

Editorial

O mês de Setembro começou com renovação no Grupo PET-Geografia. Despedimo-nos dos PETianos: Leonardo, Jéssica, Marcela e Michelle. Para seus lugares, damos boas vindas aos novos colegas: Felipe, Raquel, Francine e Giovani. Esperamos que seus caminhos sejam brilhantes nessa nova etapa. Neste mês, foi aplicada a Educação Ambiental na Escola da Aldeia M'Biguaçu. O grupo, com auxílio dos alunos indígenas, recolheu o lixo espalhado na comunidade e os separou em sala de aula em recicláveis, e outros. Na semana seguinte o Grupo realizou uma visita ao Museu do Lixo, da companhia de coleta municipal, COMCAP. Foi também organizado o quadro de atividades planejadas para o ano de 2013, como programa de rádio, documentário, entre outras atividades de ensino e extensão. Além das atividades realizadas na Grande Florianópolis, as PETianas Ana Paula e Laura apresentaram, com maestria, o projeto CinePET no SEURS, em Rio Grande/RS, onde compartilharam o trabalho e absorveram ainda mais conhecimento e aprendizados vindos da troca de experiências das diversas atividades ali reunidas. No "Mês das Festas de Outubro" todos trabalharão em suas pesquisas, buscando respostas nos mais variados campos da Geografia, dentro do Observatório da Grande Florianópolis.

Grupo PET-Geografia FAED/UDESC

PetGeo FAED/UDESC

Expediente:

Ana Paula Esnidei Pereira, Carolina Datria Schulze, Felipe Polmann Alberici, Francine Sagas Florindo, Giovani Silveira dos Santos, João Daniel Barbosa Martins, Laura Dias Prestes, Raphael Meira Knabben, Raquel Bittencourt, Rudney da Silva, Samuel Bastos Bracagioli, Yasmim Rizzolli Fontana dos Santos

Edição: João Daniel Barbosa Martins

Revisão: Grupo PET-Geografia

Impresso pelo Grupo PET-Geografia FAED/UDESC, em tamanho A4, fonte Times New Roman.

Sugestões, reclamações, convites, opiniões: petgeopress@gmail.com

Nessa edição:

Página

ESTUDO DE TÉCNICAS DE CLASSIFICAÇÃO DIGITAL SUPERVISIONADA E ANÁLISE ORIENTADA A OBJETO.....	2
PET – Indica	18
Eventos.....	19

ESTUDO DE TÉCNICAS DE CLASSIFICAÇÃO DIGITAL SUPERVISIONADA E ANÁLISE ORIENTADA A OBJETO

Dinameres Aparecida Antunes¹

Selma Regina Aranha Ribeiro²

RESUMO

O objetivo deste trabalho é o estudo e comparação de técnicas consagradas de classificação digital supervisionada. Os métodos escolhidos de classificação foram: Distância Mínima, Máxima Verossimilhança (MAXVER), Distância de Mahalanobis e *Support Vector Machine* (SVM). Para a comparação dos métodos adotou-se a análise orientada a objetos que subdividem a imagem em regiões, produzindo vetor e tabela de atributos, o que torna possível a comparação entre os classificadores. O trabalho é pertinente, pois as geotecnologias, como o Sensoriamento Remoto, têm sido bastante utilizadas nos estudos da Geografia dando respaldo ao desenvolvimento de várias pesquisas como, por exemplo, as análises temporais.

PALAVRAS-CHAVE: Classificação digital de imagens. Classificação supervisionada. Análise orientada a objetos.

INTRODUÇÃO

O avanço tecnológico proporcionou o desenvolvimento das geotecnologias, dentre elas o Sensoriamento Remoto, e os Sistemas de Informação Geográfica (SIG), que são bastante utilizadas em estudos da Geografia.

O Sensoriamento Remoto é a ciência de adquirir informações sobre objetos e fenômenos sem contato com esses, permitindo visão resumida e panorâmica de determinada área, e possibilita rapidez e periodicidade no fornecimento de imagens e informações. (CENTENO, 2004; JENSEN 2009; ROSA 2005).

O uso e ocupação do solo sofrem constantes modificações. Portanto, o seu conhecimento atualizado é importante para diversos estudos na Geografia e também em outras ciências, como por exemplo, em análises temporais, planejamentos e fiscalizações nas mais diversas áreas de ocupação do espaço geográfico.

Dessa forma, estudos sobre as técnicas de sensoriamento remoto são pertinentes para a ciência geográfica, pois podem contribuir com o desenvolvimento de pesquisas, auxiliar em monitoramentos e na tomada de decisões.

O presente trabalho utilizou-se de uma imagem digital Landsat5 TM, do município de Castro-Paraná, como objetivo de investigar as técnicas consagradas de

¹ Aluna do 4º em Geografia Bacharelado da Universidade Estadual de Ponta Grossa – UEPG – dinameres@hotmail.com

² Professora Doutora do Departamento de Geociências da Universidade Estadual de Ponta Grossa – UEPG – selmar_12@hotmail.com

classificação digital supervisionada de imagens no nível de pixel e da análise orientada a objeto, utilizando os métodos de Mínima Distância, Máxima Verossimilhança (MAXVER), Distância de Mahalanobis e *Support Vector Machine*(svm).

REFERENCIAL TEÓRICO

O avanço tecnológico proporcionou o desenvolvimento das geotecnologias, que Rosa (2005) define como um conjunto de tecnologias para a coleta, processamento, análise e oferta de informações com referência geográfica, dentre as geotecnologias está o Sensoriamento Remoto e os Sistemas de Informação Geográfica (SIG), que são usadas em diversos campos do conhecimento, como a Geografia.

O Sensoriamento Remoto constitui-se como ciência e arte de adquirir informações sobre objetos e fenômenos sem contato com esses, tipicamente utiliza regiões do espectro eletromagnético e instrumentos localizados em plataformas móveis. Os dados adquiridos são transformados por meio de técnicas de interpretação e reconhecimento de padrões, utilizando computadores. O SR possibilita uma visão sinóptica e panorâmica de uma dada região e condições homogêneas para observação de fenômenos. É uma forma eficaz de monitoramento em escala global e local, pois possibilita rapidez e periodicidade no fornecimento de imagens e informações. (CENTENO, 2004; JENSEN 2009; ROSA 2005).

Dentre os produtos do SR encontram-se as imagens digitais, que são representações bidimensionais constituídas por um arranjo de elementos discretos (*pixel*), sob a forma de matrizes de linha e coluna. Elas possuem características que determinam o teor de suas informações, tais como, resolução espacial, espectral, radiométrica e temporal.

Conforme Centeno (2004) a resolução espectral refere-se ao número de faixas e sua largura, nas quais a radiação eletromagnética é medida, quanto maior o número de faixas e menor a largura delas, maior é a capacidade de se detectar diferenças espectrais entre os alvos. A resolução espacial é definida como a área unitária de terreno representada por um *pixel*. A radiométrica refere-se à quantidade de *bits* utilizados para armazenar os dados correspondentes a um *pixel*, ea resolução temporal é definida pelo intervalo de tempo em que uma mesma área é imageada consecutivamente.

Neste trabalho utilizou-se uma imagem do satélite Landsat5 TM, que é um satélite artificial de observação da Terra, com objetivo de coletar dados sobre os recursos naturais renováveis e não-renováveis. O satélite age com sensor

TM(*Thematic Mapper*), que opera em sete bandas espectrais, três na região do visível (bandas 1,2 e 3); três na região do infravermelho refletido (bandas 4,5 e 7); e uma na região termal (banda 6). A largura de faixa imageada é de 185 km e a resolução espacial do sensor nas bandas 1,2,3,4,5, e 7 é de 30 m x 30 m; e a da banda 6 é de 120 m x 120 m. O tempo de revisita de uma mesma área é de 16 dias. (MOREIRA, 2005).

Segundo Centeno (2004), uma forma de tornar a interpretação de imagens digitais mais simples é a classificação digital, que consiste em separar grupos de *pixels* com características espectrais semelhantes em classes ou categorias, pois *pixels* cobrindo um mesmo alvo devem ter características espectrais similares. Assim a classificação gera uma nova imagem resumida, na qual cada *pixel* está associado a uma classe.

Ribeiro (2001) menciona que a classificação tem como objetivo ordenar, discriminar e categorizar, baseando-se em características espectrais dos objetos. Essa é uma ferramenta bastante utilizada, visto que agiliza trabalhos e minimiza custos em mapeamentos temáticos.

Há duas formas de classificação digital de imagens: a não supervisionada, na qual o usuário só define as classes, e o algoritmo computacional executa a classificação; e a supervisionada, na qual o usuário define as classes e seleciona amostras puras e representativas de cada categoria, e o algoritmo calcula parâmetros estatísticos para executar a classificação.

Os métodos de classificação supervisionada se baseiam nos classificadores, que empregam as funções estatísticas ou outras regras de lógica para avaliar e comparar as características das reflectâncias espectrais dos *pixels*, com as características de uma determinada classe de padrão, para classificar e delinear as classes das imagens digitais. (LIU, 2007)

A amostragem é essencial para a classificação supervisionada, pois dela depende a qualidade da classificação. Portanto deve-se sempre coletar amostras puras e representativas que estejam distribuídas ao longo de toda a região, o que nem sempre é fácil, levando em consideração que podem ocorrer classes que apareçam na imagem de diferentes formas, ou ainda, há aquelas que apresentam confusão espectral como é o caso das categorias “urbana” e “solo exposto”.

O grande problema nesta classificação é obter amostras de *pixels* puros, representativos de cada classe espectral. É sabido, que a resposta espectral de um alvo contida numa área do terreno nunca é homogênea e exclusivamente aquele alvo. Geralmente ela é mascarada pela resposta espectral proveniente

da superfície de fundo ou de outros alvos dentro da área. (MOREIRA, 2005, p.287).

Após a coleta das amostras é necessário verificar a qualidade da amostragem, há diversas formas de fazer essa verificação, dentre elas a divergência transformada, que de acordo com JENSEN (*apud* ANTUNES, 2003, p.86):

[...] a divergência transformada expressa o decréscimo exponencial do peso para o aumento exponencial da distância entre as assinaturas. Os valores da divergência podem variar de 0 a 2000. Como regra geral, $TD_{ij} \geq 1900$ indica que classes podem ser bem separadas; entre $1700 \leq TD_{ij} \leq 1900$ a separação é boa a razoável e $TD_{ij} \leq 1700$ a separação pode ser bem deficitária ou não separável. (*apud* ANTUNES, 2003, p. 86).

Posteriormente, faz-se a classificação com os métodos escolhidos, neste trabalho são utilizados os métodos da Distância Mínima, Distância de Mahalanobis, Máxima Verossimilhança (MAXVER) e *Support Vector Machine* (SVM), que descrever-se-á a seguir:

Distância Mínima: O método de distância mínima não usa uma matriz de covariância, calcula para cada *pixel* a distância entre o *pixel* e cada uma das classes, comparando os valores das distâncias. Classifica-se o *pixel* como membro da classe mais próxima, ou seja, cuja média seja mais próxima a ele. (CENTENO, 2004)

A desvantagem deve-se à dispersão dos valores de reflectância em torno das médias.

Método da Máxima Verossimilhança (MAXVER): Segundo Richards (1993) a classificação supervisionada mais utilizada é a MAXVER. Baseia-se no princípio de que a classificação errada de um *pixel* particular não tem mais significado do que a classificação errada de qualquer outro *pixel* na imagem. Centeno (2004, p. 188) explicita que “o *pixel* x pertence à classe w_j se a probabilidade que associa este *pixel* à classe w_j é maior que a probabilidade que associa o *pixel* a qualquer outra classe: $x \in w_j$ se $p(w_j | x) > p(w_k | x) \forall k \neq j$ ”.

O MAXVER utiliza a média das respostas espectrais de cada classe das amostras de treinamento nas diferentes bandas, assim define a classe mais provável para cada *pixel*, dentre as classes existentes, utilizando o conceito de probabilidade condicional. Dessa forma, cada *pixel* tem sua probabilidade de pertencer a cada classe testada, e a categoria de maior probabilidade recebe o *pixel* (CENTENO, 2004).

A desvantagem do MAXVER é o uso exclusivo do atributo espectral para a separação dos *pixels* e a subjetividade presente no processo de coleta das amostras de treinamento, que é efetuada segundo o critério do analista. (MOREIRA, 2011).

Método da Distância de Mahalanobis: O classificador da Distância de Mahalanobis é similar ao da Distância Mínima, e usa estatísticas para cada classe. Entretanto, ele supõe que a covariância das amostras são iguais. Portanto, é um classificador ainda mais rápido que o método de Mínima Distância. Além da dispersão de dados em cada banda, leva em consideração a correlação entre bandas, ao incluir elementos de covariância. (CENTENO, 2004; ENVI, 2000).

Método de Aprendizado de Máquina (*Support Vector Machine* – SVM): Segundo Nascimento ET AL (2009) o SVM, esse método consiste em uma técnica computacional de aprendizado, para problemas de reconhecimento de padrão, e baseia-se no princípio de separação ótima entre classes, de modo que, se as classes são separáveis, a solução é escolhida de forma a separar ao máximo as classes.

Os algoritmos de aprendizagem de máquina (*Support Vector Machine*) têm como objetivo a determinação de limites de decisão que produzam uma separação ótima entre classes por meio da minimização dos erros (VAPNIK, 1995 apud NASCIMENTO, 2009, p. 2).

Depois de realizada a classificação, necessita-se examinar sua qualidade. Uma das maneiras é mediante a matriz de confusão, que é uma matriz quadrada de números que expressam a quantidade de unidades amostrais; associada a uma dada categoria durante o processo de classificação efetuado, e a categoria real a que pertencem essas unidades (MANGABEIRA et. al, 2003).

Conforme Centeno (2004), em uma condição ideal na qual todos os *pixels* são classificados corretamente, a matriz só apresenta valores nas diagonais. No entanto, isso raramente acontece, e o número de *pixels* incorretos é o total que se localiza fora da diagonal principal. Sendo assim, calcula-se a estimativa global da qualidade, somando os valores da diagonal principal dividido pelo total de *pixels* da amostra.

Segundo Antunes (1997), a avaliação da acurácia pode ser obtida por meio de coeficientes de concordância. Sendo um dos mais utilizados o coeficiente *Kappa*:

Cohen (1960) define *Kappa* como um coeficiente de concordância para escala nominais que pede a proporção de concordância depois que a concordância atribuída a casualidade é retirada de consideração. O coeficiente *Kappa* considera todos os elementos da matriz de erros ao invés de apenas aqueles que se situam na diagonal principal da mesma. O

coeficiente Kappa mede o grau de concordância em escalas nominais assumindo que:

As unidades são independentes; As classes ou categorias da escala nominal são independentes e mutuamente exclusivas; O classificador e os pontos de referência operam de forma independente. (COHEN apud ANTUNES, 1997, p. 9-10)

Richards (1993) expõe que a análise orientada a objetos ou segmentação, constitui-se de um processo em que uma imagem é subdividida em partes ou objetos constituintes, fundamentado em alguma característica própria da imagem, como intensidade média, contraste ou textura. É uma técnica que particiona a imagem em objetos, de acordo com características espectrais e espaciais da imagem, gerando nova imagem com regiões as quais são descritas mediante seus atributos espaciais, como área, forma, compacidade, alongamento, convexidade, etc; e espectrais, tais como, saturação, intensidade, brilho, entre outros.

Os atributos espectrais estão vinculados às características dos pixels (brilho e cor) que estão inseridos no segmento chamados de descritores. Os atributos de forma possuem características geométricas que podem ser traduzidas em forma de comprimentos, áreas ou relações matemáticas entre medidas do segmento, e buscam representar a forma do objeto (polígono) matematicamente, de modo que o computador possa interpretar. (PRICHOA, 2012)

A segmentação é realizada em duas etapas, reguladas por dois índices percentuais: Scale Level (SL) e Merge Level (ML). O Scale Level realiza a segmentação em si, e o percentual Merge Level apura os segmentos.

METODOLOGIA

No site do INPE (Instituto Nacional de Pesquisas Espaciais) adquiriu-se, gratuitamente, uma cena do satélite Landsat5, sensor TM, órbita 72, de 29 de abril de 2009, que abrange o município de Castro-Paraná. Utilizaram-se as bandas 1, 2, 3, 4, 5 e 7, as quais possuem resolução espacial de 30 metros e radiométrica de 8bits; e temporal de 16 dias.

Mediante a análise visual da imagem e de conhecimento a campo, definiram-se seis classes, sendo elas: vegetação, área urbana, solo exposto, agricultura, corpos d'água e classe não definida.

Para elaborar a classificação supervisionada foi realizada a coleta das amostras, a verificação da qualidade dessas com a divergência transformada e escolhido os métodos de classificação supervisionada supracitado, realizou-se a matriz de confusão e coeficiente *Kappa*, para verificar da acuracidade das classificações.

Para a segmentação das bandas espectrais da cena de Castro, de acordo com a análise orientada a objeto, utilizam-se dois parâmetros, a saber, escala e fusão, ambas analisadas visualmente. A escala define o tamanho das regiões ou objetos, sendo a mais apropriada neste estudo a de valor 20; e a fusão (merge) possibilita que os objetos sejam fundidos, refinando a definição dos objetos realizados com determinada escala, nesse caso o melhor valor para a fusão foi de 10.

Após a segmentação foram exportados para um programa de SIG (Sistema de Informação Geográfica) os vetores gerados, a fim de analisar os atributos espaciais, compacidade, convexidade e alongamento; e comparar as classificações.

RESULTADOS E DISCUSSÃO

Como mencionado anteriormente, um dos passos para a classificação supervisionada é a coleta de amostras de treinamento e a verificação dessas por meio da divergência transformada. As tabela 1 e 2 mostram o número de amostras adquiridas para cada classe e a divergência transformada.

Verifica-se que há separação deficitária com a classe sombra e corpos hídricos, isso porque a separabilidade espectral entre as duas categorias não é bem definida, os níveis digitais de ambas são parecidos, provocando confusão espectral. Outro problema é a dificuldade de coleta de amostras para a classe sombra. As categorias solo exposto e área urbana também não apresentam uma boa separabilidade, pois há confusão espectral, devido à semelhança entre os níveis digitais de ambas. Nas demais classes houve separabilidade boa, chegando à proximidade a 2,0.

Classes	Nº de Amostras
Solo exposto	186
Urbana	178
Vegetação	180
Agricultura	180
Corpos hídricos	181

Classe não definida	178
Sombra	71

Tabela 1 – número de amostras de treinamento para cada classe

Divergência Transformada		
Corpos hídricos - Sombra	1,6031	Separação Deficitária
Solo exposto - Urbana	1,8120	Separação Razoável
Corpos hídricos - Classe não definida	1,9452	Separação Boa
Vegetação - Sombra	1,9636	Separação Boa
Vegetação - Corpos hídricos	1,9663	Separação Boa
Classe não definida - Sombra	1,9778	Separação Boa
Vegetação - Agricultura	1,9856	Separação Boa
Agricultura - Classe não definida	1,9889	Separação Boa
Vegetação - Classe não definida	1,9960	Separação Boa
Solo exposto - Corpos hídricos	1,9960	Separação Boa
Urbana - Corpos hídricos	1,9992	Separação Boa
Agricultura - Corpos hídricos	1,9994	Separação Boa
Solo exposto - Sombra	1,9994	Separação Boa
Urbana - Classe não definida	1,9996	Separação Boa
Urbana - Agricultura	1,9999	Separação Boa
Urbana - Agricultura	1,9996	Separação Boa
Urbana - Sombra	1,9999	Separação Boa
Solo exposto - Agricultura	1,9999	Separação Boa
Solo exposto - Vegetação	1,9999	Separação Boa
Agricultura - Sombra	1,9999	Separação Boa
Urbana - Vegetação	1,9999	Separação Boa

Tabela 2 – divergência transformada das amostras de treinamento

Depois de realizada as classificações, coletaram-se novas amostras de treinamento, para verificar a acuracidade da classificação pelo índice *kappa* e matriz de confusão. A tabela 3 mostra a divergência transformada das novas amostras.

Divergência Transformada para Matriz de Confusão e Índice <i>Kappa</i>		
Corpos hídricos - Sombra	1,690	Separação Deficitária
Solo exposto - Urbana	1,848	Separação Razoável
Corpos hídricos - Classe não definida	1,997	Separação Boa
Vegetação - Sombra	1,934	Separação Boa
Vegetação - Corpos hídricos	1,997	Separação Boa
Classe não definida - Sombra	1,999	Separação Boa
Vegetação - Agricultura	1,996	Separação Boa
Agricultura - Classe não definida	1,998	Separação Boa

Vegetação - Classe não definida	1,999	Separação Boa
Solo exposto - Corpos hídricos	2,000	Separação Boa
Urbana - Corpos hídricos	2,000	Separação Boa
Agricultura - Corpos hídricos	2,000	Separação Boa
Solo exposto - Sombra	2,000	Separação Boa
Urbana - Classe não definida	1,996	Separação Boa
Urbana - Agricultura	2,000	Separação Boa
Solo exposto - Classe não definida	2,000	Separação Boa
Urbana – Sombra	2,000	Separação Boa
Solo exposto - Agricultura	2,000	Separação Boa
Solo exposto - Vegetação	2,000	Separação Boa
Agricultura - Sombra	2,000	Separação Boa
Urbana - Vegetação	2,000	Separação Boa

Tabela 3 – divergência transformada da amostragem para verificação de acuracidade

O classificador Distância Mínima, obteve na matriz de confusão acurácia global de 85,44% e o coeficiente *kappa* apresentou índice de 0,83, sendo os menores resultados comparados aos outros métodos de classificação, conforme mostra a tabela 4. No entanto, a classe agricultura teve 98,89% de acerto na matriz de confusão (tabela 5).

O método da Máxima Verossimilhança (MAXVER) teve acerto global de 98,61% na matriz de confusão e o índice do coeficiente *kappa* obteve 0,98, os maiores valores comparados aos outros métodos (tabela 4). Teve acurácia na matriz de confusão de 100% para as classes: agricultura, vegetação e classe não definida; e o percentual mais baixo foi para a classe sombra, com 95,77%, (tabela 6). No entanto, observando a imagem visualizou-se que há confusão entre a classe sombra e corpos hídricos; e também entre urbana e o solo exposto (figura 1- imagem B).

No método Distância de Mahalanobis, a matriz de confusão obteve acuracidade de 92,11% e 0,91 no índice *kappa* (tabela 4). O melhor percentual na matriz de confusão foi para a classe não definida e os piores para as categorias agricultura (85,56%), corpos hídricos (85,64%) e sombra (88,73%), como mostra a tabela 7.

O algoritmo *Support Vector Machine* obteve acurácia global de 97,92%, na matriz de confusão (tabela 4) e 100% para as categorias de vegetação e agricultura. O percentual mais baixo nesse classificador foi para a classe sombra, de 90,14% (tabela 8). No índice *kappa* o resultado foi de 0,9755 (tabela 4). Verifica-se que esse método foi o que menos apresentou sobreposição entre as classes solo exposto e urbana (figura 1 – imagem D).

Métodos de Classificação	Matriz de Confusão (%)	Kappa
MaxVer	98,6135	0,9837
Support Vector Machine	97,9203	0,9755
Distância de Mahalanobis	92,1144	0,9073
Distância de Mínima	85,4419	0,8293

Tabela 4 – Acuracidade das classificações pelo método matriz de confusão e índice kappa.

Matriz de Confusão (%) - Distância Mínima							
Classes	Solo exposto	Urbana	Vegetação	Agricultura	Corpos hídricos	Área não definida	Sombra
Não Classificado	0	0	0	0	0	0	0
Solo exposto	61,83	17,98	0	0	0	2,81	0
Urbana	20,43	81,46	0	0	0	0	0
Vegetação	0	0	98,89	0	1,10	0	0
Agricultura	0	0	0	96,67	0	0	0
Corpos hídricos	0	0	0	0	75,14	0	5,63
Área não definida	17,74	0,56	0	3,33	0	97,19	2,82
Sombra	0	0	1,11	0	23,76	0	91,55
TOTAL	100	100	100	100	100	100	100

Tabela 5 – Matriz de confusão do método de classificação Distância Mínima

Matriz de Confusão (%) - MAXVER							
Classes	Solo exposto	Urbana	Vegetação	Agricultura	Corpos hídricos	Classe não definida	Sombra
Não Classificado	0	0	0	0	0	0	0

Solo exposto	95,7	0,56	0	0	0	0	0
Urbana	4,30	99,44	0	0	0	0	0
Vegetação	0	0	100	0	0	0	0
Agricultura	0	0	0	100	0	0	0
Corpos hídricos	0	0	0	0	97,79	0	2,82
Área não definida	0	0	0	0	0	100	1,41
Sombra	0	0	0	0	2,21	0	95,77
TOTAL	100	100	100	100	100	100	100

Tabela 6 – Matriz de confusão do método de classificação Máxima Verossimilhança (MAXVER)

Matriz de Confusão (%) - Distância de Mahalanobis							
Classes	Solo exposto	Urbana	Vegetação	Agricultura	Corpos hídricos	Classe não definida	Sombra
Não Classificado	0	0	0	0	0	0	0
Solo exposto	94,09	3,93	0	0	0	0	0
Urbana	2,69	95,51	0	0	0	0	0
Vegetação	0	0	96,11	7,78	2,21	1,69	2,82
Agricultura	0	0	0,56	85,56	0	0	0
Corpos hídricos	0	0	0	0	85,64	0	2,82

Área não definida	3,23	0,56	2,22	6,67	2,76	97,19	5,63
Sombra	0	0	1,11	0	9,39	1,12	88,73
TOTAL	100	100	100	100	100	100	100

Tabela 7 – Matriz de confusão do método de classificação Distância de Mahalanobis

Matriz de Confusão (%) - SUPPORT VECTOR MACHINE							
Classes	Solo exposto	Urbana	Vegetação	Agricultura	Corpos hídricos	Classe não definida	Sombra
Não Classificado	0	0	0	0	0	0	0
Solo exposto	95,7	2,81	0	0	0	0	0
Urbana	4,3	97,19	0	0	0	0	0
Vegetação	0	0	100	0	0	0	0
Agricultura	0	0	0	100	0	0	0
Corpos hídricos	0	0	0	0	97,79	0	7,04
Área não definida	0	0	0	0	0	100	2,82
Sombra	0	0	0	0	2,21	0	90,14
TOTAL	100	100	100	100	100	100	100

Tabela 8 – Matriz de confusão do método de classificação *Support Vector Machine* (SVM)

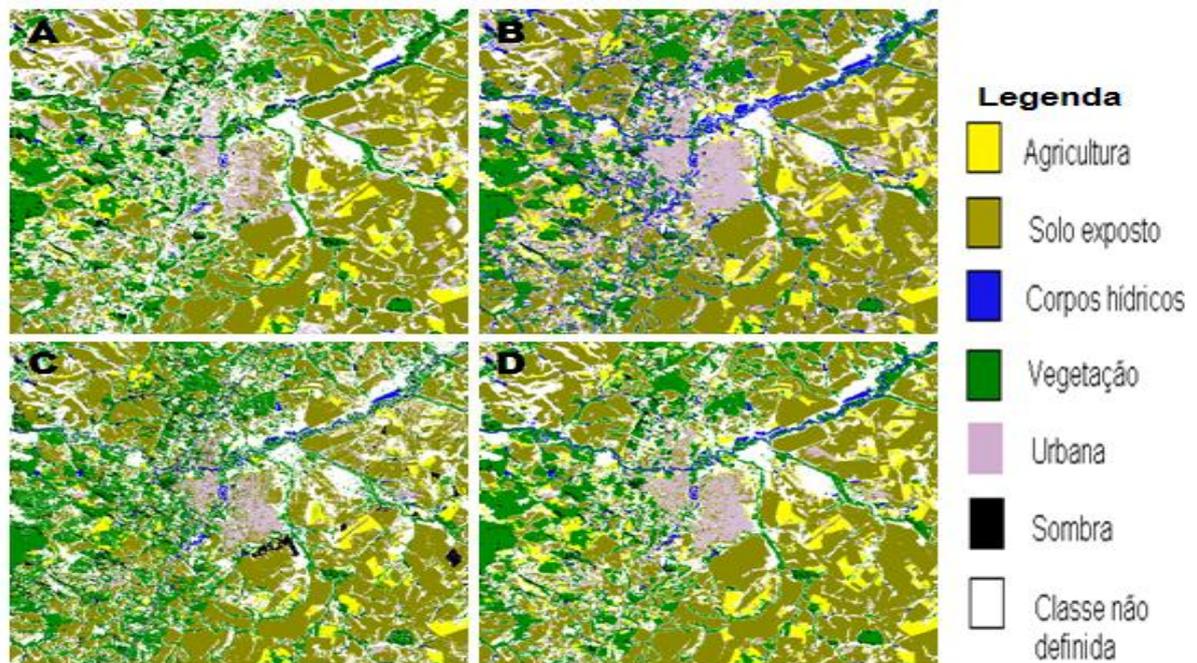


FIGURA 1 - IMAGENS CLASSIFICADAS: A) DISTÂNCIA MÍNIMA B) MAXVER C) DISTÂNCIA DE MAHALANOBIS D) SUPPORT VECTOR MACHINE

Foram comparados alguns atributos espaciais da segmentação (tabela 9), sendo eles a compacidade, convexidade, alongamento e área. A figura 2 mostra os quatro polígonos escolhidos para a comparação, todos eles são da classe agricultura.

Quanto ao atributo “área”, que é descrita em metros quadrados, os métodos Support Vector Machinee Maxima Verossimilhança obtiveram valores bastante parecidos no polígono um e também foram os classificadores que tiveram maior acuracia na classe agricultura, conforme mostrado nas matrizes de confusão.

O atributo convexidade refere-se ao quanto os polígonos têm de curvatura, o de compacidade ao grau de solidez e ao alongamento a forma alongada que esses apresentam.

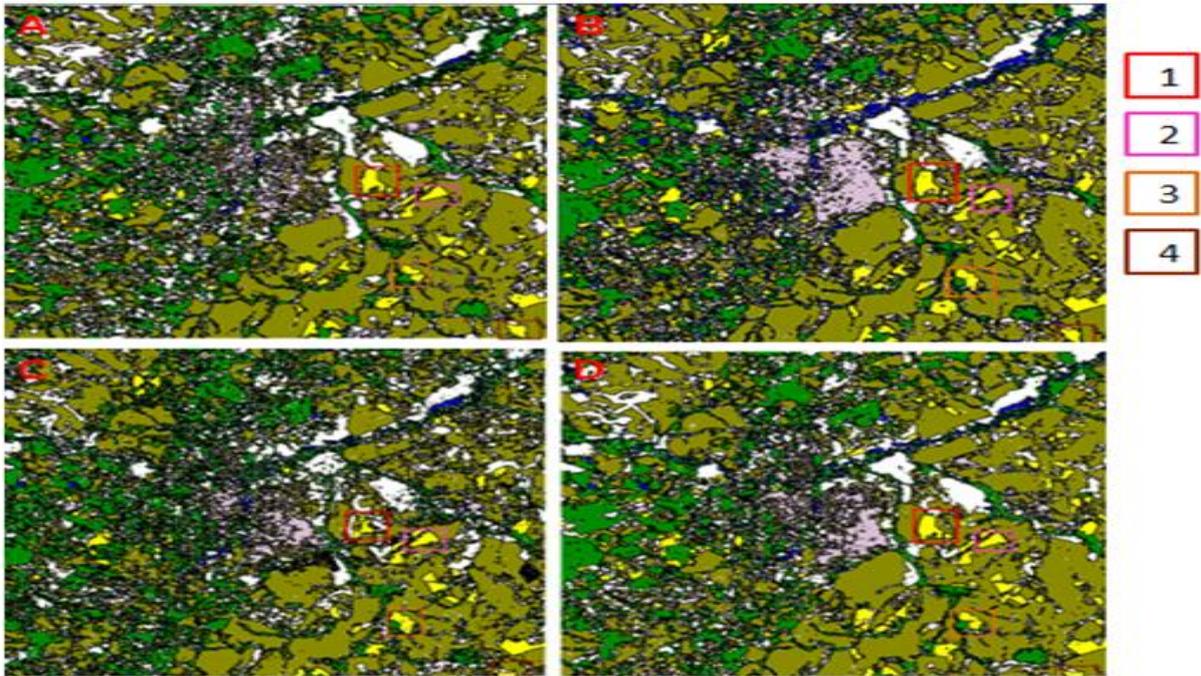


FIGURA 2 – IMAGENS CLASSICADAS E SEGMENTADAS COM OS POLÍGONOS IDENTIFICADOS – A) MÍNIMA DISTÂNCIA B) MAXIMO VEROSSIMILHANÇA (MAXVER) C) DISTÂNCIA DE MAHALANOBIS D) SUPPORT VECTOR MACHINE.

Atributos	Polígono	Métodos de Classificação Digital Supervisionada			
		Distancia de Mahalanobis	MAXVER	Distância Mínima	Support Vector Machine
Área	1	424.800	606.300	553.950	607.050
	2	290.250	283.500	297.300	318.600
	3	369.900	380.700	309.150	348.300
	4	259.650	252.000	248.400	267.750
Compacidade	1	0,17	0,18	0,2	0,19
	2	0,20	0,21	0,24	0,23
	3	0,21	0,20	0,23	0,21
	4	0,21	0,21	0,22	0,24
Convexidade	1	1,38	1,37	1,25	1,31
	2	1,21	1,15	1,02	1,08
	3	1,17	1,23	1,13	1,24
	4	1,20	1,15	1,15	1,09
Alongamento	1	1,28	1,55	1,60	1,41
	2	1,52	1,47	1,78	1,55
	3	1,91	1,95	1,40	1,87
	4	1,44	1,88	1,59	1,55

Tabela 9 – Atributos da segmentação

CONSIDERAÇÕES FINAIS

Na ciência geográfica é pertinente o estudo de técnicas do sensoriamento remoto, uma vez que os produtos de sensoriamento remoto possibilitam o desenvolvimento de pesquisas e subsidiam tomadas de decisões.

O trabalho objetivou o estudo de técnicas de classificação digital supervisionada. Os quatro métodos aqui mostrados, Distância Mínima, Máxima Verossimilhança, Distância de Mahalanobis, e *Support Vector Machine*, tiveram resultados aceitáveis, no entanto cada classificador possui melhor e pior resultados em algumas classes, necessitando-se verificar divergências em campo.

A análise orientada a objeto possibilita a geração de tabelas com atributos espaciais e espectrais. Neste estudo os espectrais não foram analisados, pois a segmentação foi realizada com imagens classificadas, portanto esses dados foram modificados. Isso também gera vetores de cada polígono das regiões, sendo possível adquirir informações sobre área, compacidade e convexidade de cada um.

REFERÊNCIAS

ANTUNES, A. F. B.; Lingnau, C. Uso dos Índices de Acurácia para Avaliação de Mapas temáticos obtidos por meios de classificação digital. In: **Congresso e Feira para Usuário de geoprocessamento**, 3.ed, Curitiba: Sagres, 1997.

ANTUNES, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. (Doutorado em Ciências Geodésicas). Curitiba: UFPR. 2003, p.147.

CENTENO, J. A. S. **Sensoriamento remoto e processamento de imagens digitais**. Curitiba – PR: Ed. Curso de Pós Graduação em Ciências Geodésicas, Universidade Federal do Paraná, 2004, p.219.

EASTMAN, J. R. **IDRISI for Windows: User's guide**. Massachusetts: Clark University, 1999, p. 367.

ENVI - Guia do ENVI em Português. Sulsoft, 2000. Disponível em: www.sulsoft.com.br. Acesso em: 23 de agosto de 2012.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução de José Carlos Neves Epiphânio. São José dos Campos: Parêntese, 2009, p.598.

LIU, W. T. H. **Aplicações de Sensoriamento Remoto**. Campo Grande: Uniderp, 2007, p.908.

MANGABEIRA, J. A. C., AZEVEDO, E. C., LAMPARELLI, R. A. C. **Avaliação do levantamento do uso das terras por imagens de satélite de alta e média resolução espacial.** Comunicado técnico 11. Campinas: Embrapa, 2003, p.15.

MOREIRA, M. A. **Fundamentos de sensoriamento remoto e metodologias de aplicação.** 4. Ed. Viçosa: Ed. UFV, 2011, p.422.

NASCIMENTO, R. F. F.; ALCÂNTARA, E. H.; KAMPEL, M.; STECH, J. L.; NOVO, E. M. L. M.; FONSECA, L. M. G. O algoritmo Support Vector Machines (SVM): avaliação da separação ótima de classes em imagens CCD-CBERS-2. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 2079-2086. DVD, On-line. ISBN 978-85-17-00044-7. (INPE-15957-PRE/10566). Disponível em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2008/10.20.10.59>>. Acesso em: 24 de agosto de 2005, p.81-90.

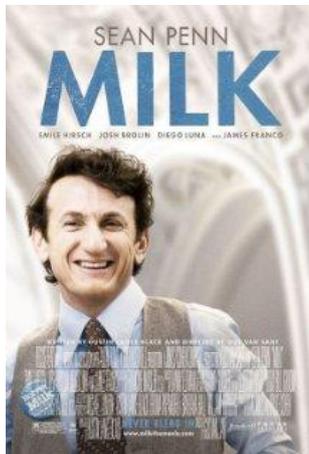
PRICHOA, Carla Eva. **ESTUDO EM DUAS UNIDADES DE PAISAGEM DA BACIA HIDROGRÁFICA DO RIO PITANGUI/PR MEDIANTE ESTATÍSTICA MULTIVARIADA E ANÁLISE ORIENTADA A OBJETOS.** 2012. 138 f. Dissertação (Mestre) - Uepg, Ponta Grossa-pr, 2012. Cap. 3.

RIBEIRO, Selma Regina Aranha. **Integração de imagens LandsatTm e dados auxiliares para a delimitação de unidades fisionômicas usando redes neurais artificiais.** 2003. 300 f. Tese (Doutorado) - UFPR, Curitiba, 2003.

RICHARDS, J. A. **Remote sensing digital imageanalysis- anintroduction.** 2.ed. Springer-Verlag, Berlin, 1993, p.28.

ROSA, R. **Geotecnologias na Geografia Aplicada.** Revista do Departamento de Geografia, 16

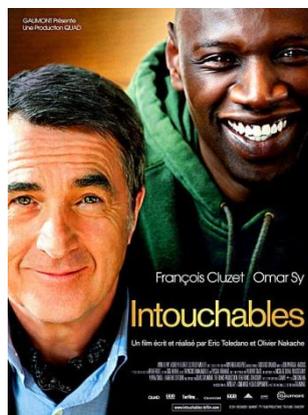
PET- Indica



FILME

“Milk - A Voz da Igualdade” é a cinebiografia de Harvey Milk (1930-1978), político norte-americano que assumiu sua homossexualidade publicamente nos anos 70, sendo o primeiro homossexual assumido a ser eleito a um cargo público nos Estados Unidos. No ano seguinte, Milk foi assassinado por um adversário de carreira política desconsolado com a perda nas urnas.

http://www.imbui.com.br/colunas/prg_col_exi.cfm?id=559



“Os Intocáveis” é uma excelente oportunidade para a reflexão e o entretenimento. É um momento que oportuniza ao espectador internalizar as emoções de uma história tocante de amor e amizade. Somada a um humor sutil e cheio de sensibilidade, a história se passa na cidade de Paris, que apesar de ricamente retratada pela fotografia do filme, não é evidenciada da forma como a conhecemos. Aqui, os cenários retratam a dualidade de dois mundos opostos: o de Dryss, jovem marginalizado interpretado pelo artista francês Omar Sy, e o do aristocrata Philippe, interpretado por François Cluzet, conhecido por sua atuação em “Um novo caminho” (2009) e “Até a eternidade” (2010), entre outros.

<http://filmesetal.net/2012/08/16/review-os-intocaveis-2012/>

EVENTOS

XII Simpósio de Geografia da UDESC: Formação do educador-pesquisador em Geografia: incursões no contemporâneo

Data: 8 a 11 de outubro de 2012

Local: Centro de Ciências Humanas e da Educação - UDESC

Informações: 2012simgeo@gmail.com

IX SINAGEO – Geomorfologia e Eventos Catastróficos: passado, presente e futuro

Data: 21 a 24 de outubro de 2012

Local: Rio de Janeiro, RJ

Informações: <http://www.sinageo.org.br/>

XXI ENGA – Encontro Nacional de Geografia Agrária

Data: 15 a 19 de outubro de 2012

Local: Universidade Federal de Uberlândia

Informações: <http://www.ig.ufu.br/node/205>

IV ENCONTRO INTERNACIONAL DE GEOGRAFIA DA SAÚDE

Data: 15 a 18 de novembro de 2012

Local: Presidente Prudente - FCT-UNESP

Informações: www.fct.unesp.br/#45,2226

X SIMPÓSIO BRASILEIRO DE CLIMATOLOGIA GEOGRÁFICA

Data: 19 a 23 de novembro de 2012

Local: Manaus - UFAM

Informações: www.xsbcg.com

