MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO DE PESQUISAS ESPACIAIS

AUTORIZAÇÃO PARA PUBLICAÇÃO
AUTHORIZATION FOR PUBLICATION

PALAVRAS CHAVES/KEY WORDS

CLASSIFICAÇÃO DE AMOSTRAS TEXTURAS
MODELOS ESTATÍSTICOS FILTROS INVERSOS

AUTORIZADA POR/AUTHORIZED BY

Roberto Pereira da Cunha
Diretor SRE

AUTOR RESPONSAVEL / RESPONSIBLE AUTHOR

Luciano Vieira Dutra

DISTRIBUIÇÃO/DISTRIBUTION

- [ ] INTERNA / INTERNAL
- [x] EXTERNA / EXTERNAL
- [ ] RESTRITA / RESTRICTED

REVISADA POR / REVISED BY

CDU/UDC

621.376.5

DATA / DATE

Outubro, 1989

PUBLICAÇÃO Nº / PUBLICATION NO

INPE-4987-PRE/1549

ORIGEM / ORIGIN

DPI

PROJETO / PROJECT

ANIMA

Nº DE PAG. / NO OF PAGES

10

ULTIMA PAG. / LAST PAGE

09

VERSÃO / VERSION

Nº DE MAPAS / NO OF MAPS

TÍTULO/TITLE

MODELOS AUTO-REGRESSIVOS - MÉDIA MÓVEL
PARA CLASSIFICAÇÃO DE TEXTURAS

AUTORES/AUTHORSHIP

Luciano Vieira Dutra
Nelson Delfino d'Ávila Mascarenhas

RESUMO - NOTAS / ABSTRACT - NOTES

Este trabalho apresenta o desenvolvimento de um método para a caracterização estatística de imagens utilizando-se de modelos auto-regressivos e média móvel - ARMA - e a utilização desses modelos para melhorar o resultado da classificação de amostras de textura de imagens digitais. Modelos são ajustados a cada classe através de um processo de identificação adequado. Em seguida, a imagem original é filtrada por filtros inversos derivados dos modelos obtidos, obtendo-se assim tantos canais quantas classes texturais foram definidas a priori, para cada imagem original. Como existe correlação entre as saídas dos filtros torna-se conveniente considerar a distribuição conjunta dos resíduos para se definir as estatísticas das classes e das amostras desconhecidas. Essas são classificadas associando-se à classe que minimizar a distância estatística entre a distribuição que governa a amostra (suposta gaussiana) e as classes existentes.

OBSERVAÇÕES / REMARKS

Trabalho apresentado no IV Simpósio Latinoamericano sobre Sensores Remotos, de 20 a 24 de novembro de 1989, Bariloche, Argentina.

INPE - 149

MODELOS AUTO-REGRESSIVOS - MÉDIA MÓVEL PARA CLASSIFICAÇÃO DE TEXTURAS[1]

Luciano Vieira Dutra
Nelson Delfino d'Ávila Mascarenhas

Instituto de Pesquisas Espaciais - INPE
Departamento de Processamento de Imagens - DPI
Caixa Postal 515
12201 - São José dos Campos - SP

RESUMO

Este trabalho apresenta o desenvolvimento de um método para a caracterização estatística de imagens utilizando-se de modelo auto-regressivos e média móvel - ARMA - e a utilização desses modelos para melhorar o resultado da classificação de amostras de textura de imagens digitais. Modelos são ajustados a cada classe através de um processo de identificação adequado. Em seguida, a imagem original é filtrada por filtros inversos derivados dos modelos obtidos, obtendo-se assim tantos canais quantas classes texturais foram definidas a priori, para cada imagem original. Como existe correlação entre as saídas dos filtros torna-se conveniente considerar a distribuição conjunta dos resíduos para se definir as estatísticas das classes e das amostras desconhecidas. Essas são classificadas associando-as à classe que minimizar a distância estatística entre a distribuição que governa a amostra (suposta gaussiana) e as classes existentes.

1 - INTRODUÇÃO

Nas áreas de Processamento Digital de Imagens e Reconhecimento de Padrões tem sido desenvolvido um esforço mais ou menos recente na pesquisa de novos modelos de imagens, capazes de incorporar no processo de classificação a informação de contexto espacial de um "pixel". Tal esforço está ligado à caracterização estatística de texturas como modelos markovianos (Yu e Fu, 1983) e os modelos auto-regressivos e de médias móvel (ARMA) (Therrien, 1983; Terrien et alii, 1986).

Neste trabalho[1] apresenta-se um estudo para a descrição estatística classificação de amostras de textura em imagens digitais utilizando modelos ARMA.

Modelos são ajustados a cada classe, através de um processo denominado identificação e estimação dos parâmetros. A imagem que contém as texturas a classificar é filtrada por filtros inversos derivados dos modelos, gerando tantos canais (resíduos) quantos forem as classes de textura. Gambotto (1980) apresenta um critério de classificação das amostras desconhecidas associando-as ao filtro que apresentar menor variância dos resíduos.

Tal critério entretanto não leva em conta a correlação existente entre as saídas dos

[1]Suporte Financeiro : Sid Informatica (Projeto ESTRA)

diversos filtros. Para isso torna-se conveniente considerar a distribuição conjunta dos resíduos dos filtros. Uma amostra desconhecida, da qual se calcula a distribuição (que se supõe gaussiana), é associada à classe cuja distribuição for mais próxima. Nesse trabalho utiliza-se uma medida de proximidade entre distribuição denominada distância JM (Mascarenhas e Velasco, 1989).

O trabalho está organizado da seguinte maneira: na seção 2 discute-se o modelo de séries unidimensionais e como estimar os parâmetros necessários. A seção 3 relaciona os modelos unidimensionais obtidos a partir da concatenação de linhas ou colunas da imagem com os modelos verdadeiramente bidimensionais. A seção 4 apresenta o processo de extração de atributos e o método de classificação de amostra por minimização da distância JM. Finalmente as seções 5 e 6 apresentam os resultados e conclusões.

2 - O MODELO ARMA DE SÉRIES TEMPORAIS

Uma série temporal é caracterizada por uma sequência de valores no tempo $y_1, y_2, \ldots, y_n$. O valor médio de y_i é μ. Essa série é modelada como sendo gerada a partir de uma sequência de "shocks" independentes, que são realizações de um processo de ruído branco com média zero e variância σ_w^2, que passam por um filtro linear que caracteriza o processo (Figura 1) (Box e Jenkins, 1970).

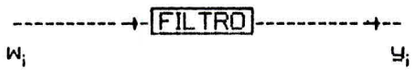

Figura 1 - Representação do filtro gerador do processo

Esse filtro é definido pela equação diferença (Eq. 1), denominado modelo ARMA(p,q):

$$y_i = \sum_{k=0}^{q} \alpha_k w_{i-k} + \sum_{j=1}^{p} \beta_j y_{i-j} + \mu \qquad (\alpha_0=1) \tag{1}$$

O modelo (1) é unidimensional e poderia ser usado para descrever uma imagem se essa fosse linealizada concatenando-se linhas ou colunas. Coeficientes não nulos em atrasos múltiplos do tamanho da linha corresponderiam a pontos colocados espacialmente vizinhos ao ponto sendo gerado.

Da Equação (1) pode-se ressaltar dois casos particulares; o primeiro é o denominado modelo auto-regressivo de ordem p (AR(p)) quando q=0 (Eq. 2):

$$y_i = \beta_1 y_{i-1} + \beta_2 y_{i-2} + \ldots + \beta_p y_{y-p} + w_i \tag{2}$$

O segundo caso particular é denominado modelo média-móvel de ordem q (MA(q)) que deriva (1) fazendo p=0 (Eq. 3):

$$y_i = \alpha_0 w_i + \alpha_1 w_{i-1} + \ldots + \alpha_q w_{i-q} + \mu \tag{3}$$

onde $\alpha_0 = 1$.

Para se obter modelos ARMA(p,q) que caracterizem um processo estocástico, normalmente se supõe que esse processo seja estacionário no sentido amplo, ou seja, ele não varia muito além da média ou não foje da média sistematicamente. Isto supõe que as estatísticas de 1ª e 2ª ordem do processo só dependam do intervalo entre tempos (também chamado de atraso) e não da posição temporal. (Box e Jenkins, 1970).

A ordem e uma estimativa preliminar dos parâmetros do modelo são obtidos com a ajuda da função de autocorrelação (FAC) e autocorrelação parcial (FAP) definidas a seguir.

Supondo $\mu = 0$, a autovariância para um processo estocástico estacionário é dada por

$$\gamma_k = E \{ y_i \, y_{i-k} \} \tag{4}$$

É fácil verificar de (2) e (4) que para um processo AR(p) vale a relação:

$$\gamma_k = \beta_1 \gamma_{k-1} + \beta_2 \gamma_{k-2} + \ldots + \beta_p \gamma_{k-p} \tag{5}$$

A função de autocorrelação (FAC) é dada por:

$$\rho_k = \gamma_k / \gamma_0 \tag{6}$$

Daí resultando que:

$$\rho_k = \beta_1 \rho_{k-1} + \beta_2 \rho_{k-2} + \ldots + \beta_k \rho_{k-p} \tag{7}$$

Fazendo-se k = 1, 2, ..., p obtêm-se as chamadas equações Yule-Walker, que são também soluções para o problema de predição linear (Marple, 1987).

Seja ϕ_{ki} o i-ésimo coeficiente num processo auto-regressivo de ordem k. Dentre os coeficientes ϕ_{ki} a função ϕ_{kk} (encarada como função de k) tem especial interesse e é chamada função de autocorrelação parcial (FAP(k)). A FAP se anula para k > p quando o processo é AR(p). Por outro lado, pode-se mostrar que, para um processo MA(q), a função de autocorrelação (FAC) se anula para atrasos maiores do que q.

Para o modelo ARMA completo, nem a FAC ou a FAP se anulam. De acordo com essas propriedades é possível tentar identificar o modelo subjacente a um processo calculando a FAC e a FAP e observando seus aspectos.

Uma vez obtida uma indicação do tipo e da ordem do modelo, a estimativa dos parâmetros α_i e β_j é feita em dois passos: 1) uma estimativa preliminar que utiliza a função de autocorrelação e que serve como ponto de partida para 2) uma estimativa de máxima verossimilhança que usa os dados diretamente.

A estimativa preliminar para o processo AR(p) é feita substituindo-se as correlações teóricas pelas estimadas na equação de Yule Walker. Para o modelo MA(q) pode-se utilizar o algoritmo das inovações (Kailath, 1968). No caso de modelos ARMA(p,q) Brockwell (1987) apresenta um método para determinação preliminar dos parâmetros baseado nas estimativas obtidas pelo algoritmo das inovações para o modelo MA(∞) equivalente. Tendo sido identificado um modelo tentativa com certos parâmetros iniciais, deseja-se escolher uma melhor estimativa para esses coeficientes. O método mais usado é o método dos mínimos quadrados, que corresponde à estimativa de máxima verossimilhança sob a hipótese gaussiana para o ruído. Como se trata de um problema de estimação não-linear, métodos iterativos como o de Gauss-Newton são utilizados (Granger e Newbold, 1977).

Deseja-se também calcular uma estimativa do erro de cálculo dos parâmetros. Sabe-se que as estimativas de máxima verossimilhança atingem assintoticamente o limite de Cramer-Rao e têm distribuição multivariada gaussiana. A raiz quadrada dos elementos da diagonal principal da matriz de covariância dado pelo limite Cramer-Rao dá o desvio padrão ($SE(\theta_i)$) de cada parâmetro. Assim, para que um parâmetro seja significativamente $\neq 0$ com 95% de probabilidade basta verificar se $| \theta_i | > 2 \; SE(\theta_i)$.

O conhecimento do erro padrão para os parâmetros auxilia o processo de identificação, pois os parâmetros não significativos podem ser retirados do modelo e reestimados os parâmetros restantes (Dutra, 1988).

3 - RELAÇÃO ENTRE MODELOS UNIDIMENSIONAIS CONCATENADOS E MODELOS BIDIMENSIONAIS

Dutra e Mascarenhas (1989) desenvolveram um método aproximado para determinar modelos ARMA 2D a partir de concatenação de linhas ou colunas da imagem. Com o processo de concatenação de segmentos de linhas ou colunas transforma-se a imagem, que é um processo estocástico de duas dimensões (também chamado de campo aleatório), em um processo unidimensional, onde se pode aplicar o método descrito na seção 2 com certas adaptações.

A metodologia pode ser sintetizada nos seguintes passos:

a) Adquirir os dados referentes às áreas de treinamento, concatenando-se segmentos de linha ou coluna.

b) Retirar a média do sinal e plotar as funções FAC e FAP. Pela observação dessas funções determinar p e q tal que as funções sejam consideradas nulas.

c) Obter as estimativas preliminares para os modelos AR(p), MA(q) e ARMA(p,q). Metodicamente eliminar as ordens de modelos que resultarem não causais ou não invertíveis.

d) De posse do erro padrão para os coeficientes preliminares zerar os não significativos, que não mais serão considerados para otimização.

e) Submeter os três modelos à estimativa de máxima verossimilhança. Observar que a natureza originalmente bidimensional dos dados vai revelar rapidamente a região de suporte do filtro.

Uma vez obtido um modelo realiza-se um teste sobre os resíduos, que já são obtidos automaticamente no processo de estivativa de máxima verossimilhança. Se os resíduos não forem considerados brancos normalmente é necessário aumentar a ordem do modelo refazendo os passos indicados.

4 - EXTRAÇÃO DOS ATRIBUTOS E CLASSIFICAÇÃO DAS AMOSTRAS

Uma vez determinado os modelos referentes às texturas das imagens o processo de classificação das amostras se dá em 2 passos:

a) Extração de atributos;

b) Classificação das amostras por minimização da distância JM da amostra às classes.

Na fase de extração de atributos a imagem toda é filtrada pelos filtros inversos casados a cada textura da imagem gerando resíduos. Resíduo é a diferença entre o valor predito pelo modelo para aquele ponto da imagem e o valor real existente. Quanto maior for o ajustamento do modelo à classe, menor será o resíduo. Serão gerados tantos canais quantos forem os filtros (e portanto classes) existentes.

Na fase de classificação das amostras, inicialmente são estimadas de áreas de treinamento as distribuições que governam as classes. Como se supõe que as classes têm distribuição gaussiana, basta calcular as médias e matrizes de covariância sobre as áreas de treinamento para classes para caracterizar suas distribuições.

Em seguida classificam-se as amostras desconhecidas. Cada amostra A_l da qual se conhece apenas sua média $\underline{\mu}_l$ e matriz de covariância Σ_l é associada á classe H_i (de médias $\underline{\mu}_i$ e matriz Σ_i) se (Souza et alii, 1980):

$$J_{il} \leq J_{kl}$$

onde

$$J_{kl} = 2(1 - e^{-\alpha_{kl}})$$

$$\alpha_{kl} = \frac{1}{8}\left(\underline{\mu}_k - \underline{\mu}_l\right)^T \Sigma^{-1} (\mu_k - \underline{\mu}_l) - \frac{1}{2} \ln \left| \frac{\det\Sigma}{\sqrt{\det\Sigma_k \det\Sigma_l}} \right|$$

e $$\Sigma = \frac{\Sigma_k + \Sigma_l}{2}$$

O índice J_{il} é denominado distância JM (de Jeffrey-Matusita) e mede a proximidade entre a distribuição da classe H_i e amostra A_l. O termo α_{kl} é o chamado distância de Bhattacharyya.

5 - RESULTADOS e CONCLUSÕES

Para avaliação do método desenvolvido foi sintetizada uma imagem composta de três texturas retiradas do livro e Brodatz (1956): grama, tecido e madeira (Fig. 1).

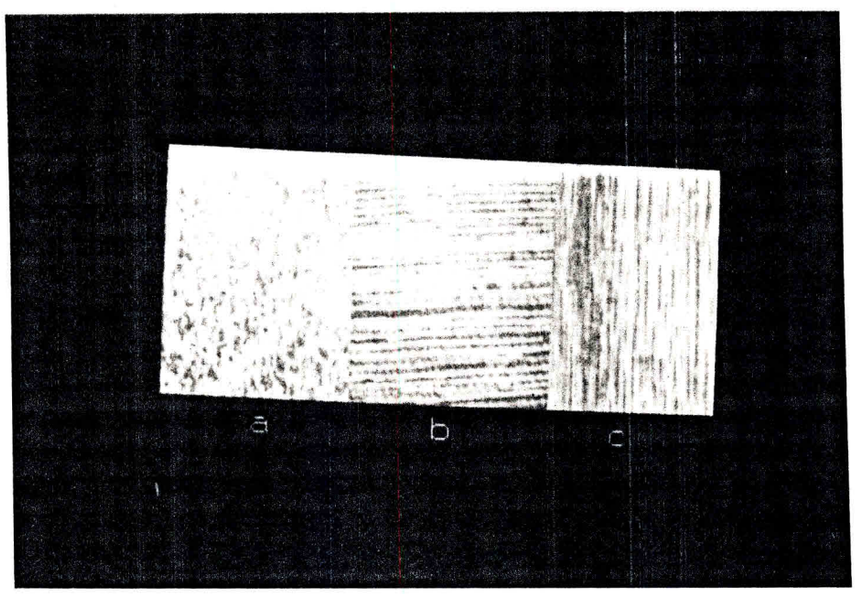

Fig. 1 - Mosaico de texturas (a)grama, (b)tecido e (c)madeira.

Os filtros inversos derivados dos modelos de cada textura, obtidas segundo o procedimento das seções 2 e 3 são os mostrados na Fig. 2.

Foram gerados 3 canais de resíduos referentes aos três filtros mencionados. A Fig. 3 mostra a imagem original filtrada pelo filtro inverso da grama.Desse cena foi obtida uma amostra de treinamento de 30 x 30 pixels por classe e 10 amostras testes de 20 x 20 pixels por classe.(Fig. 4). O resultado percentual da classificação dessas amostras testes pelo critério da distância JM, é apresentado na Tabela 1, onde o desempenho médio se refere a razão de amostras classificadas corretamente e o número total de amostras.

AR			MA		
-.121	+.225	+.173			
+.465	-.859	-.220		0.0	
-.612	$\boxed{1.0}$		0.0	$\boxed{0.0}$	0.0

(a)

AR		MA	
.535	- .675	0.0	-.221
-.817	$\boxed{1.0}$	0.0	$\boxed{0.0}$

(b)

AR			MA		
	0.0		-.340	-.610	-.181
0.0	0.0	0.0	-.574	-.954	-.305
0.0	$\boxed{1.0}$	0.0	-.452	$\boxed{0.0}$	

(c)

Fig. 2 - Filtros inversos das texturas: (a) grama - modelo do tipo AR, (b) tecido - ARMA, (c) madeira - MA.

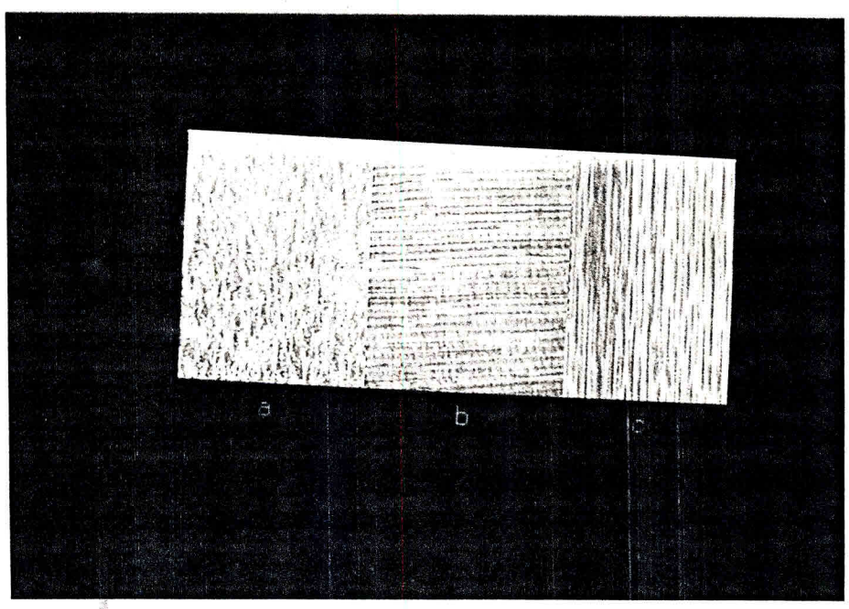

Fig. 3 - Canal residual filtrado pelo modelo grama inverso.

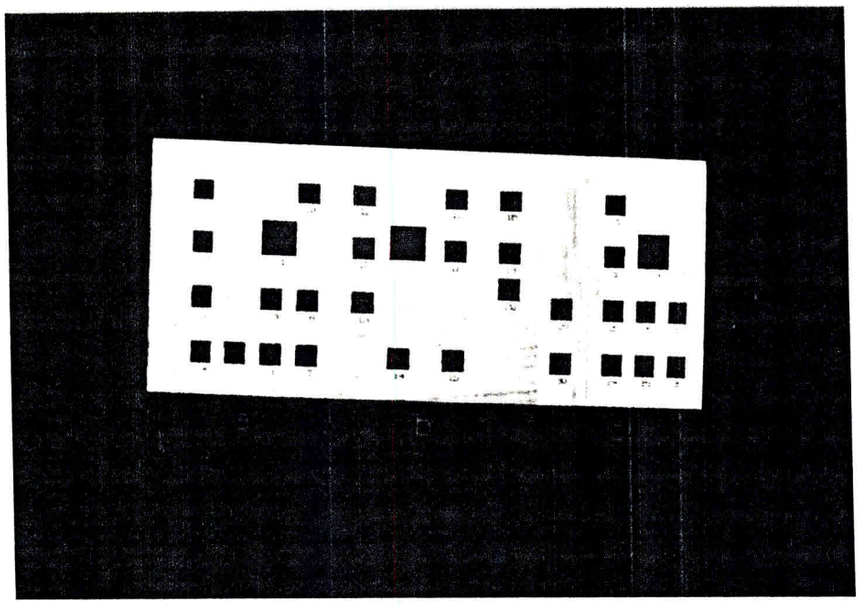

Fig. 4 - Areas de treinamento (30x30) e Teste (20x20)

TABELA 1

MATRIZ DE CLASSIFICAÇÃO - CANAIS RESIDUAIS

	AMOSTRAS		
CLASSES	GRAMA	TECIDO	MADEIRA
Grama	80.0	0.0	0.0
Tecido	20.0	100.0	0.0
Madeira	0.0	0.0	100.0

Desempenho Médio : 93,3
Confusão Média : 6,7

Para comparação, apresenta-se na Tabela 2 o resultado da classificação das mesmas áreas testes, também pelo mesmo critério-distância JM - sobre o canal original.

Como se observa, a melhoria nos resultados foi significativa, indicando a viabilidade do processo. Os estudos vão ter continuidade focalizando-se os seguintes aspectos: definição de um limiar de rejeição baseado nos limiares superiores e inferiores para P(Erro) em função da distância JM. Esse ítem é importante para definição de um método de segmentação de imagens, baseado em divisão das imagens em amostras de texturas.

TABELA 2

MATRIZ DE CLASSIFICAÇÃO - CANAL ORIGINAL

		AMOSTRAS	
CLASSES I	GRAMA	TECIDO	MADEIRA
Grama	20.0	0.0	0.0
Tecido	60.0	100.0	60.0
Madeira	20.0	0.0	40.0

Desempenho Médio : 53,3
Confusão Média : 46,7

Outros modelos também poderão ser testados tais como: modelos markovianos, mínimos quadrados generalizados, etc. Também outros critérios de seleção de amostras poderão ser usados, tais como: distância Mahalanobis média, divergência, maioria e distância entre modelos.

6 - REFERÊNCIAS BIBLIOGRÁFICAS

AKAIKE, H Fitting autorregressive models for prediction. *Ann. Inst. Statisc. Math.* 21:243-247, 1969.

BOX, G.E.P. JENKINS, G.M.; *Time Séries Analysis, Forecasting and Control*. Holden Day, San Francisco , 1970.

BROCKWELL, P.J.; DAVIS, R.A. *Time Series, Theory and Methods*, Berlin, Springer-Verlag, 1987.

BRODATZ, P.; *Textures. A Photograph Album for Artists and Designers*, New York, Dover, 1956.

DUTRA, L.V. Identificação Estatística Preliminar de Imagens de Radar: Modelos Autorregressivos e Média Móvel (ARMA). In: SIMPOSIO BRASILEIRO DE SENSORIAMENTO REMOTO, V. Natal, 11-15 outubro, 1988, Anais, São José dos Campos, INPE, v. 2, p. 517-524.

DUTRA, L.V.; MASCARENHAS, N.D.A. Análise de Texturas em Imagens de Radar Usando Modelos ARMA. In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO GRÁFICA E PROCESSAMENTO DE IMAGENS, II, Águas de Lindóia, 1989, *Anais*, São José dos Campos, INPE, 1989, pag. 77-88.

GAMBOTTO, J.P. Two Dimensional Time Series for Textures. In: SIMON, J.C.; HARALICK, R.M., ed. *Digital Image Processing*, New York, D. Reidel Publishing, 1980.

GRANGER, C.W.J.; NEWBOLD, P.; *Forecasting Economic Time Series*, New York, NY, Academic Press, 1977.

KAILATH, T.; An Innovations Approach to Least Squares estimations - Part I: Linear Filtering in Additive White Noise. *IEEE Transactions an Automatic Control*, AC-13:646-654, 1968.

MARPLE, S.L. *Digital Spectral Analysis*. Englewood Cliffs , N.J., Prentice-Hall, 1987.

MASCARENHAS, N.D.A.; VELASCO, F.R.D. *Processamento Digital de Imagens*. Buenos Aires, Argentina, Kapelusz-Ebai 1989, 2ª Ed.

SOUZA, C.R.; CAMARGOS, L.R.; KUMAR, R.; MASCARENHAS, N.D.A. *Algoritmos para Classificação de Amostras e Seleção de Atributos*. São José dos Campos, INPE, 87p. (INPE-1718-PRE/124), Abril, 1980.

TERRIEN, C.W. An Estimation-Theoretic Approach to Terrain Image Segmentation. *Computer Vision, Graphics and Image Processing*, 22(f):313-326, 1983.

THERRIEN, C.W.; QUATIERY, T.F.; DUDGEON, D.E.; Statistical Model Based Algorithms for Image Analysis. *Proceedings of the IEEE*. 74(4):532-551 April, 1986.

YOU, T.S.; FU, K.S. Recursive Contextual Classification Using a Spatial Stochastic Model. *Pattern Recognition* 16(1):89-108, 1983.