

Aplicação de Métodos de Extração e Seleção de Atributos para Classificação de Regiões

Joanito de Andrade Oliveira

Luciano Vieira Dutra

Camilo Daleles Rennó

Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12201-970 - São José dos Campos - SP, Brasil.
{joanito,dutra,camilo}@dpi.inpe.br

Abstract. Good feature extraction and selection methods are crucial for an adequate performance of remote sensing data classification methods. When data dimensionality is very high, a search strategy should be used to select the set of features that gives the minimum classification error or minimize an alternate cheaper criterion related to the classification error. In this paper different search strategies are compared for the case where a region classifier is used. Landsat imagery is first segmented using standard region growing technique. Afterwards a large number of features are extracted from regions, and a smaller set of features is selected by means of three types of search strategy. The set of features selected by each criterion is classified based on minimum Mahalanobis distance and classification accuracy is calculated. As there is no deterministic relation between standard feature selection methods and classification error, is possible to conclude that all search strategies should be used to narrow the number of choices assessments and taking the final decision based on classification error.

Keywords: *feature extraction, feature selection, region classification.*

1. Introdução

A evolução da tecnologia de computação, em termos de hardware, bem como o desenvolvimento de algoritmos mais eficientes para manipulação de imagens digitais, tem permitido um número crescente de aplicações de reconhecimento de padrões em sensoriamento remoto. O desenvolvimento de um sistema de reconhecimento de padrões requer: a definição do padrão das classes, um ambiente de aquisição dos dados, a representação do padrão, a extração e seleção de atributos, a análise de agrupamento, o desenvolvimento e aprendizado do classificador, a seleção das amostras de treinamento e teste, e a avaliação do desempenho do classificador (Jain et al., 2000).

Pode-se pensar que quanto maior o número de atributos para representar um padrão (classe), maior o poder discriminatório do classificador. Porém, nem sempre isso é verdade. Na prática o que acontece é uma degradação na acurácia dos resultados da classificação com o aumento da dimensionalidade dos dados mantendo-se constante o número de amostras de treinamento. Segundo Jain et al. (2000), existem duas razões para reduzir esta dimensionalidade: diminuir o custo de processamento e aumentar a acurácia da classificação.

A seleção de atributos é uma tarefa de difícil realização, pois depende dos dados de entrada, isto é, do domínio da aplicação, assim como do classificador a ser utilizado, por exemplo: paramétrico, não-paramétrico ou redes neurais (Dutra e Huber, 1999). Essa fase é destinada à escolha dos atributos que melhor distinguem as classes previamente selecionadas. A maioria dos métodos de seleção de atributos utiliza princípios estatísticos, ou seja, medidas estatísticas entre os atributos para cada conjunto de classes, selecionando os atributos que contém informações relevantes para a separabilidade das classes.

Este trabalho tem por objetivo aplicar métodos de extração e seleção de atributos para classificação de regiões. Atributos de texturas são extraídos das regiões em estudo e métodos de seleção são aplicados a fim de reduzir a dimensionalidade.

2. Extração de atributos

Extrair as características (atributos) mais importantes numa imagem evidencia as diferenças e similaridades entre os objetos. Algumas características são definidas por uma aparência visual na imagem. Essas características incluem: o brilho de uma determinada região, textura de uma região, amplitude do histograma, entre outros (Pratt, 1991). O principal objetivo da extração de atributos é caracterizar os objetos para serem reconhecidos através de medidas sobre a imagem (Duda e Hart, 2001).

O processo de extração e seleção de atributos foi realizado no sistema Texture (Rennó et al., 1998). Este sistema foi desenvolvido em IDL/ENVI e está sendo aperfeiçoado a fim de agregar os métodos de seleção descrito no item 3 deste trabalho.

2.1 Atributos de Textura

As texturas contêm informações importantes sobre o arranjo estrutural das superfícies e seus relacionamentos com o ambiente ao redor (Haralick et al., 1973). No sistema, podem-se extrair três grupos de atributos de textura: distribucional (dist), que se dividi em dois subgrupos: básicos e particulares; co-ocorrência (cooc); e autocorrelação espacial (auto). Esses atributos são descritos com mais detalhes em Rennó et al. (1998).

Os atributos distribucionais consideram a estatística local, ou seja, não levam em conta a distribuição espacial dos níveis de cinza. O sistema possui oito atributos de textura distribucionais básicos: desvio absoluto da média, assimetria, curtose, coeficiente de variação, mediana, média, variância e desvio padrão; e sete atributos distribucionais particulares: entropia, energia, média da log-normal, variância da log-normal, desvio padrão da log-normal, alpha da k-intensidade, alpha da k-amplitude.

Haralick et al. (1973) introduziu a representação de texturas através da matriz de co-ocorrência. Este método explora a dependência espacial dos níveis de cinza da imagem para montar uma matriz que representa a informação textural. A matriz de co-ocorrência é definida para uma orientação e uma distância entre os pixels da imagem. Dezoito atributos de co-ocorrência estão incluídos no sistema: contraste, entropia, energia (uniformidade), homogeneidade, correlação, chi-quadrado, dissimilaridade, *cluster shade* e *cluster prominence*; média, entropia, variância e energia dos vetores de soma e diferença; e contraste do vetor diferença.

A autocorrelação espacial indica a relação espacial existente entre os pixels de uma imagem. Há um valor de autocorrelação para cada relação de vizinhança, sendo esta definida por uma distância em linhas e outra em colunas. Usualmente, estas distâncias são citadas como *lags*. No sistema, esse tipo de atributo pode ser definido para *lags* entre -4 e 4 em linhas e colunas. Pode-se também calcular a razão entre os diferentes atributos de autocorrelação.

3. Seleção de atributos

A seleção de atributos é um problema de otimização e busca pelo menor subconjunto com a melhor acurácia no processo de classificação. O processo de seleção de atributos é executado com base em distâncias estatísticas entre pares de classes. Há várias formas de medir a distância entre conjuntos de classes diferentes no espaço de atributos. Dentre elas, pode-se citar (Theodoridis e Koutroumbas, 1999): distância Euclidiana, distância de Mahalanobis e distância de Bhattacharyya. A distância de Bhattacharyya é definida também como medida da similaridade entre duas distribuições estatísticas (Bhattacharyya, 1943).

Nesse trabalho, utilizou-se a distância de Bhattacharyya entre duas classes dada por:

$$B_{ki} = \frac{1}{8}(\mu_k - \mu_i)^t \left[\frac{\sum_k + \sum_i}{2} \right]^{-1} (\mu_k - \mu_i) + \frac{1}{2} \ln \frac{\left| \frac{\sum_k + \sum_i}{2} \right|}{\sqrt{|\sum_k| |\sum_i|}} \quad (1)$$

onde μ_k e μ_i são os vetores de média e Σ_k e Σ_i representam as matrizes de covariância das classes k e i .

Para executar a seleção de atributos com base em distâncias entre classes, é necessário definir uma função critério que possa avaliar a separabilidade entre todas as classes de uma maneira global. A função critério para a maioria das distâncias citadas acima pode ser efetuada por uma simples operação de soma, média, desvio padrão e outras características estatísticas entre os pares de classes existentes (Dutra e Huber, 1999). É desejável que a função critério seja maior quanto menor for a redundância entre os atributos e quanto maior a facilidade de discriminar padrões de classes diferentes. Visando otimizar o conjunto de atributos para minimizar a probabilidade de erro na classificação, deve-se maximizar a distância entre padrões de classes diferentes no espaço de atributos.

A distância Jeffreys-Matusita (JM) é uma função critério muito utilizada, que expressa as medidas estatísticas de separabilidade entre duas distribuições (Dutra e Huber, 1999). A distância JM entre as classes k e i é dada por:

$$JM_{ki} = \sqrt{2(1 - e^{-B_{ki}})} \quad , \quad JM \in [0, \sqrt{2}) \quad (2)$$

onde B_{ki} representa a distância de Bhattacharyya entre as classes k e i . Utilizou-se a maior distância média JM entre pares de classes como função critério para selecionar o subconjunto de atributos mais representativo na separabilidade das classes.

Os algoritmos de seleção de atributos são divididos em três grupos: exponenciais (busca exaustiva), randômicos e seqüenciais (Boz, 2002). Os métodos seqüenciais de seleção de atributos têm sido estudados em vários trabalhos (Bittencourt et al., 2004; Jain e Zongker, 1997). Os dois métodos mais proeminentes da seleção de atributos são (Dutra e Huber, 1999): *Sequential Forward Feature Selection* (SFS) e *Sequential Backward Feature Selection* (SBS). Implementou-se três algoritmos de seleção de atributos nesse trabalho: SFS, SBS e um algoritmo de escolha fixa do subconjunto de atributos.

3.1 Método SFS

O algoritmo SFS inicia com um conjunto vazio ($Y_0 = \phi$) e, conforme o algoritmo é executado, o melhor atributo x^+ é inserido no subconjunto, resultante do máximo valor da função critério $J(Y_K + x^+)$, quando combinado com os atributos Y_K que já tenha sido selecionado (**Figura 1**).

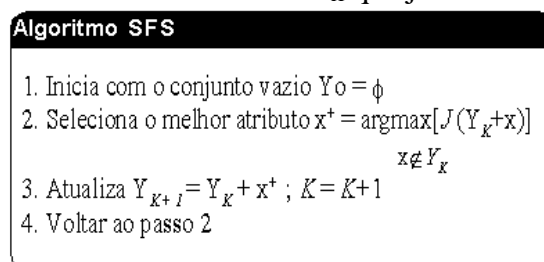


Figura 1 - Algoritmo SFS

O método SFS tem menor custo computacional quando se deseja obter conjuntos pequenos em relação ao total de atributos (Jain e Zongker, 1997). Uma vez que um atributo tenha sido selecionado, ele não pode ser descartado do subconjunto, o que pode provocar o chamado efeito *nesting*. Este efeito ocorre quando o subconjunto ótimo não contém elementos do conjunto já selecionado, o que impossibilita que seja obtido o conjunto de atributos ótimo.

3.2 Método SBS

O algoritmo SBS inicia com um conjunto de atributos completo ($Y_0 = X$) e, nas iterações do algoritmo, remove-se o atributo com o mínimo valor da função critério $J(Y_K - x^-)$, onde Y_K é o conjunto de atributos já selecionado e x^- é o atributo a ser removido (**Figura 2**). O método

SBS tem menor custo computacional, quando se deseja obter conjuntos grandes em relação ao total de atributos. Uma desvantagem desse método é que uma vez eliminado o atributo, ele não retornará ao subconjunto.

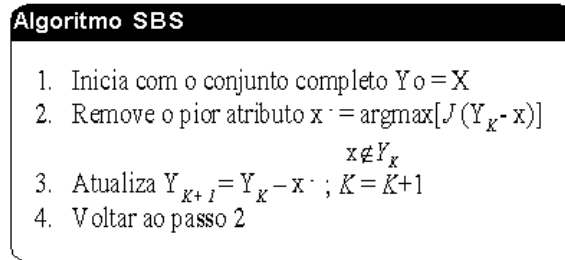


Figura 2 - Algoritmo SBS

3.3 Método de Escolha Fixa (EF)

O método de escolha fixa é uma busca exaustiva que extrai um subconjunto ótimo do conjunto global de n atributos para um número fixo de k atributos. O número de possibilidades do método ótimo cresce exponencialmente, fazendo a busca exaustiva pouco utilizada para um número alto de atributos. Implementou-se o algoritmo NEXKSB (*Next k-subset of an n-Set*) para obter as combinações de k atributos a partir de um conjunto de n atributos (Nijenhuis, 1978). O subconjunto resultante desse método obtém o resultado ótimo na separabilidade das classes.

4. Classificação

A classificação de imagens consiste em associar cada pixel ou região da imagem a uma classe ("rótulo") que descreve um objeto real. A tarefa do classificador é usar o vetor fornecido pelo processo de extração e seleção de atributos para atribuir o objeto a esta classe (Duda e Hart, 2001). A obtenção de uma classificação ideal, que corresponda totalmente a realidade, é quase impossível, sendo uma tarefa mais geral, estimar a probabilidade de que um padrão (objeto) pertença a uma determinada classe, baseando-se nos valores de alguns atributos ou em um conjunto de atributos.

A classificação de região analisa a variabilidade espacial de uma determinada região. As regiões são extraídas pelo processo de segmentação. O processo de segmentação significa agrupar partes de uma imagem em unidades homogêneas com relação a uma ou mais características (Pratt, 1991). Outra forma de extrair regiões de uma imagem é através da digitalização das regiões de interesse (*ROI*). O sistema oferece ferramentas para a classificação de regiões de uma imagem segmentada ou de regiões extraídas através dos *ROI* usando atributos de textura (Rennó et al., 1998).

5. Resultados e Discussão

Para demonstrar a potencialidade dos métodos de extração e seleção de atributos propostos para a classificação por região foi utilizado uma imagem Landsat/TM banda 5 (400x400 pixels) da região da Floresta Nacional Tapajós, situada no Estado do Pará (55° 03' 35" a 55° 08' 46" WGr, 03° 02' 07" a 03° 07' 15" S). A imagem Landsat/TM utilizada refere-se à órbita-ponto 227/062, de 02 de agosto de 1999.

A fim de testar os métodos de extração e seleção para classificação de regiões, extraiu-se 30 atributos de texturas do sistema (Tabela 1). Utilizou-se a configuração da matriz de co-ocorrência 3x3 para extrair os atributos de co-ocorrência. Com base na imagem e no conhecimento de campo, três classes de interesse foram definidas: floresta primária (FP), pasto (PT) e água (AG). Para cada classe, foram obtidas 20 regiões de treinamento (utilizadas no processo de seleção) e 20 regiões de teste (utilizadas para verificação da acurácia da classificação). Não se deve empregar o conjunto de treinamento para estimar a probabilidade

de erro, pois o classificador estará ajustado especificamente para o conjunto de treinamento e a estimativa da probabilidade de erro será muito otimista.

F ₁ desvio absoluto da média (dist)	F ₁₁ média da log-normal (dist)	F ₂₁ <i>cluster shade</i> (cooc)
F ₂ assimetria (dist)	F ₁₂ variância da log-normal (dist)	F ₂₂ <i>cluster prominence</i> (cooc)
F ₃ curtose (dist)	F ₁₃ desvio padrão da log-normal (dist)	F ₂₃ média do vetor soma (cooc)
F ₄ coeficiente de variação (dist)	F ₁₄ contraste (cooc)	F ₂₄ variância do vetor soma (cooc)
F ₅ mediana (dist)	F ₁₅ entropia (cooc)	F ₂₅ entropia do vetor soma (cooc)
F ₆ entropia (dist)	F ₁₆ energia (cooc)	F ₂₆ energia do vetor soma (cooc)
F ₇ energia (dist)	F ₁₇ homogeneidade (cooc)	F ₂₇ média do vetor diferença (cooc)
F ₈ média (dist)	F ₁₈ correlação (cooc)	F ₂₈ variância do vetor diferença (cooc)
F ₉ variância (dist)	F ₁₉ dissimilaridade (cooc)	F ₂₉ entropia do vetor diferença (cooc)
F ₁₀ desvio padrão (dist)	F ₂₀ chi-quadrado (cooc)	F ₃₀ energia do vetor diferença (cooc)

Tabela 1. Atributos extraídos para o processo de classificação.

Uma quantidade alta de atributos muitas vezes é confundida com a qualidade das relações existentes entre os mesmos. Busca-se um espaço de dimensão menor que ainda represente a informação contida nestes dados. Pode-se com um número alto de atributo, gerar problemas matemáticos (inversão de matrizes), sendo necessário escolher os atributos mais representativos, ou seja, que melhor discriminam os objetos de interesse.

A partir das regiões de treinamento, fez-se a seleção de atributos pelos 3 métodos propostos, formando subconjuntos de até 12 atributos. Para testar os métodos propostos, realizaram-se dois experimentos: a) classificação de regiões digitalizadas (*ROI*) sobre a imagem Landsat/TM (regiões de teste); b) classificação de regiões de uma imagem segmentada a partir da mesma imagem Landsat/TM.

No primeiro experimento, cada subconjunto de atributos selecionado pelos três métodos (SFS, SBS e EF) foi avaliado pela classificação das regiões de teste, através da acurácia total (razão entre o número de regiões classificadas corretamente e número total de regiões). Cada região de teste foi classificada como pertencente à classe que minimizou a função critério. Utilizou-se nesse experimento o classificador baseado na distância de Mahalanobis. A **Figuras 3** apresenta o valor da acurácia total da classificação das regiões de teste para cada subconjunto selecionado pelos métodos propostos.




Figura 3- Valor da acurácia da classificação utilizando distância Mahalanobis.

O método de seleção de atributos de escolha fixa, por ser um método que busca todas as combinações para um número requerido de atributos no espaço de atributos global, foi executado até o subconjunto de 4 atributos, devido ao custo computacional. Esperava-se que o método EF obtivesse a melhor acurácia na classificação, pois esse método extrai um subconjunto ótimo do conjunto global de atributos, ou seja, o subconjunto que possui a maior média da distância *JM*. Isso ocorre, pois os métodos de seleção que utilizam distâncias

estatísticas garantem uma boa separabilidade entre as classes, mas uma boa classificação não depende apenas dos métodos de seleção, mas também do classificador utilizado.

A **Tabela 2** apresenta os valores da média *JM* e a acurácia total para cada subconjunto de atributos selecionados pelos três métodos de seleção propostos neste trabalho. Na escolha de apenas um atributo, o atributo F5 (mediana), selecionado pelos métodos SFS e EF, obteve a maior média da distância *JM*, tendo um valor menor na acurácia total do que o atributo F8 (média).

Métodos	Número de Atributos	Média JM	Acurácia Total (%)	Atributos Selecionados
SFS	1	1,4142131	98,33	F5
SBS		1,4141301	100	F8
EF		1,4142131	98,33	F5
SFS	2	1,4129448	98,33	F5 e F16
SBS		1,4141301	98,33	F8 e F11
EF		1,4141301	98,33	F8 e F11
SFS	3	1,4139893	96,66	F5, F16 e F21
SBS		1,4142007	98,33	F8, F9 e F11
EF		1,4142110	95,00	F7, F8 e F11
SFS	4	1,4141941	93,33	F5, F16, F21, F23 e F24
SBS		1,4142134	96,66	F8, F9, F11 e F12
EF		1,4142135	95,00	F7, F8, F11 e F21
SFS	5	1,4142099	91,66	F5, F16, F21, F23 e F24
SBS		1,4142135	93,33	F8, F9, F11, F12 e F18
EF				
SFS	6	1,4142131	98,33	F5, F11, F16, F21, F23 e F24
SBS		1,4142136	93,33	F8, F9, F11, F12, F13 e F18
EF				
SFS	7	1,4142136	98,33	F5, F8, F9, F11, F12, F16, F21, F23 e F24
SBS		1,4142136	91,66	F6, F8, F9, F11, F12, F13 e F18
EF				
SFS	8	1,4142136	96,66	F5, F8, F11, F12, F16, F21, F23 e F24
SBS		1,4142136	91,66	F6, F8, F9, F11, F12, F13, F16 e F18
EF				
SFS	9	1,4142136	95,00	F5, F8, F9, F11, F12, F16, F21, F23 e F24
SBS		1,4142136	91,66	F6, F7, F8, F9, F11, F12, F13, F16 e F18
EF				
SFS	10	1,4142136	95,00	F5, F8, F9, F11, F12, F16, F21, F23, F24 e F30
SBS		1,4142136	91,66	F6, F7, F8, F9, F11, F12, F13, F15, F16 e F18
EF				
SFS	11	1,4142136	96,66	F5, F8, F9, F11, F12, F16, F21, F23, F24, F29 e F30
SBS		1,4142136	91,66	F6, F7, F8, F9, F11, F12, F13, F15, F16, F17 e F18
EF				
SFS	12	1,4142136	98,33	F5, F8, F9, F11, F12, F16, F21, F23, F24, F28, F29 e F30
SBS		1,4142136	91,66	F6, F7, F8, F9, F11, F12, F13, F15, F16, F17, F18 e F19
EF				

Tabela 2. Atributos selecionados através dos 3 métodos de seleção propostos, com suas respectivas Média *JM* e o valor da acurácia total para cada sub-conjunto.

Para a classificação das regiões de teste, obteve-se um excelente resultado, alcançando 100% no valor da acurácia total, utilizando-se apenas 1 atributo selecionado. A obtenção desse resultado foi possível, pois as classes em estudo são bem separáveis, e com apenas a obtenção de estatística de primeira ordem, como a média e a mediana pode-se obter um bom desempenho na classificação.

No segundo experimento, as regiões utilizadas para a classificação foram extraídas pelo processo de segmentação (**Figura 4a**), cuja metodologia usada é descrita em Sousa Junior et al. (2003). Para a segmentação da imagem Landsat/TM utilizou-se um limiar de área igual a 20 pixels e a similaridade de 10 níveis de cinza.

O mapa verdade de campo, utilizado como referência neste trabalho, foi confeccionado através dos dados coletados em campo (**Figura 4b**). A metodologia usada para a confecção desse mapa está descrita em Pardi Lacruz (2001). Utilizou-se as informações de campo na avaliação da classificação, analisando-se o desempenho do classificador, visualizando não somente os acertos, mas também quais as classes cujas amostras foram erroneamente classificadas e quais classes ocorreram confusão.

O resultado da classificação da imagem segmentada com o subconjunto dos 12 atributos, selecionados pelo método SFS é apresentado na **Figura 4c**. Para efeito de visualização do problema de classificar uma imagem utilizando informações redundantes (atributos correlacionados), é apresentado também a imagem classificada utilizando-se os 30 atributos (**Figura 4d**).

Observa-se que, na **Figura 4d**, há muita confusão, ou seja, o número de regiões classificadas corretamente é menor que na **Figura 4c**. Pode-se observar ainda que com um número menor de atributos, obtivesse-se um melhor resultado na classificação. Estes resultados mostram que os métodos de seleção propostos ao problema em estudo reduzem a dimensão dos dados aumentando o poder discriminatório.




Figura 4: (a) Imagem da banda 5 TM/Landsat e sua segmentação; (b) Imagem de Temática (verdade de campo); (c) Imagem classificada utilizando 12 atributos, selecionados pelo método SFS; (d) Imagem classificada utilizando 30 atributos (conjunto global de atributos).

6. Conclusões e Recomendações

Esse trabalho apresentou métodos de extração e seleção de atributos na classificação de regiões. Através desses métodos, foi possível extrair atributos de textura dos objetos (regiões) na imagem segmentada e das regiões de teste, selecionando-se os atributos mais relevantes na separabilidade das classes.

No processo de classificação, uma quantidade alta de atributos pode não aumentar a precisão do classificador. Isso ocorre devido à redundância das informações. Os resultados encontrados mostram a viabilidade em se utilizar os métodos de seleção de atributos, objetivando a redução da dimensionalidade sem haver perda no poder discriminatório entre as

classes. Não existe nenhuma relação determinística entre métodos de seleção de atributos padrão e erro de classificação, onde se conclui que todas as estratégias de busca devem ser usadas para diminuir o número de avaliações na escolha da decisão final baseada no erro da classificação.

Outra forma de aumentar a potencialidade da separabilidade das classes é agregar atributos de forma no processo de extração de atributos, que integrados ao sistema, seja possível aumentar a distinção entre as classes. Além disso, métricas de avaliação e comparação com outros algoritmos de seleção devem ser estudadas e posteriormente aplicadas para outras áreas de estudos com dados oriundos de vários sensores.

7. Referências

Bhattacharyya, A.. On a measure of divergence between two statistical populations defined by their probability distributions. **Bulletin of the Calcutta Mathematics Society** 35, 99–110, 1943.

Bittencourt H.R., Clarke R.T., Feature Selection by Using Classification and Regression Trees (cart). **XX ISPRS Congress**, 12-23 July 2004, Istanbul, Turkey.

Boz, O. Feature Subset Selection by Using Sorted Feature Relevance. Proc. of The 2002 Intl. **Conf. on Machine Learning and Applications**, 2002.

Duda R.O., Hart P.E. & Stork D.G.. **Pattern Classification**. 2 ed. New York, Wiley, (2001).

Dutra, L.V. and Huber, R.. Feature Extraction and Selection for ERS 1/2 InSAR Classification: Int. **J. Remote Sensing**, 1999, vol. 20, n°. 5, 993-1016.

Haralick, R.M; Shunmugan, K; Dinstein, I. Texture Feature for Image Classification. **IEEE Trans. Systems, Man and Cybernetics**, SMC-3(6):6610-621, Nov. 1973.

Jain. A. K., Robert P.W. Moa D., Moa. J. Statistical Pattern Recognition: A Review. **IEEE Trans. On Pattern Analysis And Machine Intelligence**, Vol. 22, N°.1, 2000.

Jain, A. K. and Zongker, D. Feature-selection: Evaluation, application, and small sample performance. **IEEE Trans. on Pattern Analysis and Machine Intelligence**, 19(2):153-158, 1997.

Nijenhuis, A., Wilf, H. S. **Combinatorial Algorithms for Computers and Calculators**. Academic Press, Second Edition, 1978.

Pardi Lacruz, M.S.; Shimabukuro, Y.E.; Williams, M.; Rennó, C.D.; Herbert, D.A; Rastetter, E.B. Utilização do sensoriamento remoto e dados de campo para amodelagem das atividades biogeoquímicas na Floresta Nacional de Tapajós. In: **X Simpósio Brasileiro de Sensoriamento Remoto**. [CD-ROM]. Instituto Nacional de Pesquisas Espaciais. Foz de Iguaçu, Brasil. Abril, 2001 <dpi.inpe.br/lise/2001/09.24.10.28>.

Pratt, W. K., **Digital Image Processing**, Wiley Interscience, 1991. (2nd ed).

Rennó, C. D., Freitas, C. C., Frery, A. C. A System for Region Image Classification Based on Textural Measures. **Jornada Latino-Americana de Sensoriamento Remoto por Radar: Técnicas de Processamento de Imagens**. 2., Santos, SP, 1998.

Sousa Junior, M.A.; Dutra, L. V.; Freitas, C.C.; Desenvolvimento de um Segmentador Incremental Multi-nível (SIM) para Imagens Ópticas e de Radar. In: **XI Simpósio Brasileiro de Sensoriamento Remoto**. Belo Horizonte. 5 a 10 de abril de 2003. p. 2293-2300 <tid.inpe.br/sbsr/2002/11.17.18.37>.

Theodoridis, S. and Koutroumbas, K. **Pattern Recognition**. Academic Press, USA, 1st edition, 1999.