

IDENTIFICAÇÃO ESTATÍSTICA PRELIMINAR DE IMAGENS DE RADAR: MODELOS AUTORREGRESSIVOS E MÉDIA MÓVEL (ARMA)*

Luciano Vieira Dutra
Ministério da Ciência e Tecnologia-MCT
Instituto de Pesquisas Espaciais-INPE
Caixa Postal 515 - 12201 - São José dos Campos - SP

RESUMO

Este trabalho reporta os resultados preliminares de modelagem estatística em aplicações de processamento de imagens. A fase denominada de identificação (que é a determinação da ordem e do tipo de modelo sendo considerado) é o problema básico da tarefa de modelagem. Uma imagem é representada por um processo estocástico bidimensional, e um modelo com duas variáveis independentes apresenta dificuldades adicionais para a identificação; assim para se ter uma idéia inicial do modelo, procura-se usar uma versão linearizada da imagem, concatenando segmentos de linha ou coluna, e formando uma sequência unidimensional. Em se tratando de imagens de radar, aparecem questões adicionais por causa do tipo de ruído presente na imagem, que se supõe multiplicativo. Neste trabalho foi usado o modelo ARMA (autorregressivo e média móvel) com dados originais e transformados por função logarítmica. A imagem usada é uma imagem em máxima resolução SAR-580. Os resultados mostraram que a imagem de radar é composta por um campo estocástico 2D não separável, que é independente da classe. Este fato indica que a textura natural é escondida pelas características do radar. Além disso o modelo no espaço homomórfico mostrou menores correlações indicando maior caráter aleatório do ruído, coerente com a hipótese de menor dependência sinal-ruído nesse espaço.

ABSTRACT

This paper reports the preliminary results of statistical modelling studies for image processing. The identification phase is the basic problem of the modelling task (that is, the order determination of the type of model being considered). An image is represented by a bidimensional stochastic process, and a model, with two independent variables brings additional difficulties to the identification. To overcome this difficulty, one looks for identification using a linearized version of the image, lexicographically organizing the image by lines or by columns. For radar images other questions arise because of the type of noise present in the image, which some authors claim to be multiplicative. In this work we used the ARMA (autorregressive-moving average) model on the original and log transformed data (which transforms the multiplicative noise in additive, if present). The image that was used is a full 512x512 resolution SAR-580 image. Results showed that radar is composed by a 2D nonseparable stochastic field which is class independent. This fact indicates that natural textures is hidden by radar characteristics. Also the model in homomorphic space showed in general, lower correlations indicating a higher random character of noise coherent with the hypothesis of lower signal-noise dependence in this space.

*Suporte Financeiro: SID Informática

1 - INTRODUÇÃO

No campo de processamento de Imagens e Reconhecimento de Padrões, tem havido um esforço mais ou menos recente, em pesquisar novos modelos para descrever o comportamento de imagens, modelos que se mostrem mais adequados para a nova geração de satélites, cada vez com maior resolução, onde a suposição da imagem formada por pontos estatisticamente independentes entre si e governada por uma distribuição gaussiana não são mais válidas. Nesse ponto ganha maior importância a discriminação de texturas na imagem e os pontos elementares ("pixels") não podem mais serem vistos isoladamente, mas formando arranjos mais ou menos regulares. O grau de regularidade dos padrões evidenciados na imagem determinam 2 tipos de métodos de descrição: os estatísticos e os estruturais. Os métodos estatísticos são apropriados para modelar texturas difusas, tais como fotos próximas de grãos de areia na praia, imagens de radar e imagens de satélite com florestas, campos e terrenos acidentados. Nessa classe de métodos podemos salientar os baseados em modelos markovianos (Yu et al, 1983) e os baseados em modelos autorregressivos e de média móvel. Os métodos estruturais, são normalmente baseados em modelos de percepção visual ou modelos sintáticos (Haralick, 1979) e são adequados para imagens que contenham texturas que se caracterizem por um arranjo regular de objetos bem definidos.

Neste trabalho, iniciamos o estudo para a descrição estatística de imagem de radar através de modelos ARMA. Em particular, para imagens de radar aparecem questões adicionais por causa da natureza, que se supõe multiplicativa, do ruído presente na imagem.

O princípio da parcimônia, que considera o modelo mais adequado como sendo aquele que possui o menor número de parâmetros, se aplica para considerar o modelo de ruído que mais se ajusta ao radar.

Serão utilizados neste estudo modelos unidimensionais, mas consideração sobre a significância dos parâmetros obtidos para o modelo ajustado à concatenação de linhas ou colunas de determinadas classes da imagem poderão determinar, dentro de certas restrições, a forma do modelo ARMA bidimensional aplicável a cada classe considerada.

2 - MODELOS DE SÉRIES TEMPORAIS

Uma série temporal é caracterizada por uma sequência de valores no tempo y_1, y_2, \dots, 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 (eq. 1), que são realizações de um processo ruído branco com média zero e variância σ_w , que passam por um filtro linear que caracteriza o processo (Figura 1).



Figura 1. Representação do Filtro gerador do processo

$$y_i = \mu + w_i + \alpha_1 w_{i-1} + \alpha_2 w_{i-2} + \dots \quad (1)$$

Alternativamente, um processo estocástico linear pode ser considerado como uma soma ponderada das observações passadas e o ruído branco corrente (Eq. 2).

$$y_i = \beta_1 y_{i-1} + \beta_2 y_{i-2} + \dots \quad (2)$$

de (1) nós temos o caso particular chamado processo de média móvel (MA(q)) de ordem q (Eq. 3).

$$y_i = \sum_{k=0}^q \alpha_k w_{i-k} + \mu \quad (3)$$

onde $\alpha_0 = 1$; de (2) temos o processo autoregressivo de ordem p (Eq. 4).

$$y_i = \sum_{j=1}^p \beta_j y_{i-j} + w_i \quad (4)$$

Combinando (3) e (4) temos o chamado processo ARMA (p,q) completo (Eq. 5). A necessidade desse modelo aparece para atender ao chamado princípio da parcimônia, dentro da hipótese de aceitabilidade do modelo, sendo que é usado quando uma série não pode ser modelada convenientemente com modelos (3) ou (4).

$$y_i = \sum_{k=0}^q \alpha_k w_{i-k} + \sum_{j=1}^p \beta_j y_{i-j} + \mu. \quad (5)$$

O modelo (5) é unidimensional e poderia ser usado para gerar uma imagem se essa fosse linearizada concatenando-se linhas ou colunas das imagens. Coeficientes não zero em atrasos múltiplos do tamanho da linha responderiam por pontos colocados espacialmente vizinhos ao ponto sendo gerado. Exemplo: o modelo $y_i = 0,5y_{i-1} - 0,4y_{i-256} + w_i$ é um modelo AR(256) com os coeficientes $\beta_j = 0$ para $j = 2 \dots 255$ e significa que (Fig. 2) o ponto é gerado como combinação linear de um vizinho a esquerda e acima adicionado do ruído branco motor do processo, para uma imagem com linhas de 256 pixels.

$$\square \quad y_{i-256}$$

$$y_{i-1} \quad y_i$$

Figura 2 - O modelo de geração de imagens linearizado.

A linearização do processo de formação de imagens conduz a certos problemas de transição entre linhas que serão comentados posteriormente.

Para tomar a transformada Z de um processo que segue o modelo (5) e ignorando a média que pode ser subtraída do processo, rearranjamos a formulação do modelo:

$$y_i - \sum_{j=1}^p \beta_j y_{i-j} = \sum_{k=0}^q \alpha_k w_{i-k}. \quad (5a)$$

tomando a transformada Z

$$(1 - \beta_1 Z^{-1} - \dots - \beta_p Z^{-p}) Y(Z) = (\alpha_0 + \alpha_1 Z^{-1} + \dots + \alpha_q Z^{-q}) W(Z) \quad (6)$$

$$Y(Z) = \frac{(\alpha_0 + \alpha_1 Z^{-1} + \dots + \alpha_q Z^{-q})}{(1 - \beta_1 Z^{-1} - \dots - \beta_p Z^{-p})} W(Z) \quad (7)$$

Para que o processo gerado $Y(z) = H(z)W(z)$ conforme o filtro-modelo $H(z)$ possa ser fisicamente realizável é necessário que o filtro seja estável e invertível (Box et al, 1970) o que significa que os polos e zeros da função de transferência estejam dentro do círculo unitário.

3 - PROPRIEDADES DOS MODELOS ARMA

Para analisarmos algumas propriedades do modelo, vamos verificar como se relacionam os coeficientes do modelo à função de autocorrelação do sinal. Considere o modelo AR(p) (Eq. 3). A autocovariança para um processo estocástico estacionário y_i é dada por

$$\gamma = E \{ y_i y_{i-k} \} \quad (8)$$

Segue então de (4), multiplicando ambos os lados da equação por y_{i-k} e tomando o valor esperado que

$$\gamma_k = \beta_1 \gamma_{k-1} + \beta_2 \gamma_{k-2} + \dots + \beta_p \gamma_{k-p} \quad (9)$$

A função de autocorrelação é dada por

$$\rho_k = \gamma_k / \gamma_0 \quad (10)$$

Então:

$$\rho_k = \beta_1 \rho_{k-1} + \beta_2 \rho_{k-2} + \dots + \beta_p \rho_{k-p} \quad (11)$$

fazendo $k = 1, 2, \dots, p$ obtemos as chamadas equações de Yule Walker, que também são soluções, para o problema de predição linear (Marple, 1987) com a condição de minimização do erro quadrático de predição. Quando a ordem do preditor linear alcança a ordem do modelo AR(p), representante do sinal sendo predito, o resíduo se torna branco.

Se ϕ_{ki} é o i -ésimo coeficiente num processo autorregressivo de k -ésima ordem então as equações de Yule Walker se tornam:

$$\begin{bmatrix} 1 & \rho_1 & & & & & & \\ & \rho_1 & 1 & & & & & \\ & & & \rho_{k-1} & \dots & \rho_{k-2} & & \\ & & & & & & & \\ & & & & & & & \\ \rho_{k-1} & \rho_{k-2} & & & & & & 1 \end{bmatrix} \begin{bmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kk} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \vdots \\ \rho_k \end{bmatrix} \quad (12)$$

Entre os coeficientes ϕ_{ki} o conjunto ϕ_{kk} tem especial interesse, e são chamados função de autocorrelação parcial (FAP(k)). A FAP apresenta um corte para zero para $k > p$ quando o processo é AR(p).

Para um processo MA(q) (Eq. 3) fazendo $\tilde{y}_i = y_i - \mu$ temos

$$\tilde{y}_i = w_i + \alpha_1 w_{i-1} + \dots + \alpha_q w_{i-q}. \quad (13)$$

Sendo a autocovariança dada por

$$\gamma_k = E \{ \tilde{y}_i \tilde{y}_{i-k} \}$$

então

$$Y_k = (\alpha_k + \alpha_{k-1} + \dots + \alpha_{k-q}) \sigma_w^2 \quad k=1, \dots, q=0$$
$$k > q \quad (14)$$

onde

$$\sigma_w^2 = E \{w_i w_i\} \text{ e } E \{w_i w_j\} = 0 \quad i \neq j$$

Logo para um processo MA(q) a função de autocorrelação (FAC) apresenta corte para atrasos maiores que q.

O modelo ARMA completo (eq. 5) não apresenta cortes nem na FAC ou na FAP. De acordo com essas propriedades é possível tentar identificar o modelo subjacente a um processo calculando a FAC e FAP e observando seu aspecto. Na prática porém é preciso estabelecer um critério para saber quando as estimativas são zero devido à variância dos estimadores das autocorrelações. Segundo Granger e Newbold (1977) que cita Anderson (1942) pode-se usar o limite de $2N^{-1/2}$ onde N é o número de amostras como um indicativo mais ou menos grosseiro para saber se as autocorrelações são zero a partir de um certo atraso. Dessa maneira vamos obter imediatamente 2 valores tentativas para MA(q) e AR(p). Para tornar o problema de identificação bem definido, foram introduzidos diversos índices, entre os quais o mais utilizado é o chamado índice de Akaike (1969) que é posto da seguinte forma:

$$AIC[p, q] = N \ln(\hat{\sigma}_{p,q}^2) + 2(p+q) \quad (15)$$

onde $\hat{\sigma}_{p,q}^2$ - variância do ruído estimado para o modelo ARMA (p, q).

O modelo escolhido é aquele que minimiza o índice de Akaike (AIC). A partir dos valores iniciais de \bar{p} e \bar{q} sugeridos pelas funções de autocorrelação escolhe-se também algumas ordens para modelos ARMA(p, q) de tal maneira que $p < \bar{p}$ e $q < \bar{q}$.

4 - ESTIMATIVA DOS PARÂMETROS

A estimativa dos parâmetros α_i e β_i é feita em 2 passos: 1) uma estimativa preliminar que se vale da 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 processo AR(p) é feita substituindo-se as correlações teóricas pelas

estimadas na equação de Yule Walker (12). A forma especial da matriz p x p em (12) (denominada Toeplitz) permite uma solução iterativa simples para os parâmetros do modelo.

Para a estimativa preliminar dos parâmetros do modelo MA(q) utiliza-se do algoritmo denominado das inovações (Kailath, 1968) que também é um algoritmo iterativo.

Uma modificação nas equações de Yule Walker, permite o cálculo dos parâmetros da parte AR do modelo ARMA(p, q) completo utilizando-se da informações da função de autocorrelação para p's atrasos entre $q < j \leq q + p$. A partir de estimativas geradas pelo algoritmo das inovações para o MA(∞) equivalente ao ARMA(p, q) sendo estimado (Brockwell, 1987) e dos parâmetros da parte AR, calculam-se os parâmetros MA do modelo ARMA(p, q).

Tendo sido identificado um modelo tentativa com certos parâmetros iniciais, deseja-se escolher uma estimativa melhor para esses coeficientes. O método mais usado é o método dos mínimos quadrados e que corresponde à minimização da soma dos resíduos quadráticos também chamada de verossimilhança reduzida (Tou, 1986). Deseja-se então encontrar os parâmetros que minimizem

$$S(\hat{\phi}, \hat{\theta}) = \sum_{t=1}^N \mu_t (\hat{\phi}, \hat{\theta})^2 \quad (16)$$

dentre o conjunto de parâmetros possíveis.

Como se trata de um problema de estimação não linear, utiliza-se para obtenção dos parâmetros de métodos iterativos tais como o método de Gauss-Newton (Nelson, 1973).

Deseja-se também calcular uma estimativa do erro de cálculo dos parâmetros.

As estimativas de máxima verossimilhança dos parâmetros dos modelos são variáveis aleatórias desde que são funções dos dados. Da teoria estatística (Nelson, 1973) sabe-se que em condições mais ou menos gerais para "grandes" amostras as estimativas são distribuídas normalmente com matriz de covariância dada por:

$$V(\beta) = 2\sigma_{\mu}^2 \cdot \begin{bmatrix} \frac{\partial^2 S(\beta)}{\partial \beta^2} & \frac{\partial^2 S(\beta)}{\partial \beta_1 \partial \beta_{p+q+1}} \\ \frac{\partial^2 S(\beta)}{\partial \beta^2} & \frac{\partial^2 S(\beta)}{\partial \beta^2} \end{bmatrix}$$

$$\beta = [\bar{\phi}, \bar{\theta}, \mu]$$

As segundas derivadas são calculadas nos valores finais dos parâmetros, utilizando-se do resultado da última linearização no processamento iterativo. A raiz quadrada dos elementos da diagonal principal dão o desvio padrão ($SE(\beta_i)$) do parâmetro. Assim para que um parâmetro β_i seja significativamente $\neq 0$ com 95% de probabilidade basta ver se $|\beta_i| > 2 SE(\beta_i)$

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 o restante dos parâmetros.

5 - MÉTODO UTILIZADO

Neste trabalho foi utilizado o programa PEST de identificação e estimação de parâmetros de modelos ARMA para séries temporais univariadas. Este programa acompanha o livro de Brockwell (1987).

O método de identificação difere conforme o tipo da área de treinamento, se adquirida apenas uma linha ou coluna, ou um conjunto de linhas ou colunas concatenadas.

Para áreas de treinamento lineares temos o seguinte método:

a) Transformações preliminares:

Fazer a transformação logaritmica dos dados se necessário;
Subtrair a média;
Analisar as FAC e FAP.

b) Escolher p máximo para o valor de atraso no qual a FAP cai abaixo do limite de confiança (indicado por traços no gráfico). Escolher q analisando a FAC

c) Para os modelos ARMA(p eq) $p \leq \bar{p}$ e $q \leq \bar{q}$ calcular as estimativas preliminares. Escolher o modelo com menor AIC.

d) Calcular as estimativas de Máxima Verossilhança para o modelo inicialmente separado.

e) Verificar o erro padrão dos coeficientes, se algum coeficiente não for significativo resubmeter o modelo à estimativa de máxima verossilhança zerando o coeficiente não significativo.

f) Checar a "adequabilidade" do modelo, verificando a FAC e FAP dos resíduos. Testar modelo de maior ordem se restarem correlações significativas nos resíduos.

Se a área for conjunto de linhas e colunas:

a) Escolher, usar logaritmo dos dados ou não; Subtrair a média.

b) A FAC vai conter altos valores nos atrasos correspondentes ao comprimento das linhas ou colunas concatenadas. Assim devem ser escolhidas ordens p ou q que compreendam no mínimo mais 2 vezes o comprimento dos segmentos de linhas ou colunas concatenados.

c) Obter as estimativas preliminares para AR(p), MA(q) e ARMA(p,q).

d) De posse do erro padrão dos coeficientes, zerar os não significativos.

e) Submeter os três modelos à estimativa de máxima verossilhança. Escolher o de menor índice de Akaike. Observe que neste caso a natureza bidimensional dos dados vai revelar rapidamente uma área de significância para a descrição do processo pelos três tipos de modelos.

h) Fazer o teste diagnóstico do modelo para verificar se o resíduo é branco, se não for, aumentar a ordem do modelo colocando coeficientes com valor aproximado a 2 vezes o erro padrão; eventualmente diminuir as ordens anulando coeficientes que vieram a se tornar não significativos.

6 - RESULTADOS

Testes foram efetuados em uma imagem de radar de abertura sintética da missão SAR-580 sobre uma área da Alemanha, sensor cujo uso se torna cada vez mais intenso devido a facilidade de se obter imagens em quaisquer condições de tempo. O radar

apresenta no entanto desafios de processamento, pois apresenta o fenômeno da presença de um ruído abrangente denominado "speckle" que se supõe multiplicativo. Foram extraídos 4 áreas de treinamento da classe Floresta e duas áreas da classe Campo.

Dessas 6 áreas 3 são lineares: uma linha e uma coluna sobre a floresta e uma linha sobre o campo.

Analisando a função de autocorrelação das duas classes observou-se que os processos referentes às áreas lineares são bem estáveis pois a FAC cai rapidamente. A FAC e FAP sugerem ordens p de 0,1 ou 2 e q de 0 ou 1. O mesmo tipo de análise foi efetuado submetendo os dados à transformação logaritmica com o objetivo de transformar o ruído multiplicativo em aditivo, obtendo-se ordens semelhantes.

A Tabela I consolida o resultado da identificação e estimativa de máxima verossimilhança dos parâmetros. Os modelos ARMA(p,q) $p > 0$ e $q > 0$ não são mostrados pois em nenhum caso, coeficientes mostraram-se significativos. Na Tabela I são apresentados todos os modelos estimados para a área Floresta (segmento de uma linha) sendo grifado o modelo de menor AIC. Para as outras áreas são apresentados apenas os modelos de menor AIC. Observando-se esses resultados nota-se a pequena variação percentual do AIC entre os diversos modelos sendo que o determinante na identificação foram os erros-padrão sobre coeficientes. O processo estocástico linear referente a uma linha do radar demonstra no geral baixa correlação entre pontos implicando em coeficientes de baixo valor e modelos bem curtos. Os modelos obtidos no campo homomórfico apresentam correlações e coeficientes ainda menores significando a presença de ruído menos correlacionado com sinal, reforçando assim a hipótese de ruído multiplicativo dependente do sinal no campo original. Radar como processo linear comporta-se como sinal adicionado de forte componente aleatório.

Para testar as propriedades bidimensionais da imagem de radar, foram construídas áreas de treinamento compostas de concatenação de pequenos segmentos de linhas ou colunas e essas áreas submetidas à análise do programa PEST. Visto que esse programa calcula as correlações considerando as séries como lineares

espera-se que haja erros no cálculo da correlação nos pontos onde se cruzam as fronteiras entre linhas e colunas, e esse erro é tanto maior quanto maior for a distância de cálculo. A partir de um atraso maior que metade do comprimento dos segmentos de retas passa-se a calcular (com erro) as correlações do ponto com pontos da linha seguinte. Porém como as correlações mais importantes são as de menor atraso e são usadas apenas para cálculo dos parâmetros iniciais da estimativa de máxima verossimilhança então o efeito do erro no cálculo das correlações não é muito importante. Resta ainda outro problema no cálculo das verossimilhanças mas o efeito nesse caso é menor que no cálculo das correlações.

TABELA I
IDENTIFICAÇÃO E ESTIMATIVA
DE ÁREAS LINEARES

| CLASSE | No. PONTOS | TIPO | MODELO | AIC |
|--------------------|------------|------|--|------|
| Floresta Linha | 304 | N | AR(1): $y_i = .362 y_{i-1} + w_i$ | 2338 |
| | | L | AR(1): $y_i = .325 y_{i-1} + w_i$ | -264 |
| | | N | AR(2): $y_i = .406 y_{i-1} - .119 y_{i-2} + w_i$ | 2336 |
| | | L | AR(2): $y_i = .368 y_{i-1} - .127 y_{i-2} + w_i$ | -241 |
| | | N | MA(1): $y_i = w_i + .394 w_{i-1}$ | 2334 |
| | | L | MA(1): $y_i = w_i + .360 w_{i-1}$ | -268 |
| Floresta Coluna | 202 | N | AR(2): $y_i = .645 y_{i-1} - .35 y_{i-2} + w_i$ | 1482 |
| | | L | AR(2): $y_i = .323 y_{i-1} - .138 y_{i-2} + w_i$ | -205 |
| Campo | 148 | N | MA(1): $y_i = w_i + .529 w_{i-1}$ | 836 |
| | | L | MA(1): $y_i = w_i + .315 w_{i-1}$ | -148 |

Devido a restrições do programa PEST, foi necessário utilizar segmentos de tamanho 10 e investigar modelos de ordem 20 ou maior para alcançar pelo menos 2 linhas abaixo do ponto de referência. Os modelos AR(21), MA(21) e ARMA(2,10) conduziram às seguintes configurações de coeficientes levando-se em conta os erros-padrão para a área Floresta (modo de aquisição por linhas de tamanho 10) (Fig. 1) onde significa o ponto de referência e os coeficientes zero não são mostrados.

. 250
.055 .604 -.111 .050
-.222
(a)
 .124
.079 .450
-.142
(b)
 .266
.076 .667 .200
.120
(c)
 .127
.083 .456 .093
(d)
 .265 (AR)
.693 (MA)
(e)
 .130 (AR)
.449 (MA)
(f)

Figura 1 - Configuração de coeficientes (a) AR(21) (b) AR(21) LOG (c) MA(21) (d) MA(21) LOG (e) ARMA(2,10) (f) ARMA(2,10) LOG.

Observa-se que os coeficientes significativos se agrupam em torno do ponto de referência e ocupam o espaço de suporte de meio plano não simétrico ("NSHP suport"). Testes diagnósticos sobre resíduos desses modelos demonstraram que estão bem adequadas pois só apresentam correlação significativa no "lag" zero. Observa-se também que o modelo ARMA(2,10) (notação unidimensional) equivalente ao ARMA(p_x, q_x, p_y, q_y) com $p_x = q_y = 1$ e $p_y = q_x = 0$; é o modelo mais econômico (parcimonioso) pois possui

menor AIC que os outros modelos e apenas 2 coeficientes a considerar. Confirmando a observação para os processos lineares, a opção de identificação homomórfica parece indicar menor correlação global, indicando maior independência do ruído. O resultado apresentado indica porém que a imagem de radar deve ser modelada como puramente bidimensional pois não se verifica a propriedade de separabilidade multiplicativa do modelo.

A Figura 2 apresenta como complemento o modelo para a classe de floresta considerando a aquisição por colunas (10 pontos por segmento); o modelo para a classe campo (aquisição por linhas de 10 pontos), ambos para o caso de menor AIC.

.565 AR
 -.140 MA - .169 MA
.138 .305 MA
(a)
 .405 (AR)
.914 MA
(b)

Figura 2 - Configuração de coeficiente (a) classe Floresta aquisição por colunas de 10 pixels (b) classe campo - aquisição por linhas.

Neste caso observa-se que o modelo ARMA obtido com a concatenação de colunas apresentou um número muito maior de coeficientes MA. Talvez se deva ao fato de que a correlação na vertical ser maior do que na horizontal e a aquisição por colunas concentrou um número maior de pixels em situação de maior correlação. O caso da Figura 2b praticamente segue o padrão dos resultados anteriores para Floresta.

7 - CONCLUSÃO

Observamos neste trabalho que a imagem de radar se compõe de forte componente aleatório principalmente na direção horizontal e que o processo é distintamente 2D de janela curta. Processos estatísticos para tratamento de imagem de radar numa primeira fase não precisarão então de máscaras grandes. O efeito de aleatoriedade se acentuou no campo homomórfico denotando assim maior

distinção do componente aleatório neste campo. A pouca diferença entre modelos de diversas classes indica que as características intrínsecas do radar "escondem" a textura natural do terreno. Uma vez obtido o modelo diversas aplicações são possíveis: detecção de objetos, classificações, detecção de bordas. Ainda no campo de modelagem pretende-se continuar a estudar com a implementação de um estimador de máxima verossimilhança 2D, estudar o efeito sobre o modelo dos filtros redutores de "speckle" existentes na literatura. Deve-se notar também que usou-se primordialmente da análise do erro padrão dos coeficientes como critério de identificação e não o índice AIC.

Pattern Recognition, Coronado, CA, 1976, Aug.

YU, T.S.; FU, K.S.; Recursive contextual classification using a spatial stochastic model. Pattern Recognition 16(1):89-108, 1983.

8- REFERÊNCIAS

- AKAIKE, H.; "Fitting autorregressive models for prediction". Ann Inst. Statisc Math. 21:243-247, 1969.
- ANDERSON, R.L.; "Distribution of serial correlation coefficient", Ann Math. Stat. 13:1-13, 1942.
- BOX, G.E.P; JENKINS, G.M.; Time Series Analysis, Forecasting and Control. Holden Day, San Francisco, 1970.
- BROCKWELL, P.J.; DAVIS, R.A.; Time series: Theory and Methods. Springer Verlag, New York, 1987.
- GRANGER, N.; NEWBOLD, P.; Forecasting Economic Time Series. Academic Press, New York, NY, 1977.
- HARALICK, R.M.; Statistical and structural approaches to texture. Proceedings of the IEEE, 67(5), May, 1979.
- KAILATH, T.; "An innovations approach to least squares estimation - Part I: Linear filtering in additive white noise", IEEE Transactions an Automatic Control, AC-13:646-654, 1968.
- MARPLE, S.L.; Digital spectral analysis, Prentice-Hall, Engle Wood Cliffs, NJ, 1987.
- NELSON, C.R.; Applied Time Series Analysis for Mananagerial Forecasting, Holden Day, San Francisco, CA, 1973.
- TOU, J.T.; KAO, D.B.; CHANG, Y.S.; "Pictorial texture, analysis and syntheses", Third Jount Conf. in