

Classificação Textural de Imagens de Radar de Abertura Sintética, por Modelagem Autorregressiva

SÉRGIO MONTEIRO SOARES¹

LUCIANO VIEIRA DUTRA¹

WALDECIR JOÃO PERRELA²

¹INPE--Instituto Nacional de Pesquisas Espaciais

Caixa Postal 515, 12201- 097 São José dos Campos, SP, Brasil

{msoares,dutra}@dpi.inpe.br

²CTA/ITA-Instituto Tecnológico da Aeronáutica

Praça Marechal Eduardo Gomes, 50, Vila das Acácias, CEP 12228-900

São José dos Campos, SP, Brasil

waldecir@ele.ita.cta.br

Abstract. The aim of this work is to present a supervised method to classify SAR images based on texture feature extraction using autorregressive modeling. The method was tested using a JERS-1 (L band) SAR image from "Floresta Nacional do Tapajós", Pará State, Brazil. The identified classes were Dense Primary Forest and Undulate Primary Forest. A Landsat TM image in color composition RGB-543, from the same area was used as ground reference. A Maximum Likelihood classifier was used to classify a set of filtered (inverse autorregressive filters) bands from the original SAR image. The results were analyzed using the confusion matrix, and showed a Kappa coefficient of 96.1 %, instead of a Kappa of 36.1 % using the original channel only.

Keywords: Remote Sensing, SAR Image Classification, Autorregressive modeling..

1 Introdução

Como não existe uma definição matemática formal para textura, em imagens de sensoriamento remoto (Crosta, 1992), podemos referenciá-la como o padrão com que se apresentam as diversas estruturas da superfície real imageada. Esta imagem digital é composta por uma matriz de pixels ("picture elements"). Em outras palavras, textura é o efeito coletivo destes pixels, causando uma impressão perceptível ao olho humano do padrão com que se apresentam as superfícies naturais.

No espectro óptico (λ variando de 0,3 μm à 2,2 μm), compreendendo desde o ultra-violeta até o infravermelho termal, a textura serve como um item auxiliar na classificação dos dados imageados. Os sensores modernos nesta faixa do espectro conseguem segmentar a faixa de frequência do espectro óptico em diversas bandas (Lillesand, et al, 1987; Slater, 1980), possibilitando a classificação das imagens baseado com comportamento espectral dos alvos.

Em imagens de RADAR de Abertura Sintética a segmentação espectral é mais complexa, uma vez que o imageamento se processa geralmente numa frequência específica. Nesse caso, pode-se apenas variar a polarização dos sinais emitidos e recebidos, obtendo-se imagens polarimétricas (Ahern, 1994).

A maioria dos satélites imageadores de radar disponíveis dispões de apenas 1 polarização, um canal portanto, e nestes casos a textura tem um papel fundamental na análise e classificação destas imagens, uma vez que ela representa a mudança dos padrões naturais da superfície imageada, permitindo a diferenciação de alvos (classes). Textura, no contexto deste trabalho, será modelada em termos de modelos estatísticos espaciais denominados Modelos Autorregressivos bi-dimensionais (AR2D).

2 Modelos Autorregressivos.

Considerando uma imagem SAR como campos aleatórios fracamente estacionários, para uma mesma classe de cobertura do solo, uma abordagem de séries temporais autorregressivas bi-dimensionais (AR2D) pode ser utilizada com a finalidade de modelar o comportamento espacial destas imagens, para essas classes.

No caso empregado neste trabalho, este campo bi-dimensional, para a finalidade de modelagem, é transformado em uma série uni-dimensional pela concatenação de segmentos de linha da imagem, que pertençam à uma mesma classe. Modelos autorregressivos (AR) são ajustados a essas séries temporais. A operação de concatenação de linhas da imagem gera um mapeamento que será depois utilizado para remapear os coeficientes estimados para o modelo AR para o plano (modelo AR2D)(Dutra, 1990).

Os modelos AR são um caso particular dos modelos Autorregressivos e Média Móvel (ARMA) que supõem a série temporal como gerada por um filtro linear (Fig. 2.1) excitado por um ruído branco, isto é, uma sequência temporal de variáveis aleatórias independentes, identicamente distribuídos com média nula e variância σ^2 , IID(0, σ^2) denominados de *shocks*. Em imagens SAR, uma amostra de uma determinada textura homogênea, após a concatenação de linhas, será então considerada como uma série temporal sobre a qual basear-se-á toda a estimação deste modelo.



Figura 2.1 - Série temporal Z_t como saída de um filtro linear, excitado por um ruído branco a_t .

O filtro linear pode ser descrito como uma soma ponderada de observações e entradas prévias, a chamada equação diferença. Esta soma, com número de coeficientes finito ou infinito, será convergente para processos estacionários, e o filtro será dito estável. A representação desta soma é descrita pela **equação 2.1** (Marple, 1988).

$$Z_t = \sum_{k=1}^p f_k \cdot Z_{t-k} - \sum_{k=0}^q q_k \cdot a_{t-k} + m \quad (2.1a)$$

ou

$$Z_t^* = f_1 \cdot Z_{t-1}^* + \dots + f_p \cdot Z_{t-p}^* + a_t - q_1 \cdot a_{t-1} - \dots - q_q \cdot a_{t-q} \quad (2.1b)$$

onde: $Z_t^* = Z_t - m$; e

Os coeficientes f_i são os parâmetros autorregressivos e q_i , os média móvel. Este é o modelo ARMA(p,q), de ordem p e q , $\theta_0 = -1$, sem perda de generalidade.

Das equações 2.1a e 2.1b, pode-se extrair o modelo puramente autorregressivo ($q=0$) na forma das equações 2.2a e 2.2b, abaixo:

$$Z_t = \sum_{k=1}^p f_k \cdot Z_{t-k} + a_t + m \quad (2.2a)$$

$$Z_t^* = f_1 \cdot Z_{t-1}^* + \dots + f_p \cdot Z_{t-p}^* + a_t \quad (2.2b)$$

onde, aqui também, $Z_t^* = Z_t - m$

Os parâmetros f_i , nas equações 2.2a e 2.2b, podem ser estimados pela equações de Yule-Walker, utilizando um algoritmo recursivo de Levinson-Durbin, como descrito por Kay, (1988), páginas 170 e 171.

3 Metodologia

Neste trabalho os atributos de texturas foram extraídos da imagem original a partir da filtragem *inversa* da imagem original por filtros correspondentes às diversas classes presentes à imagem original. Filtragem inversa corresponde à operação de filtragem utilizando-se os filtros autorregressivos de forma a recuperar os *shocks* de entrada que produziram as diversas texturas presentes na imagem. Estes *shocks*, que na operação de filtragem inversa denominam-se de resíduos, formam um campo ruído branco, nas regiões casadas com as amostras utilizadas para o cálculo dos parâmetros dos modelos AR que são ajustados a cada textura de interesse. Tem também menor variância nas regiões casadas devido à forma como são estimados os parâmetros.

A metodologia descrita sumariamente pelos passos a seguir, são explicadas detalhadamente em Soares(1998):

Etapas 1: Escolha da Imagem e Coleta de Amostras de Treinamento

Escolha da imagem ou parte dela a ser classificada. Nesta fase escolhem-se também o número e os tipos de classes, as quais se deseja discriminar na imagem.

Colhem-se amostras das classes texturais. Para implementação do método, as amostras devem ser retangulares, com um igual número de colunas de todas as amostras de uma mesma classe. Considerando-se uma série temporal obtida pela concatenação de segmentos de linhas das amostras das diferentes classes, calculam-se as funções de autocorrelação (FAC) unidimensionais, que serão utilizadas na fase de modelagem.

- Etapa 2: Cálculo dos Parâmetros e Filtros Inversos Autorregressivos

Dispondo das FACs para cada classe, calculam-se os parâmetros autorregressivos para a série temporal concatenada. Os parâmetros autorregressivos menores que o níveis de significância calculados conforme Brockwell & Davis (1987, páginas 231-238) são excluídos dos modelos de cada classe. Os parâmetros dos modelos AR são mapeados para o plano conforme demonstrado em Dutra(1990).

- Etapa 3: Filtragens Inversas AR, Branqueamento e Energia

A partir da imagem original, aplicam-se sucessivamente os filtros inversos autorregressivos, casados com cada classe. A média de cada classe é subtraída antes da aplicação do filtro respectivo. Quando uma região é filtrada pelo filtro casado correspondente, duas características são observadas nesta condição: dentre os filtros inversos este é o que apresenta menor energia (eq. 3.2) na saída, além de ser um campo aproximadamente branco. Para medir o *branqueamento* da saída dos filtros inversos o seguinte operador que atua em uma vizinhança do ponto de coordenadas (i,j) é definido:

$$b_L = \sum_{m,n \in W} \frac{(x_{m,n} - \bar{x}) \cdot (x_{m,n+1} - \bar{x})}{\#W} + \sum_{m,n \in W} \frac{(x_{m,n} - \bar{x}) \cdot (x_{m+1,n} - \bar{x})}{\#W} \quad (3.1)$$

onde b_L é o coeficiente de branqueamento que substituirá o pixel central da janela W; $\#W$ é a cardinalidade da janela. b_L é a soma das autocorrelações de atraso 1, a partir do centro da máscara W e apresenta valores próximos de zero para campos aleatórios de ruído branco.

A medida de energia em torno do ponto (i,j) é dada pela seguinte formulação:

$$FEn(i, j) = \sqrt{\frac{\sum_{m,n \in W}^n (x_{m,n})^2}{\#W}} \quad (3.2)$$

onde $x_{m,n}$ é o valor do pixel na posição (m,n).

Deste modo teremos M bandas de imagens filtradas, onde M é igual ao numero de classes multiplicado por três, onde cada classe possui as seguintes bandas filtradas:

- Uma primeira banda é a própria saída dos filtros inversos.
- Uma segunda banda é o coeficiente de branqueamento calculado para as saídas dos filtros inversos.
- Uma terceira é a banda de energia, também calculada para as saídas dos filtros inversos.
- Etapa 4: Classificações de Máxima Verossimilhança

O conjunto de bandas filtradas da imagem original é então classificado pelo classificador de Máxima Verossimilhança, com as mesmas amostras de treinamento que geraram os parâmetros AR. (Soares, 1998)

Ainda nesta fase, coletam-se sobre a imagem original, outras amostras para cada classe, em regiões diferentes das escolhidas para a coleta das amostras de treinamento do modelo, com a finalidade de servirem para o cálculo da matriz de confusão, bem como o cálculo do *kappa*, índice que indica o grau de acerto do classificador digital (Vieira, 1996).

4 Resultados.

Para testar o método escolheu-se um mosaico JERS-1, da Região da Floresta Nacional do Tapajós, no Estado do Pará, Brasil, contendo duas texturas discrepantes, representativas de dois tipos de florestas: Floresta Densa, e Floresta Ondulada, mostrado na **figura 4.1**.




Figura 4.1 - Mosaico JERS-1 contendo Floresta Densa e Floresta Ondulada da Floresta Nacional do Tapajós, Pará, Brasil.

Sobre o mosaico foram colhidas as amostras de cada classe como na **figura 4.2**, abaixo.




Figura 4.2 - Amostras das duas classes de Florestas

Procedendo-se a segunda etapa, calcularam-se os parâmetros e filtros inversos AR de cada classe. Na terceira fase aplicaram-se os filtros inversos e obtiveram-se os canais branqueamento e energia para cada classe, dando um total, portanto, de seis canais. As dimensões dos filtros e número de colunas das amostras devem ser compatíveis com a escala de observação da textura, que se quer discriminar.

Aplicando a classificação de Máxima Verossimilhança, no conjunto gerado com todas as seis bandas obtidas na etapa 3, obteve-se o resultado da **figura 4.3**. Nesta figura vale ressaltar duas observações:

1) Existe uma borda, ao redor da imagem classificada, na cor equivalente ao nível de cinza mais baixo, devido à largura das janelas de cálculo das bandas de energia e branqueamento.

2) Na parte superior esquerda da imagem classificada poder-se-ia deduzir que o classificador não foi eficiente. Porém se observarmos a imagem original, notar-se-á, que esta região corresponde a uma outra classe não estudada (regeneração), portanto resultando numa resposta não significativa, para esta avaliação.



Figura 4.3 – Classificação sobre o conjunto de todas as bandas geradas na etapa-3.

A matriz de confusão para o resultado desta classificação, para amostras de teste, encontra-se na **tabela 4.1**:

Tabela 4.1 - Matriz de Confusão da Classificação de Máxima Verossimilhança sobre todas as seis bandas geradas na Etapa-3.

Classes /Classificação	Não Classificado	DENSA	ONDULADA	Σ
N Classificado	0 / 0%	0 / 0%	0 / 0%	0
DENSA	0 / 0%	35655 / 98%	633 / 2%	36288
ONDULADA	0 / 0%	789 / 2%	34691 / 98%	36480
Σ	0	36444	36424	72768
Kappa: 0,960917			σ_k^2 : 1,05332E-06	

Com a finalidade de comparação com o caso padrão, ao utilizar-se apenas o canal original para classificação por Máxima Verossimilhança obtêm-se o resultado apresentado na **figura 4.4**..




Figura 4.4 - Imagem Original JERS-1, Classificada por Máxima Verossimilhança.

Coletaram-se as mesmas amostras de teste para o cálculo da matriz de confusão, tendo como resultado a **tabela 4.2.**:

Tabela 4.2 - Matriz de Confusão da Classificação sobre a Imagem Original JERS-1.

Classes /Classificação	Não Classificado	DENSA	ONDULADA	Σ
N Classificado	0 / 0%	0 / 0%	0 / 0%	0
DENSA	0 / 0%	30943 / 85%	5345 / 15%	36288
ONDULADA	0 / 0%	17723 / 49%	18757 / 51%	36480
Σ	0	48666	24102	72768
	Kappa: 0,366549		σ_k^2 : 2,6728E-05	

5 Conclusões

Com os resultados da experimentação da modelagem autorregressiva para distinção de texturas em imagens SAR, especificamente JERS-1, da Floresta Amazônica, pode-se concluir os seguintes tópicos:

- 1) A classificação de Máxima Verossimilhança pontual aplicada à imagem JERS-1 original, não conseguiu separar as classes em estudo.
- 2) A metodologia de extração de atributos de textura por modelagem AR, foi **bastante eficiente** quando aplicada às texturas JERS-1, para separação de florestas primárias.

Agradecimentos

Os autores deste trabalho são gratos aos seguintes pesquisadores do INPE: Dra Corina da Costa Freitas, MsC Sidnei João Siqueira Sant'anna e MsC Camilo Daleles Renó, nas suas diversas contribuições quanto à conceituação do modelo e valiosa ajuda na implementação do programa em IDL.

Referências

- Ahern, F.J. *Basic Concepts of Imaging Radar, a Intensive Course*. Instituto Nacional de Pesquisas Espaciais, São José dos Campos, Outubro, 1994.
- Brockwell, P.J.; Davis, R. A. *Times series: theory and methods*. Berlin, Springer- Verlag, 1987.
- Crosta, A. P. *Processamento Digital de Imagens de Sensoriamento Remoto*. Campinas, SP, UNICAMP, 1992, 170p.
- Dutra, L. *Classificação de Texturas usando Modelos ARMA e Distâncias da Função de Autocorrelação*. (Tese de Doutorado em Computação Aplicada). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, Abril 1990, 162 p. (INPE-5067-TDL/406).
- Kay, S.M. *Modern Spectral Estimation: Theory & Application*. New Jersey, Englewood Cliffs, 1988, 543 p.
- Lillesand T., M.; Kiefer, R. W. *Remote Sensing and Image Interpretation*. John Wiley & Sons, New York, NY, 1987.
- Marple, S. L. *Digital spectral analysis*. Englewood Cliffs, NJ, Prentice-Hall, 1987.
- Slater, N. P. *Remote Sensing: Optics and optical systems*. Addison-Wesley Publishing Company, London, 1980.
- Soares, S.M. Classificação textural de imagens de radar por modelagem estatística autorregressiva. Dissertação de Mestrado em Sensoriamento Remoto. Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, 1998.
- Vieira, P.R. *Desenvolvimento de Classificadores de Máxima Verossimilhança para Imagens SAR*. Dissertação de Mestrado em Sensoriamento Remoto. Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, 1996.