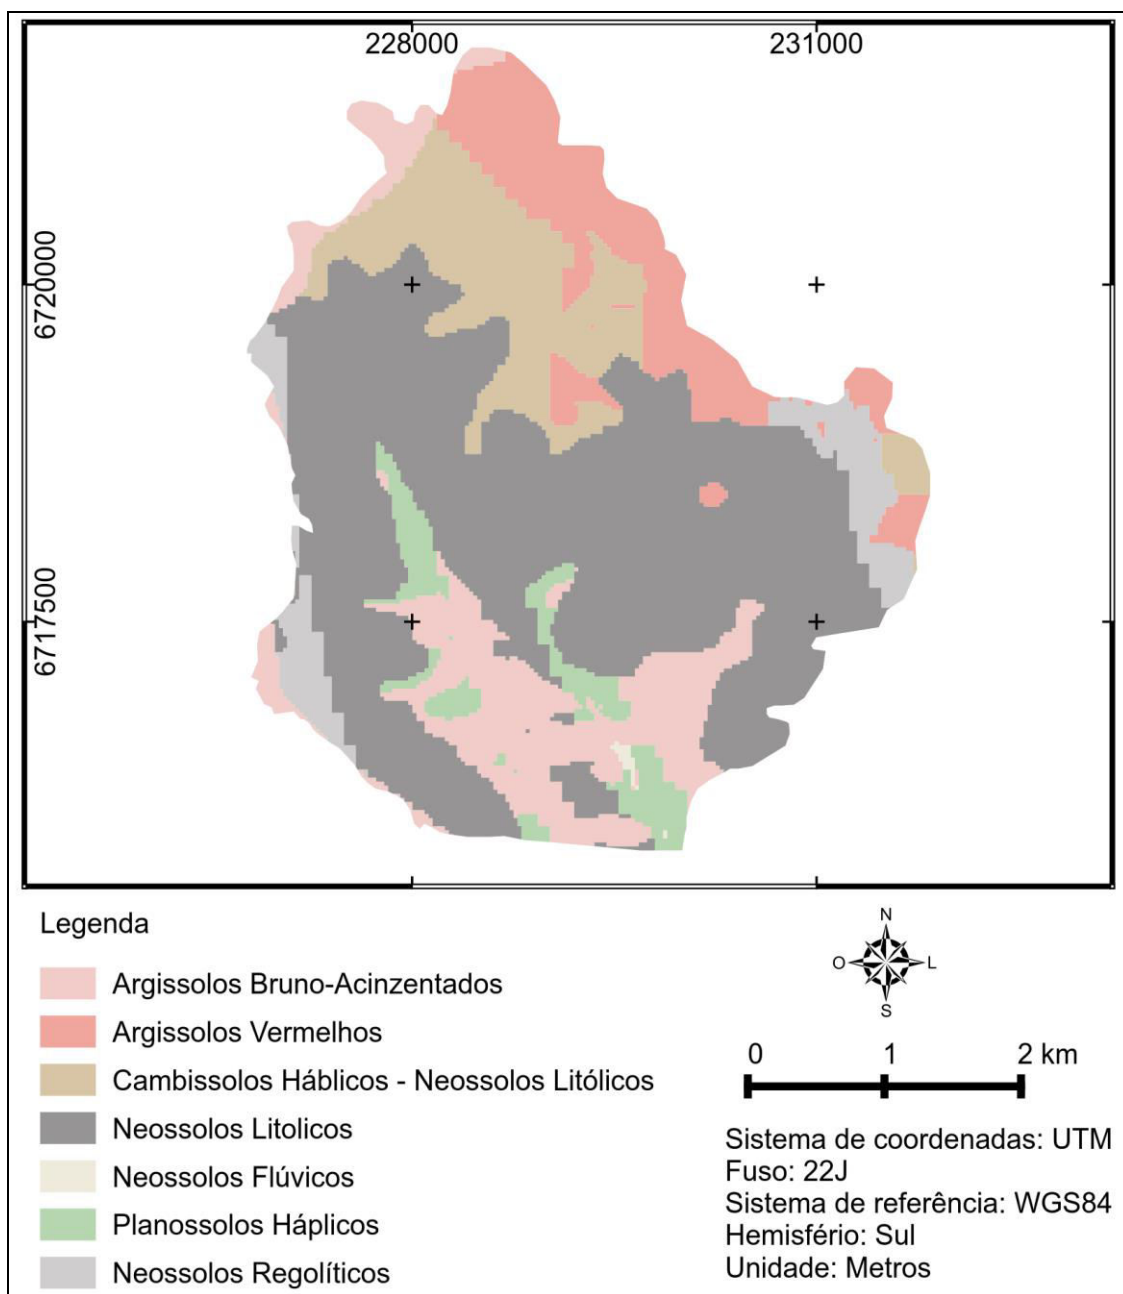
Unidades de Mapeamento	PBAC	PV	CX+ RL	RL	RY	SX	RR	Total	EU	Área (ha)
PBAC	<b>44</b>	0	4	12	3	2	3	68	64,71	271,71
PV	1	<b>4</b>	1	14	0	1	0	21	19,05	218,16
CX + RL	1	2	<b>0</b>	23	0	0	1	27	0,00	244,89
RL	18	2	4	<b>91</b>	2	0	5	122	74,59	964,8
RY	0	0	0	0	<b>0</b>	0	0	0	0,00	2,7
SX	6	0	0	5	1	<b>3</b>	1	16	18,75	90,09
RR	0	0	2	8	0	1	<b>1</b>	12	8,33	101,61
Total	70	8	11	153	6	7	11	266		
Exatidão do Produtor (%)	62,9	50,0	0,0	59,5	0,0	42,9	9,1			
<b>Exatidão global</b>	<b>53,76%</b>		<b>Kappa = 0,30</b>							

PBAC – Argissolo Bruno-Acinzentado; PV- Argissolo Vermelho; CX/RL- Cambissolo Háplico + Neossolo Litólico; RL- Neossolo Litólico; RY – Neossolo Flúvico; SX- Planossolo Háplico; RR – Neossolo Regolítico; EU: Exatidão do usuário

A exatidão do usuário (EU) mede a probabilidade de um ponto no mapa representar a verdade do terreno. Conforme a Tabela 1 observa-se que o Neossolo Litólico apresentou 74,59% dos pontos amostrados na área de treinamento através do programa GE em concordância com os pontos marcados no mapa de referência, enquanto que o Argissolo Bruno-Acinzentado apresentou 64,71% de concordância com os pontos amostrados no mapa de referência. Os maiores valores de EU podem estar relacionados à maior facilidade de identificar essas classes de solos no mapa de treinamento através do método utilizado, pois essas são as classes mais representativas da área de estudo. Já o Argissolo Vermelho, Planossolo Háplico e Neossolo Regolítico obtiveram, respectivamente, 19,05, 18,75 e 8,33% de concordância de pontos amostrados. A associação Cambissolo Háplico + Neossolo

Litólico e o Neossolo Flúvico não obtiveram concordância de pontos amostrados (Tabela 1).

Os menores valores encontrados para a EU pode estar relacionado com a maior dificuldade de identificar as classes RL, RR e associação CX + RL no mapa de treinamento (polígonos) utilizando as imagens de satélite do programa GE. Algumas classes de solos, devido a pouca representatividade na área não geraram informações suficientes para estabelecer as covariáveis preditoras, as quais podem não se mostrar eficientes para a identificação de determinadas classes de solos. Silva et al. (2013) afirmam que classes de solos com menor número de pontos amostrados se confundem com as classes mais representativas, favorecendo a ocorrência de inclusões de uma determinada classe de solo em outra. Isso ocorre em função que as covariáveis preditoras apresentam maior variabilidade nas classes de maior representação.



**Figura 3.** MDS gerado utilizando oito covariáveis ambientais.

Há também a possibilidade de o mapa de validação de Miguel (2010) obtido através de levantamento convencional não ter identificado alguma unidade de mapeamento, que no MDS pode aparecer como uma nova unidade de mapeamento. As novas unidades de mapeamento podem ser representadas por inclusão, associação, ou ainda zonas de transições, tendo essas novas unidades características diferentes das unidades de mapeamento que anteriormente não tinham sido representadas no mapa convencional (Nolasco et

al., 2008), como também, pode ocorrer uma incompatibilidade de tamanhos de pixel utilizada para a confecção do MDS, os quais podem gerar um enquadramento divergente entre o mapa de solo convencional e o digital (Zhu et al., 2001; Nolasco et al., 2008)

Entre as sete classes de solos identificadas no MDS gerado (Figura 3), as classes Argissolo Bruno-Acinzentado e Neossolo Litólico apresentam os melhores valores de exatidão do produtor (EP), que avalia o quanto uma unidade de mapeamento (classe de solo) foi identificada



corretamente no MDS gerado. Essas classes de solos apresentaram, respectivamente, 62,9% e 59,5% de EP, as quais foram melhores identificadas em função do maior número de pontos identificados corretamente (exatidão do usuário). Das 70 amostras identificadas de Argissolo Bruno-Acinzentado, 44 coincidiram com os pontos classificados no mapa de referência e os demais pontos foram identificados como inclusões predominantes nas classes Neossolo Litólico e Planossolo Háplico. No entanto, das 153 amostras identificadas de Neossolo Litólico, 91 coincidiram com os pontos classificados no mapa de referência, sendo que os demais pontos aparecem como inclusões nas outras classes de solos identificadas no MDS (Figura 3).

O predomínio de inclusões de Argissolo Bruno-Acinzentado, associação Cambissolo Háplico + Neossolo Litólico e Neossolo Regolítico na unidade de mapeamento Neossolo Litólico, e a inclusão dessa classe nas unidades de mapeamento de Argissolos, associação Cambissolo Háplico + Neossolo Litólico e Neossolo Regolítico (Tabela 1) deve estar relacionada à grande variabilidade de solos encontrada em região de relevo fortemente acidentado. Além disso, essas classes de solos apresentam algumas semelhanças de ocorrência na paisagem, por serem influenciados pelas covariáveis ambientais relacionadas ao relevo e clima, além do tempo de formação.

O Neossolo Litólico que representa 51% da área total da bacia, normalmente ocorre em associação com algum outro solo ou ocorre em forma de manchas inclusas numa outra unidade de mapeamento. Isso ocorre devido à complexidade do terreno, predominantemente de relevo forte ondulado a montanhoso basal que favorece a presença de solos mais rasos.

Diferente destes solos, o Planossolo Háplico, que é característico de áreas planas e mal drenadas apresentou predomínio de inclusão no Argissolo Bruno-Acinzentado (Tabela 1), solo esse que também ocorrem em áreas planas ou suave onduladas com drenagem imperfeita.

Por outro lado, não foram previstas corretamente as classes Neossolo Flúvico e a associação Cambissolo Háplico + Neossolo Litólico, porém as mesmas foram identificadas somente como inclusões, obtendo valores de EP nulos (Tabela 1). Isso possivelmente deve estar relacionado a não haver coincidência de amostras da área de treinamento com amostras da área de referência ou pela baixa representatividade, menor que 5% da área total, a qual deve ser desconsiderada, pois dificulta a geração do MDS (Bailey et al., 2003).

A não predição correta de uma classe de solo também pode estar relacionada às características morfológicas, que são relativamente semelhantes e podem causar confusão entre as amostras das diferentes classes de solo, principalmente quando as mesmas ocorrerem em áreas declivosas, o que torna difícil a identificação, especialmente nesse caso em que obteve-se a área de treinamento em imagens de satélite obtidas do GE.

Este trabalho é pioneiro em gerar um MDS a partir de polígonos marcados em imagens de satélite obtidas do programa GE e por isso muitos estudos ainda devem ser realizados, inclusive com a participação de mais pedólogos experientes na demarcação dos polígonos nas imagens para contrastar as diferenças existentes. O que queremos é buscar novos instrumentos que permitam obter informações mais detalhadas sobre solos do que temos atualmente, de maneira rápida e pouco onerosa e que possam auxiliar os usuários, sejam da pesquisa, extensão ou mesmo produtores rurais.

## CONCLUSÕES

1. A acurácia do MDS quando comparada com o Mapa de solos convencional foi classificada como razoável com Kappa = 0,3 e a exatidão global de 53,64%.

2. As covariáveis DECL, DCOT, CPERF, HIDRO, ELEV, DPNDVI, IUT e ILUS com maior potencial preditivo conferiram melhor confiabilidade ao MDS gerado.

3. As classes de solos Neossolo Litólico, Argissolo Bruno-Acinzentado, Planossolo Háptico e associação Cambissolo Háptico + Neossolo Litólico favoreceram as representações das relações solo-paisagem na obtenção do mapa

de treinamento no Google Earth por serem mais representativas, enquanto que as classes de solos menos representativas foram reconhecidas predominantemente como inclusões.

## REFERÊNCIAS BIBLIOGRÁFICAS

1. BAILEY, N.; CLEMENTS, T.; LEE, J. T. & THOMPSON, S. Modelling soil series data to facilitate targeted habitat restoration: A polytomous logistic regression approach. **J. Environ. Manag.**, v. 67, p.395-407, 2003.
2. BARBOSA, R. L.; MENEGUETTE JR, M.; SILVA, J. F. C.; GALLIS, R. B. A. & ITAME, O. Y. Análise estatística da qualidade de um modelo digital do terreno gerado com thin plate spline. **Rev. Bras. Cartografia**, v. 60, p.127-132, 2008.
3. BRABYN, L. **GIS analysis of macro landform**. Department of geology, University of Waikato, Hamilton, New Zealand. Proceeding of the Spatial Information Research Centers. In: 10<sup>TH</sup> COLLOQUIUM OF THE SPATIAL INFORMATION RESEARCH CENTERS, 1998, New Zealand. **Anais...** New Zealand: University of Otago, 1998.
4. CHAVEZ JR., P. S. Image-based atmospheric corrections - revisited and improved. **Photogramm. Eng. Rem. S.**, v. 62, n.9, p.1025-1036, 1996.
5. COELHO, F. F. & GIASSON, E. Comparação de métodos para mapeamento digital de solos com utilização de sistema de informação geográfica. **Ci. Rural**, v.40, n.10, p.2099-2106, 2010.
6. CONGALTON, R. G. & GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. 2. ed. Boca Raton: Taylor and Francis, 200p., 2008.
7. DALMOLIN, R. S. D.; GONÇALVES, C. N.; KLAMT, E. & DICK, D. P. Relação entre os constituintes do solo e seu comportamento espectral. **Ci. Rural**, v. 35, n.2, p.481-489, 2005.
8. FRANKL, A.; ZWERTVAEGHER, A.; POESEN J. & NYSSSEN, J. Transferring Google Earth Observations to GIS-software: Example from Gully Erosion Study. **International Journal of Digital Earth**. In Press. v.6, n.2, p.196-201, 2012. Disponível em: <https://biblio.ugent.be/input/download?func=downloadFile&recordId=3080744&fileId=3080821>. Acessado em: 10Jan2015.
9. GIASSON, E.; CLARKE, R. T.; INDA JR., A. V.; MERTEN, G. H. & TORNQUIST, C. G. Digital soil mapping using multiple logistic regression on terrain parameters in southern Brazil. **Sci. Agric.**, v.63, n.3, p.262-268, 2006.
10. GIASSON, E.; SARMENTO, E. C.; WEBERL, E.; FLORES, C. A. & HASENACK, H. Decision trees for digital soil mapping on subtropical basaltic steeplands. **Sci. Agric.**, v. 68, n.2, 167-174, 2011.
11. GUIMARÃES, D. P.; LANDAU, E. C. & COSTA, T. C. C. Relevo digital dos municípios brasileiros. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 7283-7290.
12. HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P. & WITTEN, I. H. **The WEKA Data Mining Software: An Update**; SIGKDD Explorations, 2009. Disponível em: <http://www.cs.waikato.ac.nz/ml/weka/>. Acessado em: 12Ago2014.
13. HAMILTON, N. J.; MIJATOVIC, B.; MUELLER, T. G.; LEE, B. D.; KEW, B. W.; CETIN, H. & KARATHANANIS A. D. Google Earth dissemination of soil survey derived interpretations for land use planning. **J. Extension.**, v.47, n.5, 2009. Disponível em: <http://www.joe.org/joe/2009october/a3.php>>. Acessado em: 15Jan2015.
14. HASENACK, H. & WEBER, E. **Base cartográfica vetorial contínua do Rio Grande do Sul - escala 1:50.000**. Porto Alegre: UFRGS Centro de Ecologia, 2010. DVD-ROM. (Série Geoprocessamento n.3).
15. HENGL, T. & ROSSITER, D. G. Supervised Landform classification to enhance and replace photo-interpretation in semi-detailed soil survey. **Soil Sci. Soc. Am. J.**, v.67, n.6, 1810-1822, 2003.
16. HENGL, T.; TOOMANIAN, N.; REUTER, H. I. & MALAKOUTI, M. J. Methods to interpolate soil categorical variables from profile observations: lessons from Iran. **Geoderma**, v. 140, n.4, p.417-427, 2007.
17. LAGACHERIE, P.; MCBRATNEY, A. B. & VOLTZ, M. (Ed.). **Digital soil mapping: an introductory perspective**. Amsterdam: Elsevier, 600p., 2007.
18. LANDIS, J. R. & KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v.33, n.1, p.159-174, 1977.
19. MCBRATNEY, A. B.; MENDONÇA SANTOS, M. L. & MINASNY, B. On digital soil mapping. **Geoderma**, v. 117, p. 3-52, 2003.
20. MIGUEL, P. **Caracterização Pedológica, Uso da Terra e Modelagem da Perda de Solo em Áreas de Encosta do Rebordo do Planalto do RS**. 2010. 116p. Dissertação (Mestrado em Ciência do Solo) - Universidade Federal de Santa Maria, Santa Maria, RS, 2010.
21. MORAN, C. J. & BUI, E. N. Spatial data mining for enhanced soil map modeling. **Inter. J. Geogr. Inf. Sci.**, v.16, n.6, p.533-549, 2002.
22. MORAVEJ, K.; EGHBAL, M. K.; TOOMANIAN, N. & MAHMOODI, S. Comparison of automated and manual landform delineation in semi detailed soil survey procedure. **Afr. J. Agric. Res.**, v.7, n. 17, p.2592-2600, 2012.
23. NANNI, M. R.; CÉZAR, E.; CHICATI, M. L.; HATA, F. T.; OLIVEIRA, R. B. & DEMATTÊ, J. A. Discriminação de unidades de paisagem para fins de levantamentos pedológicos por meio da resposta espectral orbital. **Acta Sci.**, v.32, n.3, p.555-561, 2010.
24. NOLASCO-CARVALHO, C. C.; FRANCA-ROCHA, W. & UCHA, J. M. Mapa digital de solos: Uma proposta metodológica usando inferência fuzzy. **R. Bras. Eng. Agríc. Ambiental**, v.13, n.1, p.46-55, 2009.
25. PEDRON, F. A. & DALMOLIN, R. S. D. Solos da região do rebordo do Planalto do Rio Grande do Sul. In: SCHUMACHER, M. V.; LONGHI, S. J.; BRUN, E. J. & KILCA, R. V. **A Floresta Estacional Subtropical:**

**Caracterização e Ecologia no Rebordo do Planalto Meridional.** 1 ed. Santa Maria, p.33-51, 2011.

26. QI, F. & ZHU, A. X. Knowledge discovery from soil maps using inductive learning. **Inter. J. Geogr. Inf. Sci.**, v. 17, n.8, p.771-795, 2003.
27. R Development Core Team. **R: A Language and Environment for Statistical Computing.** R Foundation for Statistical Computing, Vienna, Austria. 2011.
28. RUIZ, L. F. C.; TEN CATEN, A. & DALMOLIN, R. S. D. **ADtoSIG - Software de Conversão.** Universidade Federal de Santa Maria, v.1, 2011.
29. SILVA, C. C; COELHO, R. M.; OLIVEIRA, S. R. M. & ADAMI, S. F. Mapeamento Pedológico Digital da Folha Botucatu (SF-22-Z-B-VI-3): Treinamento de dados em mapa tradicional e validação de campo. **R. Bras. Ci. Solo**, v.37, n.4, p.846-857, 2013.
30. STRECK, E. V.; DALMOLIN, R. S. D. & FLORES, C. A. A utilidade social de mapas de solos produzidos no Brasil. O caso do Rio Grande do Sul. In: Boletim Informativo da Sociedade Brasileira de Ciência do Solo (SBCS) – **Em debate, a utilização dos mapeamentos de solos no Brasil**, v.39, n. 1, Jan/Abr de 2014.
31. TEN CATEN, A.; DALMOLIN, R. S. D.; PEDRON, F. A. & MENDONÇA-SANTOS, M. L. Estatística multivariada

- aplicada à diminuição do número de preditores no mapeamento digital de solos. **Pesq. agropec. bras.**, v.46 p.554-562, 2011a.
32. TEN CATEN, A.; DALMOLIN, R. S. D.; PEDRON, F. A. & MENDONÇA-SANTOS, M. L. Componentes principais como preditores no mapeamento digital de classes de solos. **Ci. Rural**, v.41, n.7, p.1170-1176, 2011b.
33. TORLAY, R. & OSHIRO, O. T. Obtenção de Imagem do Google Earth para classificação de uso e ocupação do solo 2010. In: CONGRESSO INTERINSTITUCIONAL DE INICIAÇÃO CIENTÍFICA, 4., 2010. Campinas. **Anais...** Campinas: IAC, 2010.
34. WILSON, J. P. & GALLANT, J. C. Digital terrain analysis. In:\_\_\_\_\_ (Ed.). **Terrain analysis: principles and applications.** New York: Wiley & Sons, p.1-27, 2000.
35. ZHU, A. X. & BAND, L. A knowledge-based approach to data integration for soil mapping. **Can. J. Remote Sens.**, v.20, n.4, p.108-118, 1994.
36. ZHU, A. X.; HUDSON, B.; BURT, J.; LUBICH, K. & SIMONSON, D. Soil mapping using GIS, expert knowledge, and fuzzy logic. **Sci. Soc. Am. J.**, v.65, p.885-894, 2001.

*Manuscrito recebido em: 17 de Março de 2015  
Revisado e Aceito em: 17 de Agosto de 2015*