

USO DE ÁRVORES DE DECISÃO NA CLASSIFICAÇÃO DE IMAGENS DIGITAIS

ROBIN THOMAS CLARKE¹
HÉLIO RADKE BITTENCOURT²

¹CEPSRM - Universidade Federal do Rio Grande do Sul
Caixa Postal 15044 – 91501-970 – Porto Alegre – RS, Brasil
clarke@iph.ufrgs.br

²Laboratório de Estatística - ULBRA - Universidade Luterana do Brasil
Rua Miguel Tostes, 101 - Canoas - RS, Brasil
heliorb@cpovo.net

Abstract. Binary tree-structured rules can be viewed in terms of repeated splits of subsets of the feature space into two descendant subsets, starting from the entire feature space and ending in a partition of the feature space associated with each class. This paper presents a brief introduction to binary decision trees and shows results obtained in the classifying a single Landsat-TM digital image.

Keywords: image processing, decision trees, CART, pattern recognition.

1. Árvores de Classificação e Regressão

A utilização de árvores de decisão binárias para classificação pode ser considerada uma abordagem não-paramétrica para reconhecimento de padrões. Uma árvore de decisão faz uma representação hierárquica do espaço de feições, onde padrões \mathbf{x}_i são alocados às classes w_j ($j=1,2,\dots,k$) conforme o resultado encontrado depois de percorridos os ramos da árvore. O tipo de árvore de decisão tratada nesse trabalho foi discutido em profundidade por Breiman et al. (1984), cujas contribuições são associadas à sigla CART (*classification and regression trees*).

Árvores de decisão binárias consistem de repetidas divisões do espaço de feições em dois subgrupos descendentes que terminam em nodos associados às classes w_j . Na terminologia de árvores de decisão os subgrupos do espaço de feições são definidos através de nodos. Uma árvore de decisão com alto poder preditivo e um pequeno número de nodos constitui uma situação altamente desejável.

2. Funcionamento da técnica CART

A técnica CART constrói uma árvore de decisão binária a partir de uma amostra de treinamento formando partições na amostra. Esse fato faz com que os tamanhos amostrais dos subgrupos formados por tais partições decresçam, exigindo um tamanho amostral razoável para obtenção de bons resultados, conforme sugere McLachlan (1992).

A árvore de decisão inicia com o nodo raiz t contemplando aquela variável do espaço de feições que minimiza o grau de impureza de dois nodos irmãos. De acordo com Breiman et al. (1984) a medida de impureza do nodo t – denotada por $i(t)$ – pode ser determinada por:

$$i(t) = - \sum_{j=1}^k p(w_j | t) \log p(w_j | t)$$

onde $p(w_j | t)$ é a proporção de padrões \mathbf{x}_i alocados à classe w_j no nodo t . Todos nodos não-terminais dividem-se em outros dois nodos, digamos t_L e t_R , sendo que p_L é a proporção de observações que seguem para o nodo t_L e p_R a proporção de casos que segue para t_R . A melhor divisão s é aquela que torna máxima a diferença:

$$\Delta i(s, t) = i(t) - p_L i(t_L) - p_R i(t_R)$$

O crescimento da árvore de decisão se dá por sucessivas divisões até que não haja mais possibilidade de decréscimo significativo no grau de impureza por meio de uma divisão s . Quando isto ocorre, o nodo t não é mais dividido, sendo automaticamente transformado em um nodo terminal. A classe w_j associada ao nodo terminal t é aquela que maximiza a probabilidade condicional $p(w_j | t)$.

3. Resultados

A técnica de CART foi utilizada na classificação de um segmento de uma imagem Landsat-TM utilizando seis bandas espectrais. As três classes consideradas para classificação foram: água, culturas e vegetação, conforme mostra a **Figura 1**.

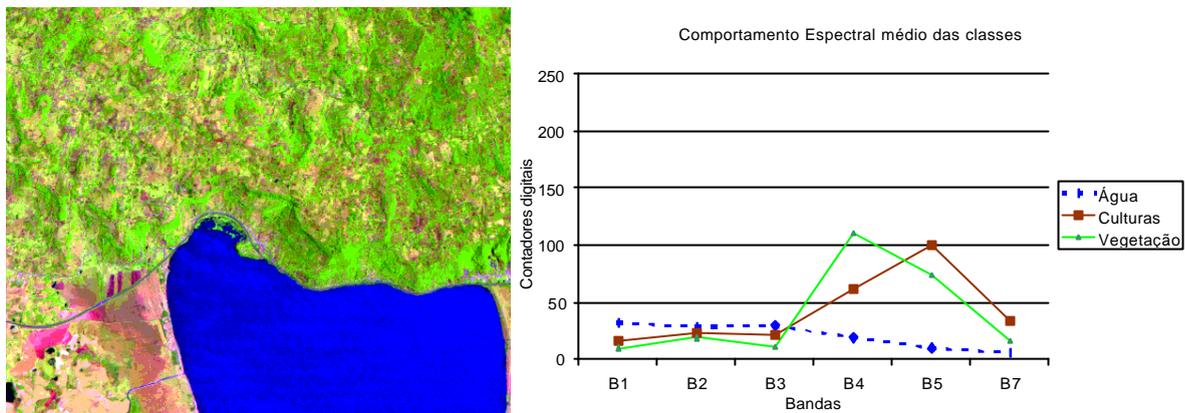


Figura 1 – Segmento de uma imagem Landsat-TM, composição 5-4-2 e comportamento espectral médio das classes

Uma amostra de treinamento de 1084 pixels foi processada no *software* inglês *Genstat 6.1* que gerou a árvore apresentada na **Figura 2**. A árvore construída considerou apenas duas bandas espectrais, apesar dos dados de entrada contemplarem seis bandas, porque a taxa de classificação correta já foi maximizada desta forma. A **Figura 3** apresenta as subdivisões do espaço de feições determinadas pela árvore de decisão.

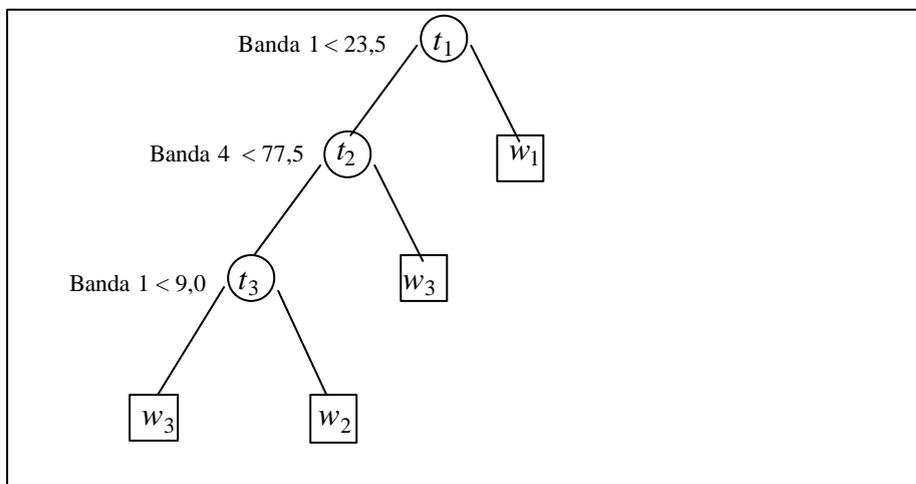


Figura 2 – Árvore de classificação construída no *software* *Genstat*

A **Tabela 1** apresenta os resultados da classificação obtidos a partir de uma amostra de validação de 1214 *pixels* não utilizada no processo de construção da árvore. Os resultados apontam para uma excelente separação entre as classes, com uma taxa de classificação correta superior a 99%.

Tabela 1 – Resultados da classificação obtidos na amostra de validação

Classe Verdadeira	Classificação		
	Água (w_1)	Culturas (w_2)	Vegetação (w_3)
Água (w_1)	750 100,0%	0 0,0%	0 0,0%
Culturas (w_2)	0 0,0%	240 100,0%	0 0,0%
Vegetação (w_3)	0 0,0%	3 1,3%	221 98,7%

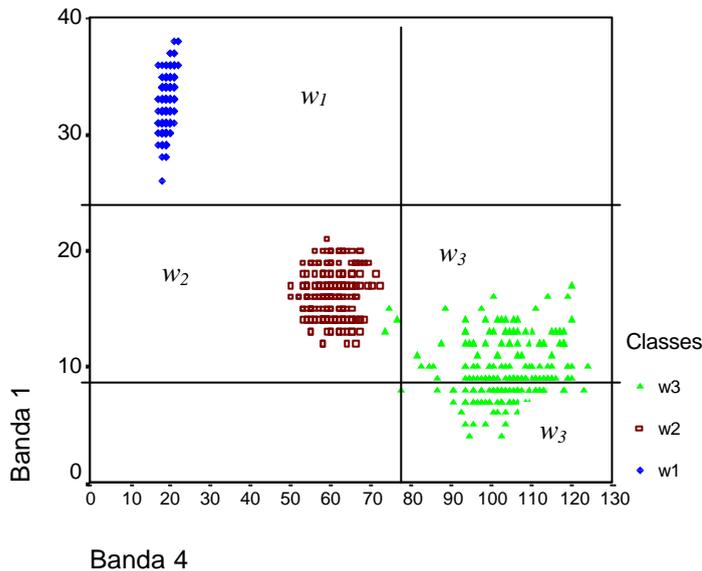


Figura 3 – Subdivisões no espaço de feições determinadas pela árvore de decisão

4. Considerações Finais

As árvores de decisão utilizam a estratégia de dividir um problema complexo em sub-problemas mais simples, oferecendo a vantagem do pesquisador acompanhar o procedimento de classificação através dos nodos da árvore. Por ser uma abordagem não-paramétrica, apresenta a vantagem de não exigir suposições a respeito da forma funcional dos dados de entrada mas, em contrapartida, exige tamanhos amostrais consideráveis para obtenção de bons resultados. Nesse estudo o resultado final foi muito bom, contudo deve-se levar em consideração que as classes não são de difícil separação. Ressalta-se que foi o próprio algoritmo que elegeu as bandas com maior poder discriminatório, informação muito importante para o pesquisador. Apesar da técnica CART ter sido desenvolvida há 18 anos, praticamente existe um consenso de sua importância e valor científico na atualidade.

Referências

Breiman, L.; Friedman, J.H.; Olshen, R. A. *Classification and Regression Trees*. Belmont, CA: Wadsworth, 1984, 358p.

McLachlan, G. *Discriminant Analysis and Statistical Pattern Recognition*. New York: John Wiley & Sons, 1992, 526p.