

Classificação de imagens de sensoriamento remoto pela aprendizagem por árvore de decisão: uma avaliação de desempenho

Marcelo Hiroshi Shiba¹
Rosangela Leal Santos^{2,3}
José Alberto Quintanilha²
Hae Yong Kim¹

¹ Universidade de São Paulo - Escola Politécnica - PSI
Av. Prof. Luciano Gualberto, tr. 3, 158, CEP 05508-900, São Paulo, SP, Brasil
marcelo.shiba@poli.usp.br, hae@lps.usp.br

² Universidade de São Paulo - Escola Politécnica - PTR
Caixa Postal 92 - CEP.: 05508-900 – São Paulo - SP, Brasil
{rosaleal, jaquinta}@usp.br

³ Universidade Estadual de Feira de Santana – UUEFS/TEC
Av. Universitária, BR-116, Km 3 - CEP.: 44031-460 - Feira de Santana - BA, Brasil

Abstract. In the literature, there are many different classification methods that can divide a set of data into small groups, so that each group present similar characteristics. The decision tree is one of these methods. This paper applies the decision tree learning technique to classification of remote sensing data, and compare its performance with the Maximum Likelihood Classifier, one of the most popular classification methods in remote sensing.

Keywords: remote sensing, image processing, decision tree, supervised classification.

Palavras-chave: sensoriamento remoto, processamento de imagens, árvore de decisão, classificação supervisionada.

1. Introdução

Na classificação supervisionada, são utilizadas as técnicas de aprendizagem de máquina para a extração de informações a partir de conhecimento *a priori* do usuário. Os algoritmos utilizados variam de acordo com a aplicação e a estrutura de dados escolhida. Este trabalho visa a estudar a possibilidade de aplicação da aprendizagem pela árvore de decisão na classificação de imagens de sensoriamento remoto, comparando-o com a técnica de Máxima Verossimilhança (Maxver). Primeiro, fazemos um breve estudo teórico das situações onde a árvore de decisão poderia fornecer uma classificação mais acurada que Maxver. Depois, avaliamos uma implementação da árvore de decisão, da biblioteca de programas de processamento de imagens IMG. O IMG é um sistema de domínio público, desenvolvido por Kim (2004). Este sistema permite, entre outras funcionalidades, realizar a classificações de imagens digitais através de um algoritmos de árvore de decisão. Acreditamos que este sistema pode ser útil para as aplicações de sensoriamento remoto, devido à sua simplicidade e à capacidade de processar grande volume de dados. Como base de comparação, utilizamos a implementação do algoritmo Maxver do software SPRING (Camara et al., 1996).

2. Árvore de decisão e Maxver

2.1 Maxver

Maxver é a técnica classificação supervisionada mais popular para tratamento de dados satélites. Este método é baseado no princípio de que a classificação errada de um pixel particular

não tem mais significado do que a classificação incorreta de qualquer outro pixel na imagem (Richards, 1993). O usuário determina a significância nos erros de atributos especificados para uma classe em comparação a outras.

A eficácia do Maxver depende, principalmente, de uma precisão razoável da estimativa do vetor médio e da matriz de covariância de toda classe espectral. Isso depende da quantidade de pixels incluídos nas amostras de treinamento. O resultado do Maxver é tanto melhor quanto maior o número de pixels numa amostra de treinamento para implementá-los na matriz de covariância (Previdelli, 2004).

Nas classificações em que se usa o algoritmo Maxver, cada classe é determinada por um modelo de classes gaussiano e multivariado, capaz de descrever a distribuição das classes no espaço de atributos. Este modelo leva em conta as extensões de dados em direções espectrais determinadas. No espaço RGB, elipsóides concêntricas de equi-probabilidade, cuja localização, forma e tamanho refletem a média variância a covariância da classe, determinam a probabilidade do pixel pertencer à classe. Crósta (1993) considera que o método Maxver deve ser aplicado quando o analista conhece bem a imagem a ser classificada, para que possa definir classes que sejam representativas.

2.2 Árvore de decisão

Amplamente utilizadas em algoritmos de classificação, as árvores de decisão são representações simples do conhecimento e um meio eficiente de construir classificadores que predizem classes baseadas nos valores de atributos de um conjunto de dados.

As árvores de decisão consistem de nodos que representam os atributos; de arcos, provenientes destes nodos e que recebem os valores possíveis para estes atributos; e de nodos folha, que representam as diferentes classes de um conjunto de treinamento (Ingargiola, 1996). Classificação, neste caso, é a construção de uma estrutura de árvore, que pode ser usada para classificar corretamente todos os objetos do conjunto de dados da entrada (Brazdil, 1999).

Muitos são os algoritmos de classificação que constroem árvores de decisão. Não há uma forma de determinar qual é o melhor algoritmo, um pode ter melhor desempenho em determinada situação e outro algoritmo pode ser mais eficiente em outros tipos de situações.

Após a construção de uma árvore de decisão é importante avaliá-la. Esta avaliação é realizada através da utilização de dados que não tenham sido usados no treinamento. Esta estratégia permite estimar como a árvore generaliza os dados e se adapta a novas situações, podendo, também, se estimar a proporção de erros e acertos ocorridos na construção da árvore (Brazdil, 1999).

A partir de uma árvore de decisão é possível derivar regras. As regras são escritas considerando o trajeto do nodo raiz até uma folha da árvore. Estes dois métodos são geralmente utilizados em conjunto. Devido ao fato das árvores de decisão tenderem a crescer muito, de acordo com algumas aplicações, elas são muitas vezes substituídas pelas regras. Isto acontece em virtude das regras poderem ser facilmente modularizadas. Uma regra pode ser compreendida sem que haja a necessidade de se referenciar outras regras (Ingargiola, 1996).

Uma árvore de decisão tem a função de particionar recursivamente um conjunto de treinamento, até que cada subconjunto obtido deste particionamento contenha casos de uma única classe. Para atingir esta meta, a técnica de árvores de decisão examina e compara a distribuição de classes durante a construção da árvore. O resultado obtido, após a construção de uma árvore de decisão, são dados organizados de maneira compacta, que são utilizados para classificar novos casos (Holsheimer & Siebes, 1994; Brazdil, 1999).

A árvore de decisão não assume nenhum modelo estatístico *a priori*, sendo a divisão do espaço de atributos feita de acordo com as amostras provenientes do treinamento. Assim, no espaço RGB, as classes são separadas por planos que as delimitam.

2.3 IMG

O sistema IMG consiste de:

- a) Biblioteca-IMG: um conjunto de classes, rotinas e “operadores sobrecarregados” para processamento de imagens (PI) escrito em C++;
- b) Programas-IMG: um conjunto de programas para PI escritos utilizando as rotinas acima.

A finalidade do Sistema IMG é fornecer meios para testar rapidamente novos algoritmos de PI. A sua interface com o usuário é pouco amigável e os comandos são dados na janela de prompt do DOS (comandos de linha).

O algoritmo de árvore de decisão da biblioteca do sistema foi desenvolvido para trabalhar com imagens tridimensionais, através do modelo de cores RGB, que pode ser encontrada em qualquer tecnologia que utilize o modelo aditivo.

No processamento de imagens, através desta biblioteca, os componentes da imagem digital colorida é fracionado nos três canais de cores. Portanto, neste sistema, as imagens de sensoriamento remoto podem ser trabalhadas em 3 bandas, uma em cada canal.

2.4 Maxver × árvore de decisão

Neste trabalho, destacamos a hipótese de que a classificação por árvore de decisão pode obter um melhor resultado que a classificação por Maxver, para os casos em que os pixels das classes não são “bem comportados”, isto é, não obedecem a uma distribuição gaussiana, como nos casos em que existem duas respostas espectrais distintas para uma mesma classe ou a “fronteira” das classes se emaranham no espaço de atributo. Algumas possíveis configurações, num plano bidimensional, que poderiam ser melhor classificadas pela árvore de decisão do que por Maxver são esquematizadas abaixo (**Figura 1**):




Figura 1: Configurações onde árvore de decisão classifica com melhor acuracidade que Maxver.

3. Materiais e métodos

3.1 Materiais

Utilizamos os seguintes materiais nos nossos testes:

- Sistema IMG para a classificação por árvore de decisão (Kim, 2004);
- Software Spring 4.0 para a classificação por Maxver (Camara et al., 1996);
- Imagens Landsat ETM 7 – Rondônia;
- Imagens Landsat ETM 7 –Esplanada/BA (2002).

3.2 Métodos

Foram realizados três processamentos com objetivos diferentes.

3.2.1 Teste preliminar – 1

Utilizou-se uma imagem do landsat ETM 7, da cidade de Porte Velho – RO (28/06/2000), com 7879×6959 pixels (colunas×linhas), numa composição colorida 5-4-3 (RGB). O objetivo deste teste era apenas avaliar a capacidade de classificação de imagens de sensoriamento remoto orbital pelo sistema IMG. Os testes indicaram que o IMG é capaz de classificar este tipo de imagem, como o Spring 4.0 que possui funções específicas para este tipo de processamento.

Os treinamentos de máquina de IMG e do SPRING são diferentes: IMG executa o treinamento através duas imagens, exemplo de entrada (**Figura 2a**) e exemplo de saída (**Figura 2b**); o SPRING executa iterativamente o treinamento através de amostras extraídas de regiões pertinentes a cada classe. Além disso, no IMG são necessárias duas etapas, uma de aprendizagem e outra de aplicação, e no SPRING, a aprendizagem e a aplicação ocorrem na mesma etapa. A fim de minimizar essas diferenças para uma comparação mais justa, no teste preliminar, foi utilizada uma “mesma região” para o treinamento de IMG e para a retirada de exemplos para o SPRING. Como se tratava apenas de testes preliminares, o exemplo de saída usado no treinamento de IMG foi gerado pelo SPRING, mas considerando-se apenas uma pequena região da imagem inteira. Isso acarretou uma limitação no treinamento de IMG; portanto, posteriormente, quando testes mais sólidos forem realizados, os treinamentos serão executados de forma a dar igualdade e independência para o treinamento de cada um (**Figuras 2c, 2d, 2e**).

3.2.2 Teste preliminar – 2

Utilizou-se um recorte da imagem do Landsat ETM 7, do município de Esplanada – BA (02/11/2002), da região litorânea, com 861×540 pixels (colunas×linhas) (**Figura 3a**). O objetivo deste teste era apenas separar duas classes distintas, água e não-água, comparando a velocidade e acuracidade de processamento áreas menores (**Figuras 3b e 3c**). Utilizamos as bandas 5-4-3 .

3.2.3 Teste preliminar – 3

Nesta etapa utilizou-se um outro recorte da imagem do Landsat ETM 7, do município de Esplanada – BA (02/11/2002), com 340×460 pixels (colunas×linhas). Desta vez, tinha-se como objetivo identificar 4 diferentes unidades de solos, 3 da classe Podzólico Amarelo e 1 do Podzólico Acinzentado, típicos dos Tabuleiros Costeiros, baseando-se em seu teor de umidade. Utilizou-se, para isso as bandas 7-5-2.



Figura 2a – exemplo de entrada para treinamento de IMG.




Figura 2b – exemplo de saída para treinamento de IMG.




Figura 2c – Imagem original.




Figura 2d – imagem classificada por Spring (tempo de processamento 150s).




Figura 2e – imagem classificada por IMG (tempo de processamento 30s)

Quadro 1 – Comparação entre pixels classificados como “Água” e “Não-Água”, utilizando-se os classificadores IMG e Maxver

Classificadores	Classes utilizadas	
	Água (Azul)	Não-Água (Vermelho)
IMG	259.459	204.941
Maxver	253.108	211.292



Figura 3a: Imagem Landsat ETM 7, Litoral Norte do Estado da Bahia (resolução de 30 m, bandas 5 – Red, 4 – Green, 3 - Blue)




Figura 3b: imagem classificada por árvore de decisão do IMG. Utilizou-se apenas 2 classes: água (azul) e não-água (vermelho).




Figura 3c: imagem classificada por Maxver do SPRING.

Quadro 2 – Matriz de erros de classificação (Maxver) para as classes “Água” e “Não-Água”

Colunas: dados de referências	Água		Não-Água		Abstenção		Σ Linha
	Absoluto	%	Absoluto	%	Absoluto	%	
Água	2579	42.11	16	0.26	0	0.00	2595
Não-Água	12	0.20	3518	57.44	0	0.00	3530
Σ Coluna	2591	-----	3534	-----	0	-----	6125

4. Resultados e Discussões

4.1 Teste preliminar – 1

O tempo exigido para o processamento de uma imagem através do programa de árvore de decisão da IMG é de aproximadamente 30 segundos, enquanto através do software SPRING (usando Maxver) é de aproximadamente 150 segundos. Além disso, a árvore de decisão con-

segue gerar partições complexas de espaço de cores, impossíveis de serem obtidas pelas partições elipsoidais do Maxver.

4.2 Teste preliminar - 2

A diferença entre os classificadores foi de aproximadamente 2,21% equivalente à 9841 pixels (**Quadro 1; Figura 3**). No **Quadro 2** apresentamos a matriz de erro da classificação do Maxver (**Figura 3c**), que apresentou um desempenho geral de 99,54% e uma confusão média de 0,46%. Baseados numa interpretação visual e na comparação de contagem e pixels, acreditamos que, para este caso, a classificação feita pelo IMG (**Figura 3b**) foi mais sensível às variações do teor de umidade do terreno que o Maxver, apresentando um maior número de pixels classificados como água.

4.3 Teste preliminar – 3

Nesta etapa, os resultados foram mais confusos, principalmente pela natureza da feição escolhida para classificar solos. O Maxver obteve um desempenho geral de apenas 66,10%, com uma confusão média de 33,90% (**Figura 4c**). O **Quadro 3** traz a matriz de erros da classificação para as 4 unidades de solos. Como o IMG não possui ainda uma rotina que gera uma matriz de erros, podemos somente comparar o número de pixels classificados com os das classes do Maxver. Verificou-se que o IMG gerou uma nova classe (em branco, na **Figura 4b**), com 15260 pixels, correspondente a quase 10% do geral de pixels da imagem, para a qual não foi treinada, diferentes das 4 esperadas (Pad – vermelho; Paf – amarelo; PA – laranja; PC – cinza). Esta nova classe surgiu devido a pixels conflitantes na imagem de treinamento, isto é, pixels que possuíam o mesmo valor de nível de cinza nas bandas 7, 5 e 2. Posteriormente, esse problema deve ser contornado e uma possível solução é adequar IMG para considerar a vizinhança do pixel conflitante, além de torná-lo apto a processar imagens multiespectrais.

5. Conclusão

Neste trabalho, fizemos um estudo teórico entre as técnicas de aprendizagem de Maxver e árvore de decisão. Argumentamos os casos em que a árvore de decisão poderia gerar uma classificação mais acurada que Maxver. Depois, testamos experimentalmente as implementações de árvore de decisão (IMG) e Maxver (Spring), na classificação de imagens de sensoriamento remoto.

O Spring não possui uma rotina de classificação por árvore de decisão. Sabe-se que existem outros softwares de sensoriamento remoto que possuem rotinas de classificação por árvore de decisão. Ainda não conhecemos detalhes desses softwares. Ao longo do projeto, pretendemos comparar esses softwares com IMG.

Sentimos a dificuldade de se obter uma imagem classificada idealmente, isto é, que seja fruto de um trabalho de campo. Tal imagem é necessária para poder calcular os erros cometidos pelos métodos de classificação. Entretanto, o procedimento comparativo das classificações proposto, mostrou-se satisfatório, por ter alcançado seu objetivo de avaliar o desempenho do sistema IMG. Este procedimento também expôs algumas deficiências que poderiam ser corrigidas, e apontou a necessidade de aperfeiçoamento deste sistema para ser aplicado especificamente na área de sensoriamento remoto de imagens multiespectrais.




Figura 4a - Imagem Landsat ETM 7, Figura 4b – Imagem classificada com a árvore de decisão do sistema IMG. Figura 4c – Imagem classificada com o Maxver (100%) (ver legenda no **Quadro 3**, na primeira coluna) composição colorida 7-5-2 (RGB). Detalhe para os polígonos amostrais das 4 unidades de solos

Figura 4 – Classificação da imagem Landsat 7 ETM com os algoritmos IMG e Maxver, para identificação de 4 unidades de solos.

Quadro 3 – Matriz de erros de classificação (Maxver) para 4 classes referentes a unidades de solos

Colunas: dados de referências	PAf		PA _d		PA		PC		Abstenção		Σ Linha
	Tot.	%	Tot.	%	Tot.	%	Tot.	%	Tot.	%	
PAf	381	38.21	68	6.82	29	2.91	1	0.10	0	0.00	479
PA_d	20	2.01	107	10.73	82	8.22	5	0.50	0	0.00	214
PA	47	4.71	50	5.02	98	9.83	4	0.40	0	0.00	199
PC	10	1.00	8	0.80	14	1.40	73	7.32	0	0.00	105
Σ Coluna	458	----	233	----	223	----	83	----	0		997

6. Agradecimentos

M. H. Shiba e H. Y. Kim agradecem à FAPESP, pela bolsa de Iniciação Científica do autor principal (processo 04/00258-9) e pelo apoio ao projeto POAMAE (processo 2003/13752-9).

7. Referências

BRAZDIL, P. Construção de Modelos de Decisão a partir de Dados. Disponível por WWW em: <http://www.ncc.up.pt/~pbrazdil/Ensino/ML/DecTrees.html>, 1999.

BREIMAN, L.; FRIEDMAN, J.H.; OLSHEN, R.A. **Stone, Classification And Regression Trees**, Wadsworth, 1984.

BRODLEY, C.E; FRIEDL, M. A.; STRAHLER, A.H. New Approaches to Classification in Remote Sensing Using Homogeneous and Hybrid Decision Trees to Map Land Cover. *In Geoscience and Remote Sensing Symposium, IGARSS '96. 'Remote Sensing for a Sustainable Future.'*, International, Vol: 1 , 27-31 May 1996 Pages: 532 – 534

CABENA, P. Discovering Data Mining from Concept to Implementation. Upper Saddle River, New Jersey: Prentice Hall, 1997.

CAMARA, G.; SOUZA, R.C.M.; FREITAS, U.M.; GARRIDO, J. SPRING: Integrating remote sensing and GIS

by object-oriented data modelling, **Computers & Graphics**, 20 (3), pp. 395-403, May-Jun 1996.

CAPES Portal Periódicos / CAPES: <www.periodicos.capes.gov.br>

CAVOUKIAN, A. Data Mining: Stanking a Clain on Your Privacy. Disponível por WWW em: http://www.ipc.on.ca/web_site.eng/MATTERS/SUM_PAP/PAPERS/datamine.htm, 1998.

EVANS, F.H.; KIIVERI, H.T.; WEST, G.; GAHEGAN, M. Mapping salinity using decision trees and conditional probability networks, **Proceedings of the second IEEE Conference on Intelligent Processing Systems**, 1998

FLORENZANO, T.G. **Imagens de Satélite para Estudos Ambientais**, Oficina de Textos, 2002.

GOEBEL, M. & GRUENWALD, Le . A Survey of Data Mining and Knowledge Discovery Software Tools. ACM SIGKDD, v. 1, n. 1, p. 20-33. june, 1999.

HOLSHEIMER, M. & SIEBES, A. Data Mining: the search for knowledge in databases. Disponível por FTP anônimo em <ftp.cwi.nl> no arquivo /pub/CWIreports/AA/CS-R9406.ps.Z, 1994.

INGARGIOLA, Giorgio. Building Classification Models: ID3 and C4.5. Disponível por WWW em: <http://www.cis.temple.edu/~ingargio/cis587/readings/id3-c45.html>, 1996.

INPE. Divisão de Processamento de Imagens. **Manual do Spring (versão 4.0)** . São José dos campos: INPE, 2004 <<http://www.dpi.inpe.br/spring/portugues/tutorial>> . Acesso em 7/09/2004.

IBGE.Instituto Brasileiro de Geografia e Estatística, **Introdução ao Processamento Digital de Imagens**. Manuais Técnicos em Geociências, no. 9, 2001.

KIM, H.Y. Binary Halftone Image Resolution Increasing by Decision-Tree Learning. **IEEE Transactions on Image Processing**. EUA: , v.13, n.8, p.1136 - 1146, 2004.

KIM, H.Y. **Manual do Sistema – IMG: rotinas e programas em C++ para processamento de imagens**. LPS/POLI/USP. <<http://www.lps.usp.br/~hae/software/manual1-08.pdf>>. Acesso em 10/11/2004.

KIM, H.Y. **Sistema – IMG**. LPS/POLI/USP. <<http://www.lps.usp.br/~hae/software/>>. Acesso em 10/11/2004.

MATHER, P. **Computer Processing of Remotely-Sensed Images:An Introduction**, Second edition, London: Wiley, 1999.

MITCHELL, T.M. **Machine Learning**, WCB/McGraw-Hill, 1997.

PREVIDELLI, I.T.S. Estimadores de maxima verossimilhança corrigidos para modelos superdispersados não-lineares. São Carlos: UFSC. **Tese de Doutorado em Economia**. 2004

RICHARDS, J.A. **Remote Sensing Digital Image Analysis** , Second Edition, New York: Wiley, 1993.

YANG, C.C; PRASHER, S.O.; ENRIGHT, P.; MADRAMOOTOO, C.; BURGESS, M.; GOEL, P.K.; CALLUM, I. Application of decision tree technology for image classification using remote sensing data, **Agricultural System**, no. 76, pp. 1101-1117, 2003.