

MINISTÉRIO DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-7499-TDI/714

SÍNTESE DE TEXTURAS UTILIZANDO MODELOS ESTATÍSTICOS ESPACIAIS

Eduardo Quesado Filgueiras

Dissertação de Mestrado em Computação Aplicada, orientada pelo Dr. Luciano Vieira
Dutra, aprovada em 13 de julho de 1998.

INPE
São José dos Campos
2000

528.711.7:551

FILGUEIRAS, E.Q.

Síntese de Texturas Utilizando Modelos Estatísticos Espaciais
/ E. Q. Filgueiras. - São José dos Campos: INPE, 1998.
182 p. - (INPE-7499-TDI/714).

1.Modelagem. 2.Síntese. 3.Texturas. 4.Autorregressivo. 5.
Média Móvel. 6.Concatenação. I. Título.

"O princípio da sabedoria é: adquira a sabedoria; sim, com tudo o que possui adquira o entendimento. Estima-a, e ela te exaltará; se a abraçares, ela te honrará; dará a tua cabeça um diadema de graça, e uma coroa de glória te entregará."

Pv 4.7-9

À Janaina,
minha querida esposa,
dedico.

AGRADECIMENTOS

Ao meu orientador, Dr. Luciano Vieira Dutra, a quem devoto a mais sincera e efusiva admiração.

Aos membros da banca examinadora pelas opiniões valiosas e preciosas sugestões.

À Divisão de Processamento de Imagens, pelo apoio material concedido, e aos colegas que, direta ou indiretamente, contribuíram para o enriquecimento deste trabalho.

Aos aos companheiros do Ministério da Aeronáutica que, com seu apoio, permitiram que tivesse esta grande oportunidade, principalmente aos membros do Centro de Computação da Aeronáutica de São José dos Campos e da Comissão de Fiscalização e Recebimento de Materiais do Sistema de Vigilância da Amazônia.

Ao meu grande amigo Marcus Vinícius Pereira Pessôa.

E, em especial, a minha querida esposa Janaina Tauchen Filgueiras e a todos que me apoiaram, emocional e espiritualmente.

RESUMO

O escopo deste trabalho concentra-se no uso de métodos capazes de geração de texturas sintéticas de aparência natural, a partir da reprodução de padrões fonte previamente selecionados. Modelos estatísticos espaciais são a base para os métodos utilizados, especificamente a modelagem baseada em processos autorregressivos e de média móvel para a estimação de parâmetros e geração de padrões de textura. Dois métodos são utilizados para a estimação de parâmetros, ambos baseados em processos autorregressivos. O primeiro método é baseado na utilização da função de autocorrelação linear e na concatenação de linhas e colunas da textura analisada. O segundo método utiliza a função de autocorrelação bidimensional concatenada, sendo capaz de evitar a acumulação de erros ocasionada por correlações indesejadas geradas pelo processo de concatenação de linhas e colunas, ao ser utilizada a autocorrelação linear. O procedimento de síntese é baseado na geração de um campo ruído branco bidimensional de média zero e mesma variância dos resíduos obtidos a partir do processo de modelagem, que é o ruído branco motor de um processo autorregressivo bidimensional, o qual resultará na textura sintética. Para imagens de radar de abertura sintética, foi utilizada uma técnica de pré-processamento submetendo as amostras das imagens à transformação pela curva raiz cúbica, como uma forma de obtenção de distribuição aproximadamente gaussiana. Imagens obtidas por sensores óticos dos satélites Landsat-5 e JERS-1 também são submetidas aos métodos, bem como texturas naturais tais quais mármore e granito. Um programa computacional gráfico multiplataforma utilizando linguagem IDL foi desenvolvido, contendo todas as funcionalidades necessárias para a modelagem autorregressiva e a síntese de texturas.

TEXTURE SYNTHESIS USING STATISTICAL SPATIAL MODELS

ABSTRACT

The scope of this work is the use of methods capable of generating natural looking synthetic textures reproducing previously selected source patterns. Spatial statistic models are the basis for the used methods, specifically autoregressive moving average modeling for parameter estimation and texture pattern generation. Two methods are used for parameter estimation; both are based on autoregressive processes. The first method is based on using the linear autocorrelation function and on concatenating rows and columns of the analyzed texture. The second method uses a concatenated two-dimensional autocorrelation function, and is able to avoid cumulative errors caused by undesired correlations generated by the row and column concatenation process using linear autocorrelation. The synthesis procedure is based on generating a zero mean two-dimensional random white noise field which has the same variance as the residuals obtained from the modeling process. This white noise is the driver for a two-dimensional autoregressive process, which results in a synthetic texture. For synthetic aperture radar images, a pre-processing technique using cubic root transformation on the image samples is used, as a way to obtain a near-Gaussian distribution. Images obtained by Landsat-5 and JERS-1 optical sensors are also tested, and so do natural textures such as marmour and granite. A graphic multiplatform computer-based program was developed using IDL language, containing all necessary functionalities for autoregressive modeling and texture synthesis.

SUMÁRIO

	<u>Pág.</u>
LISTA DE FIGURAS.....	17
LISTA DE TABELAS.....	23
LISTA DE SÍMBOLOS.....	25
LISTA DE SIGLAS E ABREVIATURAS.....	29
CAPÍTULO 1 - INTRODUÇÃO.....	31
1.1 - Objetivos.....	31
1.2 - Síntese de Texturas: sua Importância.....	31
1.3 - O Que é Textura?.....	32
1.4 - Revisão Bibliográfica.....	36
1.5 - Síntese de Texturas por Modelagem Estatística Espacial.....	40
CAPÍTULO 2 - MODELOS ESTATÍSTICOS ESPACIAIS.....	43
2.1 - Séries Temporais.....	43
2.2 - Processos Estocásticos.....	44
2.3 - Estacionariedade e Estacionariedade Estrita.....	44
2.4 - Modelos Paramétricos de Processos Estocásticos.....	46
2.5 - Modelos ARMA.....	48
2.6 - Modelos ARMA Unidimensionais.....	49
2.6.1 - Processos ARMA Causais e Inversíveis.....	50
2.6.2 - Modelos MA.....	55
2.6.3 - Modelos AR.....	56
2.6.4 - Relação entre Modelos de Séries Temporais.....	57
2.6.5 - Relacionamento entre os Parâmetros de um Modelo ARMA e a Função de Autocorrelação.....	58
2.6.6 - Função de Autocorrelação Parcial.....	60
2.6.7 - Algoritmo de Levinson-Durbin.....	62
2.7 - Modelos ARMA Bidimensionais.....	65
2.7.1 - Natureza.....	65
2.7.2 - Causalidade, Computabilidade Recursiva e Regiões de Suporte.....	65
2.7.3 - Funções de Autocovariância e Autocorrelação Bidimensional.....	68
2.7.4 - Processos AR, MA e ARMA Bidimensionais (2D).....	69
2.7.5 - Equações de Yule-Walker Bidimensionais Utilizando Região de Suporte de Quarto de Plano.....	70

CAPÍTULO 3 - MATERIAIS E MÉTODOS EMPREGADOS 71

3.1 - Adequação das Imagens SAR a Modelos Estatísticos Gaussianos Utilizando Curva de Raiz Cúbica.....	71
3.2 - Estimativa dos Coeficientes para a Modelagem de Filtros	74
3.2.1 - Primeiro Método: Concatenação dos Dados da Imagem e Utilização da Função de Autocorrelação Linear	75
3.2.1.1 - Limites do Intervalo para a Consideração de Valores Nulos nas Funções de Autocorrelação e Autocorrelação Parcial	78
3.2.1.2 - Seleção da Ordem dos Modelos	79
3.2.1.3 - Estimação Preliminar de Valores dos Coeficientes Autorregressivos e Definição de Intervalos de Confiança	82
3.2.1.4 - Diagnóstico Sobre os Resíduos Gerados pela Filtragem Inversa	84
3.2.2 - Segundo Método: Concatenação da Função de Autocorrelação Bidimensional	86
3.3 - Determinação Preliminar de Coeficientes para Modelos AR Bidimensionais.....	88
3.4 - Síntese de Texturas.....	89
3.4.1 - Obtenção dos Resíduos da Imagem.....	92
3.4.2 - Regeneração da Imagem Natural.....	92
3.4.3 - Geração de Texturas a Partir de um Campo Aleatório Branco	93
3.4.4 - Avaliação dos Resultados.....	94
3.5 - Software e Equipamentos de Apoio	95

CAPÍTULO 4 - RESULTADOS OBTIDOS 97

4.1 - Modelagem Estatística Autorregressiva.....	98
4.1.1 - Imagens SAR.....	99
4.1.1.1 - Utilização das Curvas Cúbicas para a Gaussianização dos Dados.....	99
4.1.1.2 - Estimação de Parâmetros Utilizando Modelagem Autorregressiva a Partir da Concatenação dos Dados da Imagem e a Função de Autocorrelação Unidimensional	102
4.1.1.3 - Estimação de Parâmetros Utilizando Modelagem Autorregressiva de Dados Concatenados e a Função de Autocorrelação Bidimensional Concatenada ...	112
4.1.1.4 - Diagnóstico Sobre os Resíduos	116
4.1.2 - Imagens Óticas (JERS e Landsat)	119
4.1.2.1 - Estimativa de Parâmetros Utilizando Modelagem Autorregressiva a Partir da Concatenação dos Dados da Imagem e a Função de Autocorrelação Unidimensional	121
4.1.2.2 - Estimativa de Parâmetros Utilizando Modelagem Autorregressiva de Dados Concatenados e a Função de Autocorrelação Bidimensional Concatenada ...	123
4.1.2.3 - Diagnóstico Sobre os Resíduos	124
4.1.3 - Texturas de Brodatz	126
4.1.3.1 - Estimativa de Parâmetros Utilizando Modelagem Autorregressiva a Partir da Concatenação dos Dados da Imagem e a Função de Autocorrelação Unidimensional	127

4.1.3.2 - Estimativa de Parâmetros Utilizando Modelagem Autorregressiva de Dados Concatenados e a Função de Autocorrelação Bidimensional Concatenada ...	128
4.1.3.3 - Diagnóstico Sobre os Resíduos	129
4.2 - Síntese de Texturas.....	131
4.2.1 - Imagens SAR.....	132
4.2.1.1 - Regeneração das Imagens Fonte.....	132
4.2.1.2 - Geração de Texturas a Partir de Campo Aleatório Branco	135
4.2.1.3 - Avaliação dos Resultados.....	141
4.2.1.3.1 - Comparação entre os Resultados Obtidos por Texturas Gaussianizadas e Não Gaussianizadas	145
4.2.1.3.2 - Comparação entre os Métodos de Modelagem Autorregressiva.....	146
4.2.2 - Imagens Óticas Landsat-5 e JERS-1	149
4.2.2.1 - Regeneração das Imagens Fonte.....	149
4.2.2.2 - Geração de Texturas a Partir de Campo Aleatório Branco	149
4.2.3 - Texturas de Brodatz	155
4.2.3.1 - Regeneração das Imagens Fonte.....	155
4.2.3.2 - Geração de Texturas a Partir de Campo Aleatório Branco	156
4.2.3.3 - Exemplos Suplementares de Síntese de Texturas Utilizando Texturas com Componentes Levemente Determinísticos	161
CAPÍTULO 5 - CONCLUSÕES E SUGESTÕES.....	163
REFERÊNCIAS BIBLIOGRÁFICAS	167
APÊNDICE A - CARACTERÍSTICAS DO SOFTWARE SINTETIZADOR DE TEXTURAS AUTORREGRESSIVAS	173
APÊNDICE B - CARACTERÍSTICAS DO SENSOR ÓTICO DO SATÉLITE JERS-1.....	181

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Filtro Linear	50
2.2 Modelo Autorregressivo e de Média Móvel (ARMA) de um processo aleatório.	55
2.3 Modelo Média Móvel (MA) de um processo aleatório.	56
2.4 Modelo Autorregressivo (AR) de um processo aleatório.	57
2.5 Sumário da Recursividade de Levinson.....	64
2.6 Computação Recursiva de uma equação diferença bidimensional. (a) Região de suporte para f_{ij} ; (b) Computação da saída do sistema..	67
2.7 Exemplos de Regiões de Suporte NSHP e QP.	68
3.1 Modelo sugerido para imagens de radar com baixo número de looks(M).....	72
3.2 Imagem SAR da Floresta Nacional do Tapajós (floresta tropical densa de terreno ondulado).	74
3.3 Histogramas da imagem SAR da região do Rio Tapajós. (a) original; (b) resultante da curva cúbica.	74
3.4 Transformação de uma série bidimensional em uma série unidimensional..	75
3.5 Relação entre correlações concatenadas sobre uma série concatenada e o posicionamento no plano dos pontos, para atraso M-1.....	76
3.6 Autocorrelação de resíduos obtidos a partir da imagem da Figura 3.2.....	85
3.7 Processo de obtenção da meia ACF2D linearizada (concatenação).	87
3.8 ACF 2D de imagem SAR da área do rio Tapajós (Figura 3.2).....	88
3.9 Imagem SAR da área do rio Tapajós obtida pelo satélite JERS-1.....	90
3.10 Imagem ótica obtida pelo satélite Landsat-5 (área do Tapajós).....	90
3.11 Texturas naturais granito (a), mármore (b) e junco(c).	91
3.12 Verificação de Ajuste do Modelo	93

4.1	Imagens SAR da Floresta Nacional do Tapajós obtidas pelo satélite JERS-1. (a) Floresta tropical aberta (FTA) (b) Floresta tropical densa de relevo plano (FTDP).....	99
4.2	Imagem obtida a partir da imagem da FTA (Figura 4.1.a) utilizando a curva raiz cúbica.	101
4.3	Histogramas das imagens da FTA (Figura 4.1.a) (a) e da FTA após reescalonamento pela raiz cúbica (Figura 4.2) (b), respectivamente.	101
4.4	Imagem obtida a partir do reescalonamento da imagem da FTDP (Figura 4.1.b) pela curva raiz cúbica.	102
4.5	Histogramas das imagens da FTDP (Figura 4.1.b) (a) e do reescalonamento da FTDP pela raiz cúbica (Figura 4.4) (b), respectivamente.	102
4.6	ACF (a) e PACF (b) da floresta tropical aberta (FTA).....	103
4.7	ACF (a) e PACF (b) da floresta tropical densa de relevo plano (FTDP).....	104
4.8	Áreas de Treinamento (regiões de estudo) A_1 (a) e A_2 (b) escolhidas para a imagem FTA original, cujo histograma é apresentado em (c).	105
4.9	Modelos α_1 e α_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTA (Figura 4.1.a), sem reescalonamento pela raiz cúbica, para as áreas de treinamento A_1 e A_2	105
4.10	Áreas de Treinamento (regiões de estudo) B_1 (a) e B_2 (b) escolhidas para a imagem FTA reescalada pela curva raiz cúbica, cujo histograma é apresentado em (c).	107
4.11	Modelos β_1 e β_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTA com reescalonamento pela raiz cúbica (Figura 4.2), para as áreas de treinamento B_1 e B_2	107
4.12	Áreas de Treinamento (regiões de estudo) Γ_1 (a) e Γ_2 (b) escolhidas para a imagem FTDP, sem reescalonamento pela curva raiz cúbica, cujo histograma é apresentado em (c).	109
4.13	Modelos γ_1 e γ_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTDP sem reescalonamento pela raiz cúbica (Figura 4.1.b), para as áreas de treinamento Γ_1 e Γ_2	109
4.14	Áreas de Treinamento (regiões de estudo) Δ_1 (a) e Δ_2 (b) escolhidas para a imagem FTDP, com reescalonamento pela curva raiz cúbica, cujo histograma é apresentado em (c).	111

4.15	Modelos δ_1 e δ_2 AR2D obtidos a partir de modelos AR(26) e AR(50), respectivamente, para a textura fonte contida na imagem da FTDP com reescalonamento pela raiz cúbica (Figura 4.4), para as áreas de treinamento Δ_1 e Δ_2	111
4.16	ACF2D concatenada para a FTA (a) e FTDP (b), respectivamente.	113
4.17	Modelos ε_1 e ε_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTA (Figura 4.1.a), sem reescalonamento pela raiz cúbica, para as áreas de treinamento A_1 e A_2 (Figura 4.8), utilizando a ACF2D concatenada.....	113
4.18	Modelos φ_1 e φ_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTA com reescalonamento pela raiz cúbica (Figura 4.2), para as áreas de treinamento B_1 e B_2 (Figura 4.10), utilizando a ACF2D concatenada.....	114
4.19	Modelos φ_1 e φ_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTDP sem reescalonamento pela raiz cúbica (Figura 4.1.b), para as áreas de treinamento Γ_1 e Γ_2 (Figura 4.12), utilizando a ACF2D concatenada.....	115
4.20	Modelos η_1 e η_2 AR2D obtidos a partir de modelos AR(26) e AR(50), para a textura fonte contida na imagem da FTDP com reescalonamento pela curva raiz cúbica (Figura 4.4), para as áreas de treinamento Δ_1 e Δ_2 (Figura 4.14), utilizando a ACF2D concatenada.	116
4.21	Modelos MA2D inversos obtidos a partir de modelos AR2D, para a textura fonte contida na imagem da FTA (Figura 4.1.a). Foi considerada a definição automática de regiões de suporte NSHP.....	117
4.22	Autocorrelações dos resíduos gerados a partir das texturas das imagens: (a) modelo α_1 para FTA; (b) modelo α_2 para FTA; (c) modelo ε_1 (utilizando ACF2D concatenada) para FTA; (d) modelo β_1 para FTA com reescalonamento pela raiz cúbica; (e) modelo ϕ_1 (utilizando ACF2D concatenada) para FTDP; (f) modelo γ_1 para FTDP; ($Lag_{m\acute{a}x} = 300$).....	118
4.23	Imagens óticas. (a) Tokyo (JERS-1); (b) Rio de Janeiro (Landsat-5).....	120
4.24	Histogramas de imagens óticas. (a) Tokyo; (b) Rio de Janeiro.	121
4.25	Imagens óticas com representação das áreas de treinamento (regiões de estudo) para Tokyo (Λ) e Rio de Janeiro (M).....	122

4.26	Modelo AR2D obtido a partir de modelo AR(36), para a textura fonte obtida a partir da imagem de Tokyo (Figura 4.23.a). Foi considerada a definição automática de região de suporte NSHP.	122
4.27	Modelo AR2D obtido a partir de modelo AR(78), para a textura fonte obtida a partir da imagem do Rio de Janeiro (Figura 4.23.b).	123
4.28	Modelos AR2D obtidos a partir das texturas fonte obtidas das imagens da Figura 4.23. O modelo π referencia a imagem ótica JERS de Tokyo e o modelo τ referencia a imagem Landsat do Rio de Janeiro, utilizando a autocorrelação bidimensional concatenada para a estimação de parâmetros.	124
4.29	Modelos MA2D inversos obtidos a partir das texturas fonte obtidas das imagens óticas de Tokyo (Região Λ) e do Rio de Janeiro (Região M), utilizando os dois métodos de modelagem.	125
4.30	Autocorrelações dos resíduos das imagens óticas da Figura 4.23 com o uso da ACF linear para estimação. (a) Modelo λ (Tokyo); (b) Modelo μ (Rio de Janeiro).	125
4.31	Autocorrelações dos resíduos das imagens óticas da Figura 4.23 com o uso da ACF2D concatenada para estimação. (a) Modelo π (Tokyo); (b) Modelo τ (Rio de Janeiro).	126
4.32	Texturas de Brodatz. (a) Granito; (b) Mármore.	127
4.33	Áreas de treinamento Ω e Ψ para as classes granito (a) e mármore (b), respectivamente.	127
4.34	Modelos AR2D obtidos a partir das texturas de Brodatz (Figura 4.32). O modelo ω referencia a classe granito e o modelo ψ referencia a classe mármore.	128
4.35	Modelos AR2D obtidos a partir das texturas de Brodatz mostradas na Figura 4.32, utilizando a ACF2D concatenada . O modelo ρ referencia a classe granito e o modelo θ referencia a classe mármore.	129
4.36	Modelos MA2D inversos para a classe granito, utilizando os dois métodos em estudo.	130
4.37	Modelos MA2D para a classe mármore, utilizando os dois métodos em estudo.	130
4.38	Autocorrelações para os resíduos das classes granito - modelos ω (a) e ρ (b) - e mármore - modelos ψ (c) e θ (d).	131

- 4.39 Processo de verificação do ajuste dos algoritmos utilizados para o processo de filtragem inversa (obtenção do resíduo) e direta (regeneração) para a imagem da FTA (Figura 4.1.a) utilizando o modelo α_1 . (a) Imagem SAR original; (b) resíduo; (c) Imagem regenerada.....134
- 4.40 Processo de verificação do ajuste dos algoritmos utilizados para o processo de filtragem inversa (obtenção do resíduo) e direta (regeneração) para a imagem da FTDP (Figura 4.1.b) utilizando o modelo γ_1 . (a) Imagem SAR original; (b) resíduo; (c) Imagem regenerada.....134
- 4.41 Seqüência de imagens para a avaliação do processo de síntese de texturas de imagens SAR da FTA: (a) Imagem original; (b) Campo sintético - modelo α_1 ; (c) Inserção do campo sintético; (d) Campo sintético - modelo ε_1 ; (e) Inserção do campo sintético; (f) Campo sintético - modelo β_1 ; (g) Inserção do campo sintético; (h) Campo sintético - modelo ϕ_1 ; (i) Inserção do campo sintético; (j) Inserção do campo sintético - modelo α_1 - sem moldura; (k) Inserção do campo sintético - modelo β_1 - sem moldura136
- 4.42 Seqüência de imagens para a avaliação do processo de síntese de texturas de imagens SAR da FTDP: (a) Imagem original; (b) Campo sintético - modelo γ_1 ; (c) Inserção do campo sintético; (d) Campo sintético - modelo ϕ_1 ; (e) Inserção do campo sintético; (f) Campo sintético - modelo δ_1 ; (g) Inserção do campo sintético; (h) Campo sintético - modelo η_1 ; (i) Inserção do campo sintético; (j) Inserção do campo sintético - modelo γ_1 - sem moldura; (k) Inserção do campo sintético - modelo δ_1 - sem moldura.139
- 4.43 Histograma dos resíduos obtidos a partir do modelos: (a) α_1 - imagem FTA original (Figura 4.1.a); (b) β_1 - imagem FTA com reescalonamento pela raiz cúbica (Figura 4.2).145
- 4.44 Seqüência de imagens para a avaliação do processo de síntese de texturas da imagem ótica JERS de Tokyo: (a) Imagem original; (b) Campo sintético - modelo λ ; (c) Inserção do campo sintético; (d) Campo sintético - modelo μ ; (e) Inserção do campo sintético; (j) Inserção do campo sintético - modelo λ - sem moldura; (k) Inserção do campo sintético - modelo μ - sem moldura.150
- 4.45 Seqüência de imagens para a avaliação do processo de síntese de texturas de imagens óticas Landsat: (a) Imagem original; (b) Campo sintético - modelo π ; (c) Inserção do campo sintético; (d) Campo sintético - modelo τ ; (e) Inserção do campo sintético; (j) Inserção do campo sintético - modelo π - sem moldura; (k) Inserção do campo sintético - modelo τ - sem moldura.....152

4.46	Seqüência de imagens para a avaliação do processo de síntese de texturas naturais da classe granito: (a) Imagem original; (b) Campo sintético - modelo ρ ; (c) Inserção do campo sintético; (d) Campo sintético - modelo ω ; (e) Inserção do campo sintético; (j) Inserção do campo sintético - modelo ρ - sem moldura; (k) Inserção do campo sintético - modelo ω - sem moldura.....	156
4.47	Seqüência de imagens para a avaliação do processo de síntese de texturas naturais da classe mármore: (a) Imagem original; (b) Campo sintético - modelo ψ ; (c) Inserção do campo sintético; (d) Campo sintético - modelo θ ; (e) Inserção do campo sintético; (j) Inserção do campo sintético - modelo ψ - sem moldura; (k) Inserção do campo sintético - modelo θ - sem moldura.....	158
4.48	Texturas levemente determinísticas e campos sintéticos: tecido natural (a) e sintético (b); pedras (natural) (c) e sintética (d); trançado natural (e) e sintético (f).	161
A.1	DHF do Sintetizador de Texturas Autorregressivas	173
A.2	Diagrama de Interação entre Processos	175
A.3	Controlador de Eventos.	176
A.4	Interfaces com imagens e dados.....	176
A.5	Interfaces com dados gráficos e textuais.....	177
A.6	Interfaces tipo janela de comandos.	178
A.7	Interfaces com texto em janela de comandos.	178
A.8	Interface tipo termômetro.	179
A.9	Interface tipo caixa de diálogo.....	179
A.10	Interface tipo <i>datagrid</i>	179
A.11	Interface específica para cálculo de distâncias euclidianas.....	180
B.1	Imagens do sensor ótico do satélite JERS-1: (a) Tokyo(Japão); (b) Chiba (Japão).	182
B.2	Especificações do satélite JERS-1.	182

LISTA DE TABELAS

	<u>Pág.</u>
3.1	Valores críticos para a estatística “D” de Kolmogorov-Smirnov73
4.1	Comparação entre os valores da estatística “D” de Kolmogorov-Smirnov para as imagens reescaladas e os valores críticos para níveis de significância 0,01 e 0,05 ($n = 4000$)100
4.2	Momentos de segunda ordem relativos ao modelo α_1 (FTA).....134
4.3	Momentos de segunda ordem relativos ao modelo γ_1 (FTDP)135
4.4	Momentos de segunda ordem relativos ao modelo β_1 (FTA reescalada)135
4.5	Características dos campos texturados em estudo138
4.6	Características dos campos texturados em estudo141
4.7	Distâncias entre modelos obtidos a partir das texturas sintéticas e texturas originais, para o processo de modelagem e síntese utilizando a textura existente na imagem SAR da FTA (Figura 4.1.a).....144
4.8	Distâncias entre modelos obtidos a partir das texturas sintéticas e texturas originais, para o processo de modelagem e síntese utilizando a textura existente na imagem SAR da FTDP (Figura 4.1.b)144
4.9	Distâncias entre modelos obtidos a partir das texturas sintéticas e texturas originais, para o processo de modelagem e síntese utilizando textura existente na imagem ótica JERS-1 de Tokyo (Figura 4.23.a)154
4.10	Distâncias entre modelos obtidos a partir das texturas sintéticas e texturas originais, para o processo de modelagem e síntese utilizando textura existente na imagem Landsat-5 do Rio de Janeiro (Figura 4.23.b)154
4.11	Distâncias entre modelos obtidos a partir das texturas sintéticas e texturas originais, para o processo de modelagem e síntese utilizando textura natural granito (Figura 4.32.a)160
4.12	Distâncias entre modelos obtidos a partir das texturas sintéticas e texturas originais, para o processo de modelagem e síntese utilizando textura natural mármore (Figura 4.32.b).....160

A.1	Descrição das funções implementadas no software Sintetizador de Texturas Autorregressivas	174
-----	---	-----

LISTA DE SÍMBOLOS

Latinos

B	- Operador atraso
c_k	- Estimativa para a autocovariância
C	- Conjunto dos números complexos
d_{ab}	- Distância euclidiana
$F(x,y,z)$	- Função das variáveis independentes x , y e z
H	- Representação de um filtro H
M	- Número de pixels dos segmentos a concatenar
$O(n)$	- Ordem de um algoritmo
p	- Ordem de modelo AR, ou da parte AR de modelo ARMA
P_{sp}	- Projeção sobre um espaço linear fechado
q	- Ordem de modelo MA, ou da parte MA de modelo ARMA
r_{xx}	- Estimativas para os coeficientes de autocorrelação
R_{xx}	- Matriz de estimativas para os coeficientes de autocorrelação
S_p	- Região de suporte bidimensional de rótulo p
S'_p	- Região de suporte bidimensional de rótulo p não incluindo a origem
T_o	- Domínio do tempo em séries temporais
\mathbf{X}	- Vetor aleatório
X_t	- Série temporal
X_t	- Variável aleatória
$\{X_t\}$	- Série temporal vetorial
z	- Transformada z
Z	- Conjunto dos números inteiros
Z_t	- Série temporal ruído branco
\hat{Z}_t	- Resíduo obtido a partir da filtragem inversa

Gregos

a	- Função de autocorrelação parcial
$\alpha \dots \omega$	- Modelos estimados a partir das texturas fonte (letras gregas)
α^3	- Modelos reconstituídos a partir de modelos transformados pela raiz cúbica
γ_x	- Função de autocovariância
Γ	- Matriz de autocovariâncias
q	- Polinômio de coeficientes média móvel de um modelo ARMA
q_n	- Coeficiente ou parâmetro média móvel de um modelo ARMA
Q	- Matriz de coeficientes média móvel
m	- Média de um processo estacionário estocástico
N	- Número de observações ou amostras de um processo estocástico
r_x	- Função de autocorrelação
R_{xx}	- Densidade do Espectro de Potência
s^2	- Variância
Σ	- Matriz de covariância
u_n	- Variância do ruído branco motor
f	- Polinômio de coeficientes autorregressivos de um modelo ARMA
f_n	- Coeficiente ou parâmetro autorregressivo de um modelo ARMA
F	- Matriz de coeficientes autorregressivos
w_t	- Amostra de um processo estocástico Z_t

Índices Superiores

*	- Complexo conjugado
-1	- Operação inversa
3	- Recuperação de modelos transformados a partir da raiz cúbica
H	- Matriz hermitiana
'	- Matriz transposta

Índices Inferiores

- i,j - Índices de coeficientes bidimensionais ou componentes de matrizes
- k - Atraso (*lag*)
- t - Tempo

Símbolos Especiais

- ~ - Aplicado sobre uma variável aleatória ou processo estocástico significa versão centralizada (média subtraída)
- ^ - Aplicado sobre uma variável indica sua estimativa
- - Aplicado sob uma variável indica vetor
- - Aplicado sobre uma variável indica média

LISTA DE SIGLAS E ABREVIATURAS

2D	- Bidimensional – <i>Two-dimensional</i>
ACF	- Função ou Sequência de Autocorrelação – <i>Autocorrelation Function</i>
ACF2D	- Função de Autocorrelação Bidimensional – <i>Two-dimensional Autocorrelation Function</i>
AIC	- Critério Informativo de Akaike – <i>Akaike Information Criterion</i>
AR	- Autorregressivo – <i>Autoregressive</i>
AR2D	- Autorregressivo Bidimensional – <i>Two-Dimensional Autoregressive</i>
ARMA	- Autorregressivo e de Média Móvel – <i>Autoregressive Moving Average</i>
ARMA2D	- Autorregressivo e de Média Móvel Bidimensional – <i>Two-dimensional Autoregressive Moving Average</i>
CAT	- Critério de Transferência Autorregressiva – <i>Criterion Autoregressive Transfer</i>
CPU	- Unidade Central de Processamento – <i>Central Processing Unit</i>
DOS	- Sistema Operacional em Disco – <i>Disk Operating System</i>
DPI	- Divisão de Processamento de Imagens
DTFT	- Transformada de Fourier Discreta no Tempo – <i>Discrete Time Fourier Transform</i>
<i>fbm</i>	- Movimento Fractal Browniano – <i>Fractional Brownian Motion</i>
FHD	- Diagrama Hierárquico de Funções – <i>Function Hierarchy Diagram</i>
FPE	- Erro de Predição Final – <i>Final Prediction Error</i>
FTA	- Floresta tropical aberta
FTDP	- Floresta tropical densa de relevo plano
GUI	- Interface Gráfica com o Usuário - <i>Graphic User Interface</i>
IBM	- <i>Industrial Business Machines Company</i>
IDL	- Linguagem de Dados Interativa – <i>Interactive Data Language</i>
IEEE	- Instituto de Engenheiros Elétricos e Eletrônicos
IID	- Independente e identicamente distribuído

INPE	- Instituto Nacional de Pesquisas Espaciais
JERS	- <i>Japanese Environmental Resources Satellites</i>
LS	- Mínimos Quadrados – <i>Least Squares</i>
MA	- Média Móvel – <i>Moving Average</i>
MA2D	- Média Móvel Bidimensional – <i>Two-dimensional Moving Average</i>
MAP	- Máximo a posteriori
MDL	- Comprimento de Descrição Mínima – <i>Minimum Description Length</i>
ML	- Máxima Verossimilhança – <i>Maximum Likelihood</i>
NASDA	- <i>National Space Development Agency of Japan</i>
NSHP	- Meio Plano Não Simétrico – <i>Non-symmetrical Half Plane</i>
PACF	- Função de Autocorrelação Parcial – <i>Partial Autocorrelation Function</i>
PSD	- Densidade do Espectro de Potência – <i>Power Spectrum Density</i>
QP	- Quarto de Plano – <i>Quarter Plane</i>
SAR	- Radar de Abertura Sintética – <i>Synthetic Aperture Radar</i>
TNSHP	- Meio Plano Não Simétrico Truncado– <i>Truncated Non-symmetrical Half Plane</i>
WN	- Ruído Branco – <i>White Noise</i>
YW	- Equações de Yule-Walker

CAPÍTULO 1

INTRODUÇÃO

1.1 OBJETIVOS

Este trabalho tem por objetivo geral primário testar o comportamento da modelagem autorregressiva para a síntese de diversos tipos de textura, incluindo texturas existentes em imagens obtidas por sensores óticos e por radar de abertura sintética, além de texturas naturais semelhantes às do álbum de Brodatz (1966). O objetivo geral secundário é o desenvolvimento de uma interface gráfica orientada a eventos, multiplataforma, utilizando “*Interactive Data Language*” (IDL), a qual contenha toda a funcionalidade necessária à realização do objetivo primário.

Como objetivos específicos, pode-se citar: implementação de modelagem autorregressiva utilizando a função de autocorrelação puramente linear com a concatenação de linhas e colunas da imagem; modelagem autorregressiva utilizando a função de autocorrelação bidimensional concatenada para a eliminação de correlações indesejadas decorrentes do processo de concatenação das amostras; teste de um modelo específico para a aproximação do histograma das imagens de radar de abertura sintética com a distribuição gaussiana; integração do sistema desenvolvido no ambiente da linguagem IDL com o software de processamento de imagens ENVI, proporcionando extensão de funcionalidade.

1.2 SÍNTESE DE TEXTURAS: SUA IMPORTÂNCIA

Métodos para a geração sintética de texturas de aparência natural são necessários para a geração de cenas de aparência realística, semelhantes a um padrão previamente escolhido, ou textura fonte. Este é o escopo deste trabalho.

Pode-se reputar como altamente desejável que os parâmetros para a síntese sejam derivados automaticamente da textura fonte. Texturas deste tipo podem ser

extremamente úteis para utilização em armazenamento de imagens, já que o armazenamento de um conjunto de parâmetros e limites é muito menos custoso que uma cena integral digitalizada.

Outro fator interessante a ser considerado é que, sem as redundâncias existentes nas imagens brutas, é muito menos complexo o estudo e análise da cena resultante. As características dos parâmetros de textura são também utilizáveis para a discriminação e reconhecimento de padrões.

As potencialidades recaem ainda no campo da *renderização* de imagens de computação gráfica, para utilização em simuladores de cenas naturais, como em aplicações militares ou jogos de computador.

Finalmente, através da manipulação dos parâmetros, especificando-se intervalos de valores, pode-se potencialmente gerar famílias de texturas para aplicações diversas, ampliado ainda mais a utilidade do estudo de métodos de geração de texturas através de síntese.

1.3 O QUE É TEXTURA?

Embora não exista uma definição univesalmente aceita para textura, pode-se referenciá-la como o conjunto de estruturas detalhadas, existentes nas superfícies físicas, perceptíveis ao olho humano, e que trazem grande quantidade de informações sobre a natureza da superfície. Outrossim, a definição de textura é fortemente intuitiva, o que torna uma definição incisiva alvo suscetível de contestação. Dessa forma, é importante a busca, na literatura referente a Processamento de Imagens, Computação Gráfica e Visão por Computador, de outras formas de conceituação:

- Sklansky (1978), *Image Segmentation and Feature Extraction*:
“Uma região, em uma imagem, tem uma textura constante se um conjunto de estatísticas locais ou outras propriedades locais da função da figura são constantes, de lenta variação, ou de variação aproximadamente periódica.”

- Wilson e Spann (1988), *Image Segmentation and Uncertainty*:
“Regiões de Textura são padrões espacialmente estendidos baseados na maior ou menor repetição precisa de alguma unidade celular (*texton* ou subpadrão).”
- Jain (1988), *Fundamentals of Digital Image Processing*:
“O termo textura geralmente se refere a repetição de elementos básicos de textura chamados *texels*. O *texel* contém vários pixels, cuja colocação pode ser aleatória, quasi-periódica ou, periódica. Texturas Naturais são geralmente aleatórias, ao passo que texturas artificiais são frequentemente determinísticas ou periódicas. Textura pode ser áspera, fina, suave, granulada, ondulada, irregular, regular, ou linear.”
- Instituto de Engenheiros Elétricos e Eletrônicos (1990), *IEEE Standard Glossary of Image Processing and Pattern Recognition Terminology*:
“Textura é um atributo representando o arranjo espacial dos níveis de cinza dos pixels em uma região.”
- Gonzalez e Woods (1992), *Digital Image Processing*:
“Nós intuitivamente vemos este descritor como provedor de uma medida de propriedades tal como suavidade, asperidade, e regularidade.”
- Jahne (1995), *Digital Image Processing*:
“Modelos que caracterizam objetos são chamados texturas em Processamento de Imagens.”

Pode-se inferir que, a despeito da falta de uma definição universalmente aceita, os pesquisadores concordam em dois pontos:

- existe uma variação significativa na intensidade dos níveis da coloração entre pixels próximos, ou seja, no limite da resolução, não existe homogeneidade;
- a textura é uma propriedade homogênea a certa resolução espacial maior que a resolução da imagem.

O estudo das texturas é aplicável para o aumento do realismo das imagens geradas pela Computação Gráfica, uma vez que os métodos de remoção de superfícies escondidas e de *shading* não conseguem, por si próprios, conferir alto grau de verossimilhança às imagens, tendo em vista a complexidade do mundo real. Em termos de Computação Gráfica, textura nada mais é que uma função espacial do tipo $F(x,y)$, em um espaço bidimensional, ou $F(x,y,z)$, em um espaço tridimensional. Seguindo tal definição, é possível imaginar a textura como uma matriz de valores discretos, os quais são indexados pelas coordenadas discretas x , y e z , comumente chamadas de espaço de textura.

Existem, ainda, duas abordagens principais para a definição de textura, em termos computacionais: a abordagem estatística e a abordagem estrutural.

A primeira considera que os valores das texturas são gerados por um campo aleatório bidimensional, como descrito por Faugeras e Pratt (1980) e Cross e Jain (1981). Esta abordagem é adotada neste trabalho, o qual considerará a textura com um campo bidimensional (imagem), estocástico e possivelmente periódico. Supõe-se também que existe uma certa estrutura espacial no campo aleatório, conforme Cross e Jain (1981), o qual preceitua que o nível de cinza (brightness) a um certo ponto da imagem é altamente dependente do nível de cinza nos pontos da vizinhança, a não ser que a imagem seja um campo totalmente aleatório. Jain e Karu (1996) também preceituam que as texturas não são somente caracterizadas pelo nível de cinza de um dado pixel, mas também pelo valor de cinza “padrão” em uma vizinhança circunvizinha ao pixel.

A abordagem estrutural adota a premissa que a textura é composta de primitivas que se repetem ao longo da mesma. O posicionamento relativo das primitivas no padrão é determinado pela chamada “regra de distribuição” (*placement rule*), conforme o definido por Cross e Jain (1981):

“O ponto de vista regra de distribuição considera a textura como sendo composta por primitivas. Estas primitivas podem variar em sua forma determinística, como círculos, hexágonos ou padrões de pontos. Macrotexturas tem primitivas grandes, e microtexturas

composta por primitivas pequenas. Estes termos são relativos à resolução da imagem. A imagem texturizada é formada por primitivas cuja orientação é especificada pelas regras de distribuição, tanto no contexto global da imagem quanto em respeito a cada uma em particular. Exemplos destas texturas incluem ladrilhos em um plano, estruturas celulares como amostras de tecido, e a foto de uma parede de tijolos.”

Faugeras e Pratt (1980) também salientam que esta formulação determinística de textura considera um padrão local que é periodicamente ou quase periodicamente repetido ao longo de uma área.

Neste trabalho, considerou-se a textura como um campo aleatório homogêneo localmente estruturado, ou seja, sua intensidade em um dado pixel é uma função probabilística das intensidades dos pixels localizados na vizinhança. Esta função probabilística é independente da localização da imagem, gerando a impressão perceptível de homogeneidade.

Serão apenas consideradas texturas em níveis de cinza, o que exclui imagens preto e branco e multiespectrais. Tal restrição é consistente com a literatura, a qual trata quase que exclusivamente de imagens em tons de cinza.

O trabalho ora proposto terá como tema principal a síntese de texturas utilizando metodologia estatística. Para discorrer-se sobre o tema, entretanto, dividiu-se esta dissertação em cinco partes: a Introdução, no Capítulo 1, abordando o conceito de textura (Seção 1.3), realizando uma revisão bibliográfica a respeito do tema, na Seção 1.4, e discutindo a respeito da síntese de texturas, através de modelagem estatística espacial, na Seção 1.5; no Capítulo 2, é realizado um estudo a respeito dos modelos estatísticos Autorregressivos e de Média Móvel (ARMA - *Autoregressive Moving Average*) na Seção 2.5, com suas versões uni e bidimensionais, respectivamente nas Seções 2.6 e 2.7, porém antes efetuando-se uma revisão a respeito dos conceitos de séries temporais (Seção 2.1), processos estocásticos (2.2), estacionariedade (2.3) e modelos paramétricos (2.4); a descrição dos materiais e métodos a serem empregados no trabalho é feita no Capítulo 3, discorrendo sobre a forma de adequação do histograma

das imagens SAR ao método (Seção 3.1), estimativa dos modelos (3.2), determinação de coeficientes (3.3), a metodologia de síntese (3.4) e o software e equipamentos de apoio utilizados (3.5); no Capítulo 4, são descritos resultados alcançados com o uso da metodologia proposta, na Seção 4.1, e resultados alusivos à síntese de texturas, na Seção 4.2. Conclusões e sugestões para trabalhos futuros são apresentados Capítulo 5.

1.4 REVISÃO BIBLIOGRÁFICA

Os métodos de síntese de texturas propostos na literatura tem se concentrado em grande parte na teoria de fractais (Mandelbrot, 1975,1978 e 1982; Fournier et al., 1982, Musgrave, 1995) os quais utilizam-se do conceito de movimento fractal browniano (*fbm*) para simular as variações de valores relativos à textura. Tais variações são inversamente proporcionais à chamada *dimensão fractal* do objeto e baseiam-se em subdivisão recursiva. Uma outra forma é a perturbação do vetor normal (Thalman e Thalman, 1987), a qual utiliza-se de vetores normais perturbados por outros vetores, os quais são formados por variáveis gaussianas de média zero e desvio padrão conhecido.

De qualquer maneira, os métodos fractais utilizam-se sempre de geradores pseudoaleatórios, os quais tentam produzir ruído branco para a geração do *fbm*, o que permite classificá-los com métodos de natureza estocástica. Apesar de serem capazes de gerar padrões de texturas de excelente realismo, os métodos fractais não são capazes, entretanto, de reconstituir um dado padrão de textura (Chellapa e Kashyap, 1985).

A abordagem descritiva de Kaufman e Azaria (1985), que define cinco abordagens para síntese de texturas baseadas em modelos matemáticos ou derivadas de técnicas de análise de texturas, outrossim, é bastante apropriada:

- síntese de texturas utilizando abordagem sintática;
- geração de texturas usando abordagem estatística;
- síntese de texturas utilizando modelos evolutivos;
- abordagem utilizando esboços de computador;
- síntese de texturas utilizando modelos estocásticos fractais.

Este último tipo relaciona-se unicamente com a teoria de fractais, a qual foi citada acima. Devemos também considerar as abordagens geoestatísticas, a morfologia matemática e os modelos booleanos como áreas de estudo para a análise de texturas.

Existem, dessa maneira, vários métodos baseados em análise de texturas, como o método baseado em sintaxe introduzido por Fu e Lu (1978,1979), o qual consiste em dividir o padrão de texturas em retângulos de tamanho fixo (“*tiles*”), que são associadas em uma estrutura em árvore, onde cada nó corresponde a um pixel no retângulo. Um retângulo pode ser gerado com uma gramática de árvore do tipo $G = (V, r, P, s)$ sobre $\langle S, r \rangle$, onde V é um conjunto de símbolos terminais e não terminais, S é um conjunto de símbolos terminais, s é o símbolo inicial, r é o *rank* associado com os membros de S e P é um conjunto de regras de produção a fim de formar uma árvore de um nível com r folhas. Uma gramática estocástica permite que padrões irregulares possam ser gerados associando-se uma probabilidade $Pr(k)$ a cada regra P , mas a coerência entre os retângulos vizinhos consiste em um problema.

Outros métodos derivados da análise de texturas são os de geração de texturas baseados na teoria estatística. Estes métodos têm sido utilizados principalmente para a geração de texturas baseadas em níveis de cinza, produzindo texturas utilizando cadeias de Markov (Chellappa e Kashyap, 1981; Cross e Jain, 1981; Hassner e Sklansky, 1980) cujos estados são de níveis de cinza $\{G\}$ com distribuição limite $\{P(G)\}$. O uso da modelagem de textura utilizando campo aleatório markoviano necessita, entretanto, de muita área de armazenamento em memória secundária e tem custo computacional (tempo de uso da unidade central de processamento - CPU) muito elevado.

Uma outra abordagem estatística foi proposta por Schachter e Ahuja (1979), que é um modelo de mosaicos que se utiliza de um mecanismo de dois níveis, inicialmente embutindo mosaicos no plano em um conjunto de regiões distintas e posteriormente colorindo-as de forma individual. Schachter (1980) também propôs um método para a simulação de terrenos em simuladores de vôo o qual utiliza *long crested waves* e síntese de Fourier.

Adicionalmente, podemos ainda citar a abordagem geoestatística tal como descrita por Goovaerts (1997) a qual supõe que pontos adjacentes em uma grade não regular são correlatos entre si espacialmente. A continuidade é medida e então utilizada para a estimativa da célula, bloco ou ponto. O relacionamento que expressa a extensão desta continuidade, ou correlação, é medido pelo *variograma*, a função que mensura a correlação espacial. Após isto, pode-se aplicar um processo de *kriging*¹, o qual é uma técnica de média móvel (MA – *moving average*) que se utiliza dos parâmetros do variograma para obter os relacionamentos entre os pontos, expressando a variação espacial e minimizando os erros de predição.

É interessante citar também o modelo de hipertexturas proposto por Perlin (1989), o qual baseia-se em um campo de texturas tridimensional gerado por um algoritmo que “toca” a superfície a receber a textura. Gardener (1984) também utilizou-se deste método da chamada “textura sólida” para desenvolver métodos de síntese tanto no domínio do espaço como no domínio de Fourier, gerando funções matemáticas de texturização as quais representam os detalhes naturais da superfície, de forma estatística.

Existem ainda as texturas baseadas em modelos evolutivos, que são métodos sistemáticos e complexos desenvolvidos por Haralick (1979), os quais simulam o processo evolutivo da natureza. Introduzem três operações básicas aplicadas à “células”, quais são a distribuição de sementes, o crescimento da estrutura (ou do esqueleto) e o crescimento muscular.

Finalmente, a abordagem de texturas baseada em esboços de computador foi uma forma originariamente desenvolvida para utilização com penas de plotadores, porém também tem sido utilizada com telas tipo *raster*. Mezei et al. (1974) descrevem um método para a plotagem de padrões a partir de uma coleção de símbolos tais como linhas, curvas,

¹ Método de interpolação que se utiliza de predição ótima, prevendo valores desconhecidos a partir de valores de dados em localizações conhecidas.

quadriláteros e ovais que são distribuídos ao longo da superfície para a geração do padrão desejado.

Este trabalho basear-se-á em modelos estatísticos de síntese de texturas que possuem várias características semelhantes aos métodos anteriores de abordagem estatística, porém sua principal característica concentrar-se-á no uso de modelos ARMA, conforme o descrito na Seção 2.5, para a estimativa de parâmetros que levarão à geração dos padrões de texturas. Tais modelos possuem características estatísticas próprias interessantes, cujas vantagens este trabalho procurará explorar.

Tal qual outras técnicas desenvolvidas para estimação de parâmetros (Banon,1971), os modelos ARMA tem sido largamente utilizados para a estimação de parâmetros com a finalidade de análise de sinais aleatórios, em contraste com os métodos clássicos não parametrizados (Porat, 1994). Seu uso em estimação espectral bidimensional é descrito, por Marple (1987) e Kay (1988), sendo que Wernecke e D'Addario (1977) e Jain (1981) já haviam estendido a aplicação de processamento digital de sinais bidimensionais para a teoria de processamento de imagens. Dutra (1990) e Dutra e Sant'Ana (1995) propõem um método para a estimação bidimensional a partir de modelos estimados sobre séries unidimensionais obtidas pela concatenação de linhas e colunas de imagens, a fim de classificar as texturas destas com filtros inversos derivados dos modelos.

Jain (1981), assim como Woods (1972) e Pendrel (1979) propuseram modelos não causais para a estimativa de parâmetros, porém, se o modelo é motivado por um processo físico onde existe uma ordem ou seqüência natural, modelos causais seriam mais desejáveis (Cadzow e Ogino,1981) e a escolha recairá em modelos puramente autorregressivos (AR) bidimensionais (2D).

Em relação à síntese de texturas, finalmente, Garber e Sawchuck (1981) utilizaram-se de modelos AR bidimensionais (AR2D) causais para a análise e síntese de imagens, assim como Chellappa e Kashyap (1985) desenvolveram uma síntese de texturas utilizando modelos AR2D não causais, construindo várias texturas semelhantes às naturais encontradas no álbum de Brodatz (1966), comparando os variogramas das texturas

originais e sintéticas, além de adicionalmente utilizarem-se da Função de Autocorrelação (ACF) para verificar a similaridade entre texturas naturais.

1.5 SÍNTESE DE TEXTURAS POR MODELAGEM ESTATÍSTICA ESPACIAL

O trabalho ora proposto utilizará um método de síntese, ou seja, a partir de um sistema cuja função de transferência é conhecida, ou, no caso, estimada, será feita uma tentativa de reconstrução ou simulação. No caso dado, as texturas sintéticas buscarão possuir características visuais e estatísticas que podem ser semelhantes às texturas reais.

Pode-se utilizar várias técnicas e abordagens para a síntese de texturas, tanto baseadas em modelos matemáticos como derivadas de técnicas de análise de texturas, conforme foi visto na Seção 1.4. Isto se deve ao fato de que as texturas podem ser consideradas determinísticas, como normalmente são as de construções elaboradas por mãos humanas, tal qual paredes de tijolos, ou de natureza estatística, como normalmente são as texturas naturais, tal qual florestas em imagens de sensoriamento remoto.

Neste trabalho propõe-se utilizar um método estatístico baseado na chamada modelagem ARMA de séries temporais, o qual proporcionará a síntese de padrões de texturas do tipo inerentemente não determinístico, a partir de padrões encontrados em imagens SAR, óticas ou em texturas digitalizadas naturais.

O método utilizará a idéia básica de que uma imagem é um sinal bidimensional de natureza aleatória, ou seja, existe uma lei probabilística que governa o sinal, cujos parâmetros são inferidos do sinal observado.

A síntese de texturas proposta buscará, a partir da modelagem estatística bidimensional baseada em séries temporais, simular padrões de textura do mundo real. Os maiores problemas a serem considerados na modelagem estatística para a síntese de texturas, e que serão abordados neste trabalho, concentrar-se-ão em:

- escolher o modelo apropriado e sua ordem;

- estimar os parâmetros do modelo e obter os momentos de segunda ordem das variáveis aleatórias de entrada;
- geração da imagem sintética obedecendo o modelo; e
- comparação das propriedades de segunda ordem das texturas geradas com as das texturas naturais.

Outro fato a ser observado é que a noção estatística unidimensional, que é a mais desenvolvida e estudada, deverá ser estendida a duas dimensões, a fim de atender as necessidades do processamento de imagens.

Apesar de alguns autores conseguirem resultados interessantes com modelos não causais (Chellappa e Kashyap,1985), este trabalho concentrar-se-á nos modelos AR2D causais, tal qual o trabalho de Garber e Sawchuck (1981), tendo em vista que tais filtros são inversíveis, ou seja, a partir dos resíduos calculados, consegue-se regenerar as imagens originais, o que é possível quando o filtro é causal, estável e de fase mínima, conforme será visto nas Seções 2.6.1 e 3.1.

Uma característica interessante a ser explorada, entretanto, é que as regiões de suporte dos filtros gerados são causais, o que possibilita a filtragem direta ou inversa em um único passo (Seção 2.7.2).

Existe, ainda, mais uma característica implementada no trabalho: a de que, sendo baseado em modelagem estatística, pode-se excitar o filtro inverso estimado com um campo branco e avaliar a semelhança do padrão de textura resultante com o padrão da imagem original.

Finalmente, foi desenvolvido um sistema em linguagem IDL, conforme o citado na Seção 3.5 e descrito no Anexo A, a fim de alcançar o objetivos definidos para a Dissertação.

Para a avaliação e compreensão das idéias aqui descritas, far-se-á um estudo dos modelos ARMA nas seções a seguir.

CAPÍTULO 2

MODELOS ESTATÍSTICOS ESPACIAIS

Conforme discutido no capítulo anterior, a modelagem sintética de texturas a partir de padrões obtidos em imagens naturais conduz naturalmente à utilização da abordagem estatística, tendo em vista que formas naturais raramente são regulares. Observando-se, entretanto, que a ordem das amostras ou, no caso das imagens, a organização espacial, é fator importante para o estudo das características das texturas, a análise das séries temporais é o ramo do conhecimento estatístico que melhor se adapta ao escopo do trabalho, já que, em muitas aplicações, pode-se estender a idéia da série temporal para dados obtidos em seqüências lineares diferentes do tempo, tal qual a seqüência ordenada de *pixels* em linhas e colunas de imagens formando um padrão de textura.

Outro fato é que, sabendo-se que as texturas tendem a agrupar-se em “famílias”, permitindo a existência de padrões, pode-se considerar que as texturas de um mesmo grupo nada mais são que realizações de um mesmo processo estocástico.

Tendo em vista estas considerações, séries temporais e processos estocásticos serão discutidos nas seções a seguir.

2.1 SÉRIES TEMPORAIS

Podemos definir uma série temporal como um conjunto de observações x_t , cada uma destas observada a um tempo t específico (Brockwell e Davis,1987). Séries temporais contínuas são aquelas geradas a partir de observações obtidas continuamente no tempo, ou seja, presume-se que é possível obter-se medições a partir de qualquer momento no tempo. Uma série temporal discreta no tempo, por sua vez, é aquela em que o conjunto T_o de valores temporais nos quais as observações são feitas é medido em intervalos fixos de tempo, ou seja, em períodos, tais quais semanal, mensal ou anualmente ou frações menores como horas, minutos e segundos.

Séries temporais têm sido largamente empregadas em engenharia, sociologia e economia e, neste trabalho, inferências sobre estas séries serão utilizadas para a modelagem de texturas em processamento de imagens. É necessário, entretanto, construir um modelo matemático hipotético para representar os dados. Havendo-se escolhido o modelo, torna-se possível estimar parâmetros, checar sua capacidade de representar os dados e utilizar o modelo para aumentar o grau de conhecimento do mecanismo gerador da série. A partir da geração de um modelo considerado satisfatório, pode-se utilizá-lo para a predição e o controle de valores futuros da série em estudo. O problema da construção de modelos matemáticos para séries temporais será discutido na seção a seguir.

2.2 PROCESSOS ESTOCÁSTICOS

A seleção de um modelo matemático compatível (ou uma classe de modelo) para os dados é o primeiro passo para a análise de uma série temporal. A fim de se compreender a natureza imprevisível das observações futuras é importante a suposição de que cada observação x_t é uma realização de uma variável aleatória X_t (Brockwell e Davis, 1987). Pode-se agora considerar a série temporal $\{X_t, t \in T_o\}$ como uma realização da família de variáveis aleatórias $\{X_t, t \in T_o\}$. Estas considerações sugerem a modelagem dos dados como realizações de um processo estocástico $\{X_t, t \in T\}$, $T \supseteq T_o$. Este trabalho restringir-se-á a classes de processos estocásticos particularmente úteis para a modelagem de texturas.

2.3 ESTACIONARIEDADE E ESTACIONARIEDADE ESTRITA

Os modelos estacionários são uma classe importante de modelos estocásticos, pois supõem que o processo permanece em equilíbrio em torno de um certo nível médio constante (Dutra, 1990).

A fim de melhor compreender o conceito de estacionariedade¹, entretanto, é necessário citar que, ao se manipular um conjunto finito de variáveis aleatórias, é normalmente útil se trabalhar com a matriz de covariâncias, com o intuito de se inferir informações a partir da dependência entre os elementos do conjunto.

Se $\mathbf{X} = (\mathbf{X}_1, \dots, \mathbf{X}_n)'$ e $\mathbf{Y} = (\mathbf{Y}_1, \dots, \mathbf{Y}_m)'$ são vetores aleatórios tais que $E|\mathbf{X}_i|^2 < \infty$, $i = 1, \dots, n$, e $E|\mathbf{Y}_i|^2 < \infty$, $i = 1, \dots, m$, definimos a matriz de covariância de \mathbf{X} e \mathbf{Y} como a matriz:

$$\sum_{XY} = Cov(X, Y) = E[(X - E(X)) \times (Y - E(Y))'] = E(XY') - E(X)E(Y)' \quad (2-1)$$

O (i, j) -ésimo elemento de \sum_{XY} é a covariância, $Cov(X_i, Y_j) = E(X_i Y_j) - E(X_i)E(Y_j)$. No caso específico de $Y = X$, $Cov(X, Y)$ se reduz à matriz de covariância de X (Brockwell e Davis, 1987).

Para uma série temporal $\{X_t, t \in T\}$ é necessário estender-se o conceito de matriz de covariância para trabalhar-se com coleções infinitas de variáveis aleatórias, o que é provido pela chamada função de autocovariância.

Se $\{X_t, t \in T\}$ é um processo tal que $Var(X_t) < \infty$ para cada $t' \in T$, então a função de autocovariância γ_x de $\{X_t\}$ é definida por:

$$\gamma_x(r, s) = Cov(X_r, X_s) = E[(X_r - E(X_r)) \times (X_s - E(X_s))'], r, s \in T. \quad (2-2)$$

Compreendendo-se estas definições, pode-se dizer que uma série temporal $\{X_t, t \in T\}$ de índices $T = \{0, \pm 1, \pm 2, \dots\}$ é estacionária de segunda ordem se

- a) $E|\mathbf{X}_i|^2 < \infty$ para todo $t \in T$,
- b) $E(\mathbf{X}_i) = m$ para todo $t \in T$,
- c) $\gamma_x(r, s) = \gamma_x(r + t, s + t)$ para todos $r, s, t \in T$.

¹ Alguns livros texto referem-se à estacionariedade como estacionariedade no sentido amplo e estacionariedade estrita como estacionariedade de 2ª ordem ou, simplesmente, estacionariedade.

Assim pode-se redefinir autocovariância de um processo estacionário como uma função de uma única variável:

$$\gamma_x(h) \equiv \gamma_x(h,0) = Cov(X_{t+h}, X_t), \forall t, h \in T. \quad (2-3)$$

A função γ_x é referida como a função de autocovariância de $\{X_t\}$ e $\gamma_x(h)$ é o valor da função para *lag* (atraso ou intervalo) h . A função de autocorrelação (ACF) de $\{X_t\}$ é definida analogamente como a função cujo valor no intervalo h é:

$$\rho_x(h) \equiv \gamma_x(h)/\gamma_x(0) = Corr(X_{t+h}, X_t), \forall t, h \in T. \quad (2-4)$$

Pode-se definir que uma série temporal $\{X_t, t \in T\}$ é dita estritamente estacionária se as distribuições conjuntas de $(X_{t_1}, \dots, X_{t_k})'$ e $(X_{t_1+h}, \dots, X_{t_k+h})'$ são as mesmas para todos inteiros positivos k e para todos $t_1, \dots, t_k, h \in T$ (Brockwell e Davis, 1987). A definição de estacionariedade estrita significa intuitivamente que os gráficos sobre dois intervalos de tempo de mesma extensão pertencentes a uma dada realização de uma série temporal estritamente estacionária devem exibir características estatísticas semelhantes.

Outra definição importante associada ao conceito de estacionariedade estrita é a série temporal gaussiana. Diz-se que um processo $\{X_t\}$ é uma série temporal gaussiana se e somente se a função de distribuição de $\{X_t\}$ é normal (Brockwell e Davis, 1987).

Finalmente, se $\{X_t, t \in T\}$ é um processo gaussiano estacionário então $\{X_t\}$ é estritamente estacionário, desde que para todo $n \in \{1, 2, \dots\}$ e para todo $t_1, \dots, t_k, h \in T$, os vetores aleatórios $(X_{t_1}, \dots, X_{t_k})'$ e $(X_{t_1+h}, \dots, X_{t_k+h})'$ possuem a mesma média e matriz de covariância e, conseqüentemente, a mesma distribuição.

2.4 MODELOS PARAMÉTRICOS DE PROCESSOS ESTOCÁSTICOS

Define-se a Densidade do Espectro de Potência (PSD) como a transformada de Fourier discreta no tempo de uma seqüência de autocorrelação infinita (Marple, 1987). Esta relação pode ser considerada como uma descrição não paramétrica dos momentos de

segunda ordem de um processo aleatório. Da mesma maneira, uma descrição paramétrica dos momentos de segunda ordem pode ser obtida supondo-se um modelo de séries temporais para o processo aleatório.

A PSD do modelo de séries temporais será então uma função dos parâmetros do modelo ao invés da seqüência de autocorrelação. Uma classe especial de modelos de séries temporais, orientada por processos de ruído branco e possuindo funções de transferência racionais, a qual segue as características anteriores é explorada neste trabalho: esta classe inclui os modelos autorregressivos (AR), os modelos média móvel (MA) e os modelos autorregressivos e de média móvel (ARMA). As saídas desta classe de modelos possuem PSD que são totalmente descritas em termos dos parâmetros do modelo e da variância do processo ruído branco motor. Os parâmetros e a variância do ruído branco são obtidos a partir da função de autocorrelação, o que será discutido adiante.

A motivação para se utilizar modelos paramétricos de processos aleatórios é a habilidade de se obter melhores estimativas da PSD baseada sobre o modelo, em contraste com os estimadores espectrais clássicos (Marple, 1987). Os métodos clássicos, como o periodograma, permitem estimativas da PSD a partir de um conjunto de uma janela dos dados ou estimativas da seqüência de autocorrelação (ACF). Dados não disponíveis ou subestimados para a ACF fora da janela são implicitamente zero, assunção pouco realística que leva a distorções na estimativa espectral. Pode-se, entretanto, utilizar as informações disponíveis a respeito das amostras para construir um modelo que se aproxima do processo gerador da série temporal, fazendo hipóteses mais realísticas a respeito dos dados fora da janela, o que é melhor que a assunção do valor zero, eliminando a necessidade da função de janela e seu efeito de distorção. O aumento da fidelidade na resolução espectral é determinado, então, pela propriedade do modelo selecionado e a habilidade de se ajustar os dados medidos à ACF (obtida ou estimada a partir dos dados) utilizando um modelo mínimo parametrizado (Marple, 1987).

Finalmente, pode-se citar que a abordagem paramétrica para a estimação espectral envolve três passos:

- a) seleção do modelo paramétrico de séries temporais apropriado para os dados;
- b) estimativa dos parâmetros do modelo;
- c) inserção dos parâmetros estimados na expressão apropriada para a PSD teórica do modelo em questão.

2.5 MODELOS ARMA

Como considerar-se-á as imagens tais quais sinais, é possível abstrair a idéia de que, assim como nos sinais unidimensionais, os estimadores parametrizados apresentam melhores resultados que os não parametrizados, ou seja, o uso de informações ou assunções *a priori* nos modelos parametrizados produz resultados mais aproximados do processo estudado do que as estimativas baseadas tão somente na função de autocorrelação ou na densidade do espectro de potência, ou seja, dos estimadores chamados “clássicos” para séries temporais, os quais partem de estimativas não parametrizadas, como no método do periodograma (Kay, 1988).

Vem daí a necessidade de uma eficiente estimação de parâmetros para a modelagem, e do uso de modelos que, apesar de não serem conhecidas as entradas e tampouco a função de transferência, sejam capazes de produzir uma eficiente estimativa inicial de parâmetros para a posterior síntese, baseada na função de transferência estimada. Por apresentarem estas características no campo da análise de sistemas, as identificações de modelos ARMA tornam-se a base principal deste trabalho.

Os modelos ARMA englobam uma descrição paramétrica para os momentos de segunda ordem, a partir da assunção dos modelos de séries temporais para processos estocásticos. A densidade do espectro de potência será, então, uma função obtida a partir dos parâmetros do modelo, ao invés de simplesmente uma transformada de Fourier discreta no tempo (DTFT) da Função de Autocorrelação.

Equações-diferença lineares com coeficientes constantes serão utilizadas para definir os modelos ARMA, os quais são uma família paramétrica de processos estacionários. Para uma função de autocovariância γ tal que $\lim_{h \rightarrow \infty} \gamma(h) = 0$, e para cada inteiro $k > 0$, é possível encontrar-se um processo ARMA com função de autocovariância γ_x tal que $\gamma_x(h) = \gamma(h)$, $h = 0, 1, \dots, k$. É por esta razão que a classe de modelos ARMA tem um papel importante na modelagem de séries temporais (Brockwell e Davis, 1987).

2.6 MODELOS ARMA UNIDIMENSIONAIS

Inicialmente, uma abordagem dos modelos ARMA unidimensionais será efetuada, tendo em vista a sua menor complexidade para, posteriormente, buscar-se a extensão bidimensional. O modelo unidimensional também será útil quando da aproximação de modelos bidimensionais em unidimensionais, no que será utilizado em uma das abordagens propostas pelo trabalho.

Em muitos aspectos, a série temporal $\{X_t\}$ mais simples é aquela na qual as variáveis aleatórias X_t , $t = 0, \pm 1, \pm 2, \dots$ são independentes e igualmente distribuídas com média zero e variância σ^2 . Ignorando-se todas as propriedades das distribuições conjuntas de $\{X_t\}$, exceto as que podem ser deduzidas dos momentos $E(X_t)$ e $E(X_s X_t)$, tais processos são definidos como a classe de processos estacionários com média zero e que possuem a função de autocovariância:

$$\gamma(h) = \begin{cases} \sigma^2, & \text{se } h = 0, \\ 0, & \text{se } h \neq 0. \end{cases} \quad (2-5)$$

Adicionalmente, o processo $\{Z_t\}$ é dito um ruído branco de média zero e variância σ^2 , dado por:

$$\{Z_t\} \sim WN(0, \sigma^2), \quad (2-6)$$

se e somente se $\{Z_t\}$ tem média zero e função de covariância tal qual em (2-5). Um grande número de processos estacionários são passíveis de geração utilizando ruídos brancos como os valores iniciais de um conjunto de equações diferença lineares.

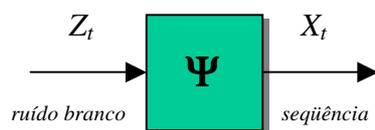


Fig. 2.1 – Filtro Linear

Os modelos ARMA, então, baseiam-se na premissa que a série temporal será gerada a partir de um filtro linear cuja entrada é um ruído branco gaussiano de variância σ^2 e média nula, como mostra a Figura 2.1.

Um processo $\{X_t, t = 0, \pm 1, \pm 2, \dots\}$ é dito um processo ARMA(p, q) se $\{X_t\}$ é estacionário para todo t ,

$$X_t - \phi_1 X_{t-1} - \dots - \phi_p X_{t-p} = Z_t + \theta_1 Z_{t-1} + \dots + \theta_q Z_{t-q}, \quad (2-7)$$

onde $\{Z_t\} \sim WN(0, \sigma^2)$ (Brockwell e Davis, 1987). É denotado por ARMA(p, q), onde p e q determinam a ordem autorregressiva e média móvel do modelo, respectivamente. Sem perda de generalidade considerar-se-á média zero para X_t .

2.6.1 Processos ARMA Causais e Inversíveis

Na literatura de processamento de sinais, modelos racionais representam parte importante no estudo de sinais aleatórios discretos no tempo, pois apresentam melhor estimativa do espectro de potência, e utilizam os modelos de séries temporais ou, como também são chamados, modelos de função de transferência racional. O termo racional relaciona-se diretamente com a linearidade e convergência das séries estudadas.

Em tais modelos, o sinal ou seqüência de entrada Z_t relaciona-se com a seqüência de saída X_t pela equação diferença dada em (2-7).

Quando a seqüência de entrada Z_t é um ruído branco gaussiano, a equação (2-7) é a equação linear de um modelo ARMA.

É importante dizer que o ruído branco Z_t é distinto de outros ruídos observáveis porque é uma parte inata ao modelo e da sua natureza aleatória, essencial para a determinação da saída X_t e completamente diferente de ruídos multiplicativos tais quais o *speckle* de imagens de radar de abertura sintética (SAR).

Pode-se tomar a função do filtro linear e causal do sistema como h_k , a qual produz X_t a partir de Z_t , e tomando a transformada z de (2-7) (Marple, 1987), obtém-se a Função de Transformação do filtro por:

$$H[z] = \frac{\Theta[z]}{\Phi[z]} \quad (2-8)$$

e cujas formas polinomiais são dadas por:

$$\Phi[z] = 1 - \sum_{k=1}^p \phi(k)z^{-k}, \quad (2-9)$$

$$\Theta[z] = 1 + \sum_{k=1}^q \theta(k)z^{-k}, \quad (2-10)$$

$$H[z] = 1 + \sum_{k=1}^{\infty} h(k)z^{-k}. \quad (2-11)$$

O polinômio $\Phi[z]$ representa a parte autorregressiva do modelo, enquanto o polinômio $\Theta[z]$ representa sua parte média móvel.

Uma forma alternativa de escrever de forma mais compacta as equações acima em termos da equação diferença apresentada em (2-7) é:

$$\phi(B)X_t = \theta(B)Z_t, t = 0, \pm 1, \pm 2, \dots, \quad (2-12)$$

onde ϕ e θ são polinômios de grau p e q ,

$$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p \quad (2-13)$$

$$\text{e } \theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q \quad (2-14)$$

onde B é o operador atraso definido por:

$$B^j X_t = X_{t-j}, j = 0, \pm 1, \pm 2, \dots \quad (2-15)$$

o qual é igual ao operador z^{-1} da transformada z .

O processo ARMA(p,q) definido pelas equações $\phi(B)X_t = \theta(B)Z_t$ é dito causal se

existirem uma série de constantes $\{\psi_j\}$ tais que $\sum_{j=0}^{\infty} |\psi_j| < \infty$ e

$$X_t = 1 + \sum_{j=0}^{\infty} \psi_j Z_{t-j}, t = 0, \pm 1, \dots \quad (2-16)$$

Deve-se entender que a causalidade não é uma propriedade somente do processo $\{X_t\}$ mas sim do relacionamento entre os processos $\{X_t\}$ e $\{Z_t\}$ integrantes da definição do modelo. Pode-se afirmar que $\{X_t\}$ é causal se é obtido a partir de $\{Z_t\}$ aplicado em um filtro causal linear (Brockwell e Davis, 1987).

Se $\{X_t\}$ for um processo ARMA(p,q) onde os polinômios ϕ e θ não tenham zeros comuns, então $\{X_t\}$ é causal se e somente se $\phi(z) \neq 0$ para todo $z \in \mathbf{C}$ tal que $|z| \leq 1$ (Kay, 1988). Os coeficientes $\{\psi_j\}$ são determinados pela relação:

$$\Psi[z] = \frac{\Theta[z]}{\Phi[z]}, |z| \leq 1. \quad (2-17)$$

Adicionalmente, se $\{X_t\}$ é um processo estacionário com função de autocovariância γ_e

se $\sum_{j=0}^{\infty} |\psi_j| < \infty$, então para cada $t \in \mathbf{Z}$ a série converge em média quadrática (*mean*

square) absolutamente com probabilidade 1 (um) para o mesmo limite. Se $Y_t = \psi(B)X_t$, então o processo $\{Y_t\}$ é estacionário com função de autocovariância:

$$\gamma_Y(h) = \sum_{j,k=-\infty}^{\infty} \psi_j \psi_k \gamma(h-j+k) \quad (\text{Brockwell e Davis, 1987}). \quad (2-18)$$

Deve-se, agora, introduzir o conceito de inversibilidade, o qual é estritamente relacionado ao de causalidade.

Dado um processo ARMA(p, q) definido pelas equações $\phi(B)X_t = \theta(B)Z_t$, este é dito inversível se existirem uma série de constantes $\{\pi_j\}$ tais que $\sum_{j=0}^{\infty} |\pi_j| < \infty$ e

$$Z_t = \sum_{j=0}^{\infty} \pi_j X_{t-j}, t = 0, \pm 1, \dots \quad (2-19)$$

Assim como a causalidade, a inversibilidade não é uma propriedade tão somente do processo $\{X_t\}$, mas do relacionamento dos processos $\{X_t\}$ e $\{Z_t\}$ (Brockwell e Davis, 1987).

Se $\{X_t\}$ for um processo ARMA(p, q) onde os polinômios ϕ e θ não tenham zeros comuns, então $\{X_t\}$ é inversível se e somente se $\theta(z) \neq 0$ para todo $z \in C$ tal que $|z| \leq 1$ (Kay, 1988).

Os coeficientes $\{\pi_j\}$ são determinados pela relação:

$$\Pi[z] = \frac{\Phi[z]}{\Theta[z]}, |z| \leq 1. \quad (2-20)$$

As condições de estabilidade e estacionariedade resumem-se na condição de fase mínima (Oppenheim e Schaffer, 1975; Dutra, 1990) a qual estabelece que o sinal, e sua transformada Z, segundo o modelo ARMA, têm as propriedades a seguir:

- a) Causalidade;

- b) Pólos e zeros dentro do círculo unitário;
- c) Maior parte de sua energia perto da origem, no espectro de potência;
- d) H e H^{-1} são somáveis absolutamente.

Observa-se, então, que os polinômios $\Phi[z]$ e $\Theta[z]$ devem possuir todos os seus zeros dentro do círculo unitário do plano- z (z -plane) a fim de garantir que o filtro $H[z]$ seja causal, estável, inversível e de fase mínima, assim como o processo estritamente estacionário (Marple, 1987). Outra consideração genérica a respeito dos modelos ARMA é que os mesmos também são referenciados como modelos zero-pólos, tendo em vista as posições dos polinômios na razão $H[z]$.

A transformada Z da função de autocorrelação na saída de um filtro linear, dada por $P_{XX}[z]$, é relacionada com a transformada Z da autocorrelação de entrada $P_{ZZ}[z]$ por (Marple,1987):

$$P_{XX}[z] = H[z]H^*\left[\frac{1}{z^*}\right]P_{ZZ}[z] = \frac{\Theta[z]\Theta^*\left[\frac{1}{z^*}\right]}{\Phi[z]\Phi^*\left[\frac{1}{z^*}\right]}P_{ZZ}[z]. \quad (2-21)$$

Ao se avaliar a expressão acima ao longo do círculo unitário, fazendo $z=e^{j2\pi f}$ para $-1/2 \leq f \leq 1/2$, tem-se a densidade do espectro de potência (PSD) $P_{XX}(f)$. Como se considerou a entrada Z_t como um ruído branco de média zero e variância σ^2 como ruído branco motor, a PSD do ruído é σ^2 e a do modelo ARMA será:

$$P_{ARMA}(f) = P_{XX}(f) = \sigma^2 \left| \frac{\Theta(f)}{\Phi(f)} \right|^2. \quad (2-22)$$

Em outras palavras, a especificação dos parâmetros ϕ_k (coeficientes autorregressivos) e θ_k (coeficientes de média móvel) e σ^2 é equivalente a especificar a PSD do processo X_t .

Pode-se supor que $\phi_0 = 1$ e $\theta_0 = 1$, sem perda de generalidade, uma vez que qualquer ganho no filtro pode ser incorporado a σ^2 (Marple,1987).

A Figura 2.2 representa esquematicamente um processo ARMA.

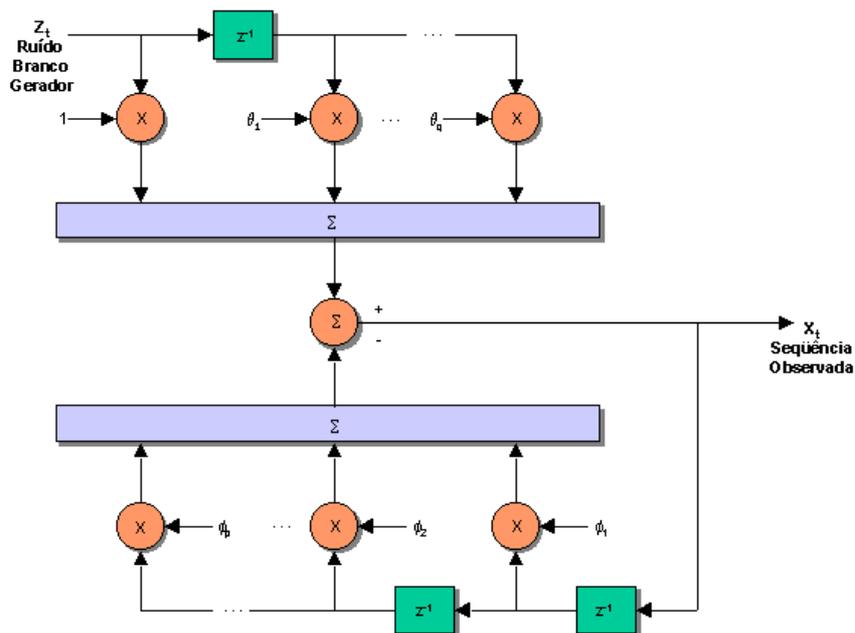


Fig. 2.2- Modelo Autorregressivo e de Média Móvel (ARMA) de um processo aleatório.
FONTE: adaptado de Marple (1987).

2.6.2 Modelos MA

Se todos os coeficientes ϕ_k , exceto $\phi_0 = 1$ são considerados zero para os parâmetros ARMA, então:

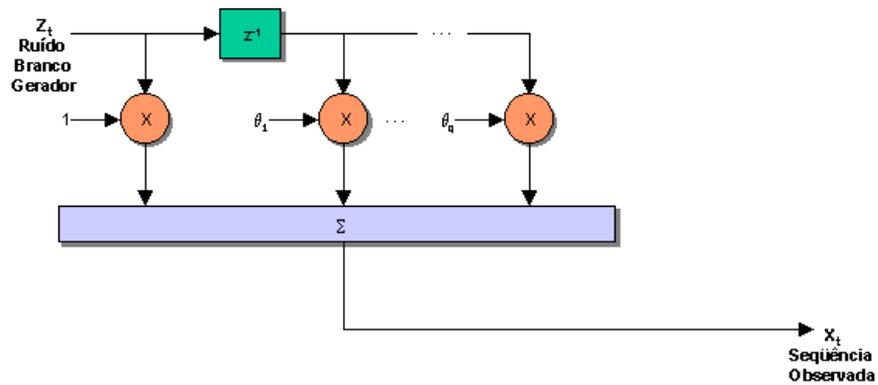
$$X_t = Z_t + \theta_1 Z_{t-1} + \dots + \theta_q Z_{t-q} \quad (2-23)$$

e o processo é estritamente MA de ordem q , e

$$P_{MA}(f) = \sigma^2 |\Theta(f)|^2 \quad (2-24)$$

Este modelo é também referenciado como todo-zeros(*all-zeros*) e é denotado como um processo MA(q).

A Figura 2.3 representa esquematicamente um processo MA.



**Fig. 2.3 - Modelo Média Móvel (MA) de um processo aleatório.
 FONTE: adaptado de Marple (1987).**

2.6.3 Modelos AR

Se, ao contrário do anterior, todos os coeficientes θ_k são considerados zero (exceto $\theta_0 = 1$), ter-se-á:

$$X_t = Z_t + \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} \quad (2-25)$$

O processo é estritamente AR de ordem p , onde:

$$P_{AR}(f) = \frac{\sigma^2}{|\Phi(f)|^2} \quad (2-26)$$

O modelo AR é também conhecido com todo-pólos (*all-poles*) e é denotado como um processo AR(p).

A Figura 2.4 representa esquematicamente um processo AR.

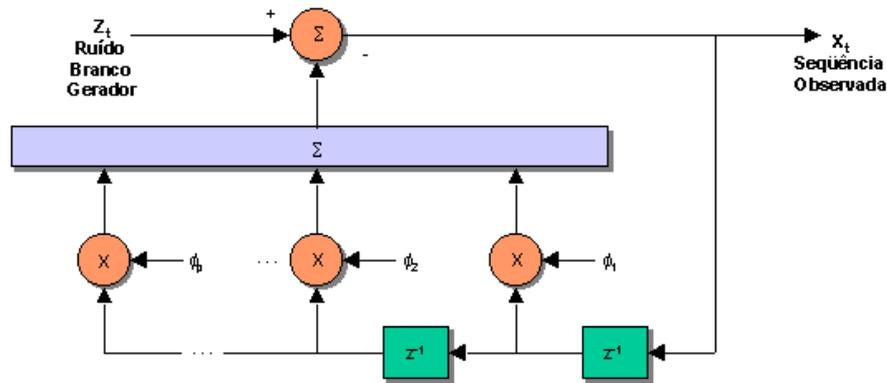


Fig. 2.4 - Modelo Autorregressivo (AR) de um processo aleatório.
FONTE: adaptado de Marple (1987).

2.6.4 Relação entre Modelos de Séries Temporais

Kay (1988) afirma que o Teorema de Decomposição de Wold (Wold, 1954) relaciona os modelos AR, MA e ARMA. Este teorema define que um processo aleatório estritamente estacionário pode ser decomposto em um componente completamente aleatório e outro determinístico. O componente determinístico do processo aleatório é, então, aquele que é perfeitamente predizível baseado num passado infinito, ou seja, a seqüência observada X_t pode ser expressa em termos de $-\sum_{k=1}^{\infty} \phi_k X_{t-k}$, onde ϕ_k representa uma série de constantes que correspondem a coeficientes autorregressivos estimados. Um corolário do mesmo teorema que diz que se a PSD é puramente contínua, qualquer processo ARMA ou AR pode ser representado por um processo MA infinito (Marple, 1987). Um teorema de Kolmogorov (1941) declara, por sua vez, que qualquer processo ARMA ou MA pode ser representado por um processo AR de ordem infinita. A importância destes teoremas reside no fato de que a escolha de um modelo inapropriado, dentre os três tipos, ainda assim pode alcançar a resultados razoavelmente aproximados utilizando-se um modelo de ordem elevada.

Existem vantagens algorítmicas estimando os parâmetros de um modelo a partir dos dados e então calculando os parâmetros de um outro modelo a partir dos parâmetros do modelo inicial (Kay, 1988). Levando-se em conta que os modelos AR são mais simples

para a análise e estimação de parâmetros que os modelos MA, uma vez que estes não geram sistemas lineares para o cálculo de estimativas, ao contrário daqueles, os quais permitem estimativas lineares como as equações de Yule-Walker (Seção 2.6.5) e o algoritmo de Levinson-Durbin, e, pelo mesmo motivo, sabendo-se que os modelos ARMA completos também são de difícil estimativa, devido a maior complexidade encontrada em sua parte MA, freqüentemente utiliza-se uma estimativa AR como aproximação inicial para um algoritmo de estimação MA ou ARMA.

2.6.5 Relacionamento entre os Parâmetros de um Modelo ARMA e a Função de Autocorrelação

Os relacionamentos entre os parâmetros de um modelo e a função de autocorrelação (ACF) são explicitamente obtidos a partir da transformada z inversa da PSD (Kay, 1988). Estes relacionamentos também podem ser derivados diretamente dos modelos de séries temporais.

A partir de (2-21) obtém-se:

$$P_{xx}[z]\Phi[z] = \frac{\Theta^* \left[\frac{1}{z^*} \right]}{\Phi^* \left[\frac{1}{z^*} \right]} \Theta[z] \sigma^2 = H^* \left[\frac{1}{z^*} \right] \Theta[z] \sigma^2. \quad (2-27)$$

Supondo-se um ruído branco como entrada e realizando-se a transformada z inversa obtém-se:

$$\sum_{i=0}^p \phi_i \rho_{k-i} = \sigma^2 \sum_{i=0}^q \theta_i h_{i-k}^*. \quad (2-28)$$

Utilizando-se a causalidade de $H[z]$, e $h_k = 0$ para $k < 0$, o resultado final da ACF para um processo ARMA é:

$$\rho_k = \begin{cases} -\sum_{i=0}^p \phi_i \rho_{k-i} + \sigma^2 \sum_{i=0}^{q-k} h_i^* \theta_{i+k} & \text{para } k = 0, 1, \dots, q \\ -\sum_{i=0}^p \phi_i \rho_{k-i} & \text{para } k \geq q+1 \end{cases}, \quad (2-29)$$

e considerando-se que $\rho_k = \frac{\gamma_k}{\gamma_0}$, onde γ é a Função de Autocovariância.

Note-se que o relacionamento entre os parâmetros do processo ARMA e a ACF é do tipo não linear, de maneira que, para se encontrar os parâmetros do modelo a partir da ACF deve-se resolver um conjunto de equações não lineares, tendo em vista o termo $\sum_{i=0}^{q-k} h_i^* \theta_{i+k}$. Se, no entanto, considerar-se o processo como apenas AR fazendo $\theta_l = \delta_l$, $h_{-k}^* = 0$ (para $k > 0$) e $h_0^* = [\lim_{z \rightarrow \infty} H[z]]^* = 1$ tem-se:

$$\rho_k = \begin{cases} -\sum_{i=0}^p \phi_i \rho_{-i} + \sigma^2 & \text{para } k = 0 \\ -\sum_{i=0}^p \phi_i \rho_{k-i} & \text{para } k \geq 1. \end{cases} \quad (2-30)$$

As equações (2-30) são conhecidas como equações de Yule-Walker (Marple, 1987), de Yule (1927) e Walker (1931). Estas definem um relacionamento linear entre os parâmetros de um processo AR e a ACF. Portanto, obtida a ACF, pode-se determinar os parâmetros AR solucionando-se um conjunto de equações lineares, como na forma matricial expressa a seguir:

$$\underbrace{\begin{bmatrix} \rho_0 & \rho_{-1} & \cdots & \rho_{-(p-1)} \\ \rho_1 & \rho_0 & \cdots & \rho_{-(p-2)} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{(p-1)} & \rho_{(p-2)} & \cdots & \rho_0 \end{bmatrix}}_P \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix} = - \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_p \end{bmatrix} \quad (2-31)$$

Pode-se facilmente perceber que a matriz P é hermitiana² ($P^H = P$) e Toeplitz (tendo em vista que os elementos na diagonal principal são iguais). A matriz também é positivo semi-definida³, devido a propriedade positivo semi-definida da ACF (Marple, 1987). O

² Uma matriz A é hermitiana se $A=A^H$, onde H denota conjugada complexa transposta.

³ Se a matriz A é positivo-semidefinida, então $\det A \geq 0$.

algoritmo de Levinson para a solução de (2-31) é de ordem $O(n^2)$ e será utilizado neste trabalho, sendo discutido adiante.

A partir de (2-30) pode-se também incorporar σ^2 , obtendo-se

$$\begin{bmatrix} \rho_0 & \rho_{-1} & \cdots & \rho_{-(p-1)} \\ \rho_1 & \rho_0 & \cdots & \rho_{-(p-2)} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{(p-1)} & \rho_{(p-2)} & \cdots & \rho_0 \end{bmatrix} \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix} = \begin{bmatrix} \sigma^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix}, \quad (2-32)$$

o que é uma outra forma de se expressar as equações de Yule-Walker.

Os relacionamentos para os processos MA também são obtidos a partir de (2-29), fazendo-se $\phi_l = \delta_l$ e $h_l = \theta_l$.

$$\rho_k = \begin{cases} \sigma^2 \sum_{i=0}^{q-k} \theta_i^* \theta_{i+k} & \text{para } k = 0, 1, \dots, q \\ 0 & \text{para } k \geq q + 1. \end{cases} \quad (2-33)$$

Percebe-se nitidamente que os relacionamentos entre os parâmetros MA e a ACF são do tipo não linear.

Para os modelos ARMA completos, as equações de Yule-Walker também derivam diretamente da equação diferença para o processo ARMA (2-7). As especializações nas partes MA e AR são realizadas tais quais nas derivações anteriores.

2.6.6 Função de Autocorrelação Parcial

A função de autocorrelação parcial (PACF), tal qual a função de autocorrelação, depende somente dos momentos de segunda ordem do processo aleatório. A autocorrelação parcial α_k a um *lag* (intervalo) k pode ser vista como a correlação entre X_l e X_{k+l} , ajustada para a observação X_2, \dots, X_k (Brockwell e Davis, 1987). Pode-se, então, definir a função de autocorrelação parcial α de uma série temporal estacionária por:

$$\alpha_1 = \text{Corr}(X_2, X_1) = \rho_1, \quad (2-34)$$

e

$$\alpha_k = \text{Corr}(X_{k+1} - P_{\overline{sp}\{1, X_2, \dots, X_k\}} X_{k+1}, X_1 - P_{\overline{sp}\{1, X_2, \dots, X_k\}} X_1), k \geq 2, \quad (2-35)$$

onde as projeções $P_{\overline{sp}\{1, X_2, \dots, X_k\}} X_{k+1}$ e $P_{\overline{sp}\{1, X_2, \dots, X_k\}} X_1$ são dadas por:

$$P_{\overline{sp}\{1, Z_1, \dots, Z_n\}} X = \sum_{i=0}^n \alpha_i Z_i, Z_0 = 1 \quad (2-36)$$

e onde $\alpha_0, \dots, \alpha_n$ satisfazem ao produto interno:

$$\left\langle \sum_{i=0}^n \alpha_i Z_i, Z_j \right\rangle = \langle X, Z_j \rangle, j = 0, 1, \dots, n, \quad (2-37)$$

ou, de maneira equivalente:

$$\sum_{i=0}^n \alpha_i E(Z_i Z_j) = E(X Z_j), j = 0, 1, \dots, n. \quad (2-38)$$

A autocorrelação parcial α_k , $k \geq 2$, é então a correlação de dois resíduos obtidos após a regressão X_{k+1} e X_1 , a partir das observações intermediárias X_2, \dots, X_k (Brockwell e Davis, 1987).

Uma definição equivalente da PACF, utilizada neste trabalho, é dada a seguir.

Sendo $\{X_t\}$ um processo estacionário de média zero e com função de autocovariância γ tal que $\gamma_h \rightarrow 0$ e $h \rightarrow \infty$, e supondo-se que ϕ_{nj} , $j = 1, \dots, n$ ($n = 1, 2, \dots$), são os coeficientes na representação:

$$P_{\overline{sp}\{X_1, \dots, X_n\}} X_{n+1} = \sum_{i=0}^n \phi_{nj} X_{nj}. \quad (2-39)$$

Então, a partir de:

$$\langle X_{n+1} - P_{S^p\{X_1, \dots, X_n\}} X_{n+1}, X_j \rangle = 0, j = n, \dots, 1, \quad (2-40)$$

obtém-se:

$$\begin{bmatrix} \rho_0 & \rho_{-1} & \cdots & \rho_{-(n-1)} \\ \rho_1 & \rho_0 & \cdots & \rho_{-(n-2)} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{(n-1)} & \rho_{(n-2)} & \cdots & \rho_0 \end{bmatrix} \begin{bmatrix} \phi_{n1} \\ \phi_{n2} \\ \vdots \\ \phi_{nm} \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_n \end{bmatrix}. \quad (2-41)$$

A PACF α_n de $\{X_t\}$ no lag (atraso) n é:

$$\alpha_n = \phi_{nm}, n \geq 1, \quad (2-42)$$

onde ϕ_{nm} é unicamente determinada por (2-41) (Brockwell e Davis, 1987).

Os coeficientes ϕ_{nm} representam a correlação normalizada entre X_{k+1} e X_k , com as correlações X_2, \dots, X_k removidas (Kay, 1988; Dutra, 1990). Outra forma de visualizar ϕ_{nm} é tê-lo como o último coeficiente obtido ao se ajustar uma seqüência AR de ordem crescente. O negativo dos coeficientes, $k_i = -\phi_{nm}$ são chamados de coeficientes de reflexão, devido à sua interpretação como parâmetros físicos de um modelo de tubo acústico de voz (Makhoul, 1981) ou modelos sísmicos da terra distribuídos em camadas (Robinson e Treitel, 1980).

Tais coeficientes de autocorrelação parcial serão empregados no Algoritmo de Levinson-Durbin, visto a seguir.

2.6.7 Algoritmo de Levinson-Durbin

A solução das equações de Yule-Walker para um processo AR(p) pode ser obtida a partir de qualquer método padrão para a solução de equações lineares. O método da eliminação Gaussiana, por exemplo, poderia ser utilizado, mas o algoritmo que reflete sua implementação é de ordem $O(n^3)$. As equações de Yule-Walker, no entanto, possuem características que permitem sua solução utilizando um algoritmo de $O(n^2)$

conhecido como algoritmo de Levinson-Durbin ou simplesmente Levinson (Marple, 1987). Este algoritmo também pode ser definido como um esquema recursivo de se computar $\phi_n = (\phi_{n1}, \dots, \phi_{nn})'$ e v_n para $n = 1, 2, \dots$, onde v_n é uma estimativa de σ^2 , a variância do ruído branco motor do processo AR.

Além de ser um algoritmo computacionalmente eficiente, este algoritmo trabalha com propriedades fundamentais de um modelo AR. O próprio conceito de coeficiente de reflexão (Seção 2.6.6) tem sua origem no algoritmo de Levinson.

Formalmente, Brockwell e Davis(1987) definem o Algoritmo de Levinson-Durbin por: Seja $\{X_t\}$ um processo estacionário AR(p) de média zero e função de autocovariância γ tal que $\gamma_0 > 0$ e $\gamma_h \rightarrow 0$ quando $h \rightarrow \infty$, e tomando, como condições iniciais:

$$\hat{\phi}_{11} = \hat{\rho}_1 = \frac{\hat{\gamma}_1}{\hat{\gamma}_0} \quad \text{e} \quad \hat{v}_1 = (1 - \hat{\rho}_1^2)\hat{\gamma}_0, \quad (2-43)$$

então os coeficientes ϕ_{nj} e v_n são definidos por:

$$\hat{\phi}_{mm} = \left[\hat{\gamma}_m - \sum_{j=1}^{m-1} \hat{\phi}_{m-1,j} \hat{\gamma}_{m-j} \right] \hat{v}_{m-1}^{-1} \quad (2-44)$$

$$\begin{bmatrix} \hat{\phi}_{m,1} \\ \vdots \\ \hat{\phi}_{m,m-1} \end{bmatrix} = \begin{bmatrix} \hat{\phi}_{m-1,1} \\ \vdots \\ \hat{\phi}_{m-1,m-1} \end{bmatrix} - \hat{\phi}_{mm} \begin{bmatrix} \hat{\phi}_{m-1,m-1} \\ \vdots \\ \hat{\phi}_{m-1,m} \end{bmatrix} \quad (2-45)$$

$$\text{e} \quad \hat{v}_m = \hat{v}_{m-1} [1 - \hat{\phi}_{mm}^2]. \quad (2-46)$$

onde v_n é a variância estimada do ruído branco de entrada do processo e $m = 1, 2, \dots, p-1$. O estado final para a ordem p é a solução desejada para as equações de Yule-Walker. A Figura 2.5 representa um sumário do algoritmo recursivo de Levinson.

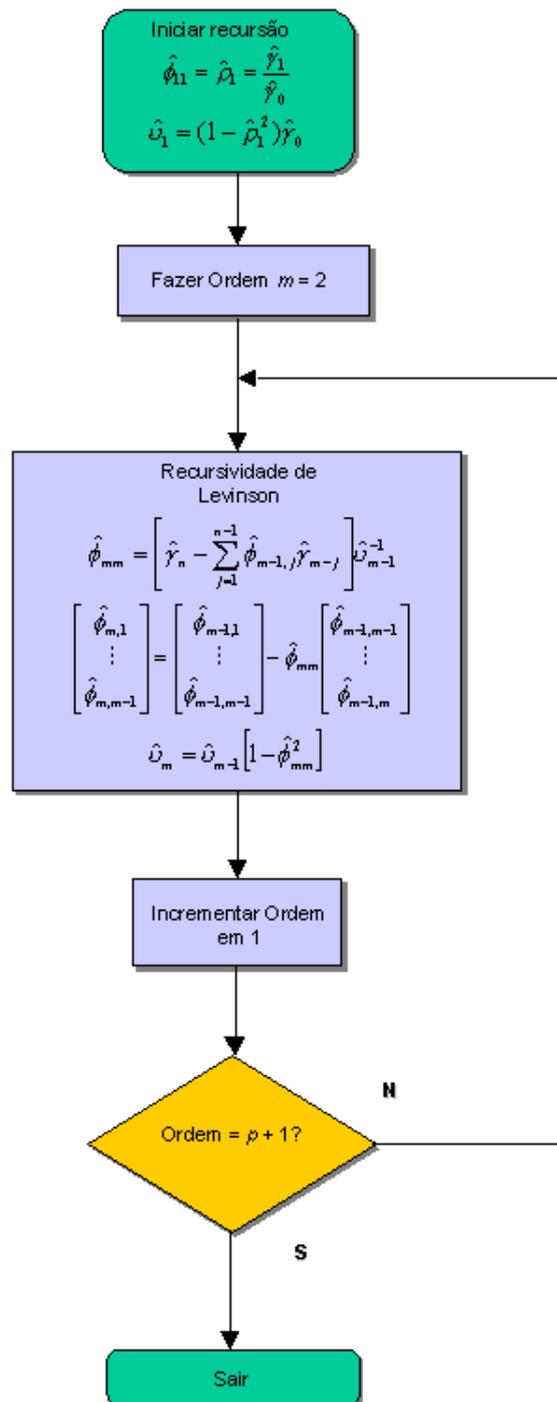


Fig. 2.5 –Sumário da Recursividade de Levinson.

2.7 MODELOS ARMA BIDIMENSIONAIS

2.7.1 Natureza

A excelente performance dos modelos ARMA unidimensionais leva a buscar aplicações com modelos de mesma natureza, porém de características bidimensionais, tendo em vista o processamento de imagens digitais.

A extensão para o modelo bidimensional, entretanto, não é trivial e várias dificuldades são encontradas, principalmente quanto a fatoração de polinômios bidimensionais em polinômios de menor grau. Como consequência, a forma usual de isolar pólos e zeros não é facilmente extensível para duas dimensões. Outro fato é que sistemas bidimensionais possuem muito mais graus de liberdade que sistemas unidimensionais, ou seja, modelos caracterizados por equações diferença recursivas podem ser estendidos a modelos bidimensionais, porém com a possibilidade de coexistirem várias destas equações diferença, sendo que nem todas possuam computabilidade recursiva, a ser definida adiante.

2.7.2 Causalidade, Computabilidade Recursiva e Regiões de Suporte

Um sistema unidimensional é dito causal se sua saída depende unicamente das entradas passadas e presentes. Esta restrição, muito utilizável em sistemas cuja única variável independente é o tempo, não é facilmente transportada para sistemas 2D, tendo em vista que somente uma das variáveis independentes pode representar o tempo. Em outras palavras, uma ou duas das dimensões do sinal representa(m) função(ões) de espaço ao invés de tempo.

Há, no entanto, uma propriedade dos sistemas unidimensionais que é perfeitamente utilizável em duas dimensões: a computabilidade recursiva. Esta permite computar a saída baseando-se em um conjunto finito de saídas passadas, a partir de um conjunto finito de condições iniciais e entradas recentes.

Para se estudar o conceito de computabilidade recursiva para modelos bidimensionais há necessidade de que se adote o conceito de regiões de suporte. *Região de suporte* S_x pode ser definida como a região na qual os valores da seqüência bidimensional não são nulos, uma vez que, na prática, estas são diferentes de zero somente em uma área finita.

A região de suporte mais genérica que supõe o conceito de computabilidade recursiva é o suporte de meio plano não simétrico (NSHP). Esta definição de “causalidade” bidimensional supõe que a seqüência de saída $y(m,n)$ é calculada de uma maneira análoga à de uma imagem *raster* de televisão, executando uma busca linha a linha de cima para baixo, movendo da esquerda para direita em cada linha. Se $y(m,n)$ for considerado como a posição n na linha m , então a saída é gerada recursivamente computando $y(m,-\infty)$ a $y(m,\infty)$, seguido pelo incremento do índice de linha m .

A Figura 2.6 ilustra o uso da computabilidade recursiva para a computação de uma equação-diferença bidimensional do tipo geral:

$$\sum_{i,j \in S_p} \phi_{i,j} X_{m-i,n-j} = \sum_{i,j \in S_q} \theta_{i,j} Z_{m-i,n-j} \quad (2-47)$$

Um caso especial para a região NSHP ocorre quando o suporte é confinado ao quarto de plano (QP), e outra possibilidade é a utilização do suporte de meio plano não simétrico truncado (TNSHP), a qual corresponde a um subconjunto do suporte de meio plano não simétrico, e é definida por:

$$S_x(x_1, x_2, x_3) = \{(i, j) \mid i = -x_3, \dots, 0, \dots, x_1; j = -x_2, \dots, -1\} \cup \{(i, j) \mid j = 0; i = 0, \dots, x_1\} \quad (2-48)$$

As regiões QP e NSHP são vistas na Figura 2.7.

Observe-se que a região NSHP é igual a região TNSHP quando x_1, x_2 e $x_3 \rightarrow \infty$. A região QP é obtida fazendo $x_3 = 0$.

Uma vez definidas as regiões de suporte, é possível estabelecer um modelo ARMA bidimensional “causal”, sendo a causalidade entendida como a utilização de uma região de suporte que possua computabilidade recursiva.

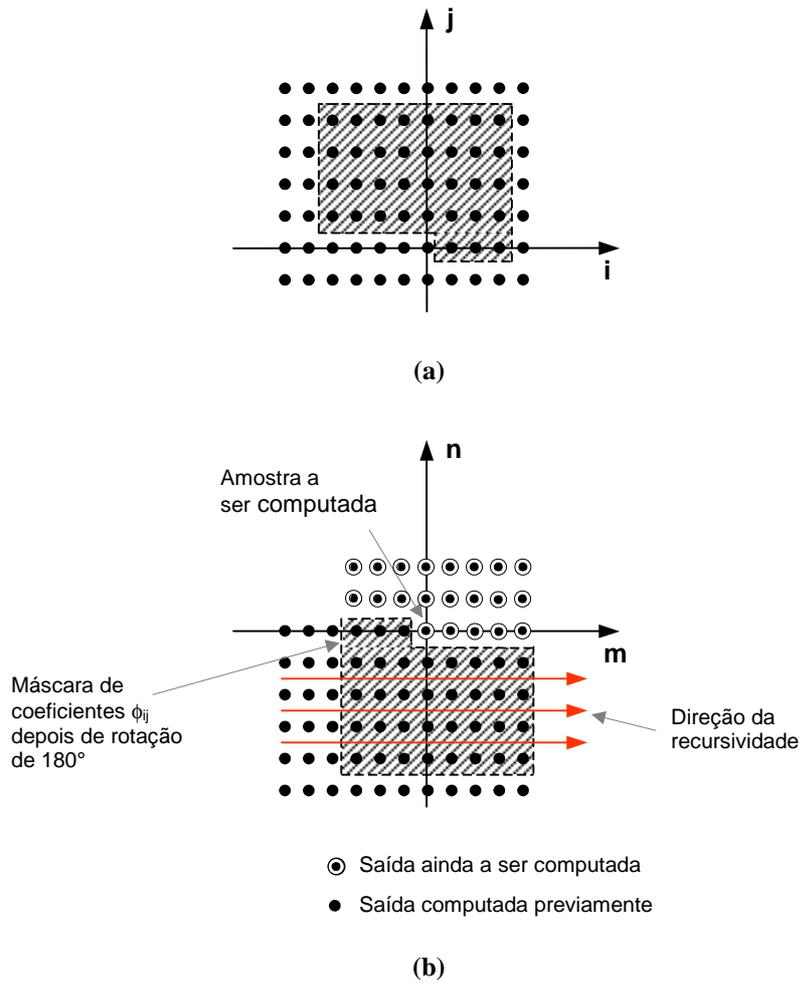
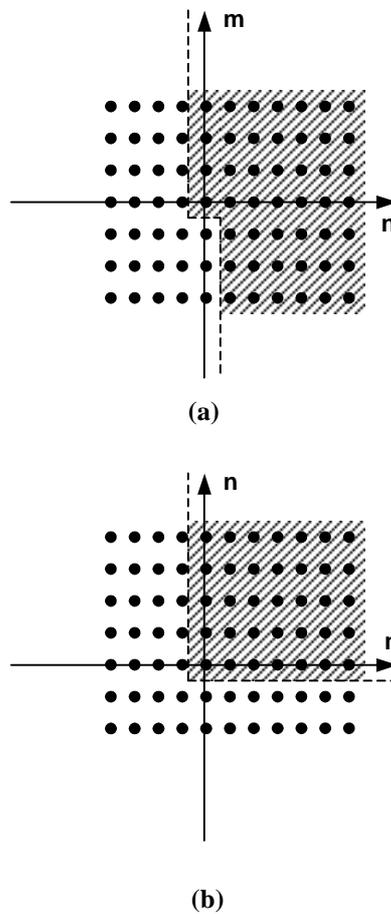


Fig. 2.6 - Computação Recursiva de uma equação diferença bidimensional.
(a) Região de suporte para ϕ_{ij} ; (b) Computação da saída do sistema.
FONTE: Marple (1987).



**Fig. 2.7 – Exemplos de Regiões de Suporte NSHP (a) e QP (b).
 FONTE: Marple (1987).**

2.7.3 Funções de Autocovariância e Autocorrelação Bidimensional

De maneira geral, coeficientes preliminares dos modelos de processos estocásticos são obtidos a partir de sua função de autocovariância. Os processos estocásticos bidimensionais também possuem esta característica, assim como campos aleatórios são considerados estacionários se as estatísticas de até 2ª ordem não dependerem da posição no plano, mas tão somente do intervalo espacial (Dutra, 90).

Define-se a função de autocovariância bidimensional como:

$$\gamma_{k,l} = Cov(Z_{m,n}, Z_{m+k,l+n}) = E\{(Z_{m,n} - \mu_z)(Z_{m+k,l+n} - \mu_z)\}, \quad (2-49)$$

onde $\mu_z = E(Z_{m,n})$.

Utilizando amostras em uma área retangular $m \times n$, tem-se a seguinte expressão para a estimativa polarizada de autocovariância (Dutra, 1990):

$$\hat{\gamma}_{k,l} = \begin{cases} \frac{1}{MN} \sum_{m=0}^{M-1-k} \sum_{n=0}^{N-1-l} (Z_{m+k,n+l} - \hat{\mu}_z)(Z_{m,n} - \hat{\mu}_z); k \geq 0, l \geq 0 \\ \frac{1}{MN} \sum_{m=0}^{M-1-k} \sum_{n=-l}^{N-1} (Z_{m+k,n+l} - \hat{\mu}_z)(Z_{m,n} - \hat{\mu}_z); k \geq 0, l < 0, \\ \hat{\gamma}_{-k,-l}; k \leq 0, \forall l \end{cases} \quad (2-50)$$

onde $0 \leq m < M$, $0 \leq n < N$, $|k| \leq p_1 \ll M$, $|l| \leq p_2 \ll N$ e $\hat{\mu}_z = \frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} Z_{m,n}$.

2.7.4 Processos AR, MA e ARMA Bidimensionais (2D)

Uma seqüência AR2D $X_{m,n}$ pode ser gerada excitando-se um filtro linear e invariante em translação (LSI) bidimensional com um ruído branco 2D (ou campo aleatório) $Z_{m,n}$ como abaixo:

$$X_{m,n} = - \sum_{(i,j) \in S'_p} \hat{\phi}_{i,j} X_{m-i,n-j} + Z_{m,n}, \text{ e } S'_p = S_p - \{(0,0)\} \quad (2-51)$$

Os intervalos (*range*) dos valores de m e n dependem da região de suporte escolhida para a matriz de parâmetros AR, região esta que pode ser NSHP ou QP.

Da mesma maneira, para um processo estocástico bidimensional, ou seja, um campo aleatório, estacionário e de média zero, pode-se definir a equação diferença do modelo ARMA2D:

$$X_{m,n} = \sum_{(i,j) \in S_p} \theta_{i,j} Z_{m-i,n-j} - \sum_{(i,j) \in S'_p} \phi_{i,j} X_{m-i,n-j}, \text{ } S'_p = S_p - \{(0,0)\} \quad (2-52)$$

ou seja, tem-se extensões bidimensionais das equações vistas anteriormente, e a função de sistema, usando a transformada z bidimensional, pode ser definida como:

$$H[z_1, z_2] = \frac{\sum_i \sum_j \theta_{i,j} z_1^{-i} z_2^{-j}}{\sum_i \sum_j \phi_{i,j} z_1^{-i} z_2^{-j}}, \quad (2-53)$$

onde $\phi_{0,0} = \theta_{0,0} = 1$.

Deve-se observar que, para um modelo estável e “causal”, a região de suporte para os parâmetros AR e MA deve estar contida na região NSHP, de maneira que se possa computar a seqüência $X_{m,n}$ de maneira recursiva.

2.7.5 Equações de Yule-Walker Bidimensionais Utilizando Região de Suporte de Quarto de Plano

De forma semelhante as suas correspondentes unidimensionais, a solução das Equações de Yule-Walker Bidimensionais permite a estimativa de parâmetros Autorregressivos Bidimensionais (AR2D).

Embora a solução possa ser teoricamente obtida através da utilização de regiões de suporte NSHP ou QP, indiferentemente, o método utilizando a região QP tem recebido mais atenção na literatura (Marple, 1987), tendo em vista o grande relacionamento entre os processos AR2D e processos AR unidimensionais de natureza multicanal, ao ser utilizado a região de suporte QP. Tal abordagem provê uma maneira de se obter uma versão bidimensional aproximada do Algoritmo de Levinson-Durbin, baseado na versão multicanal do mesmo algoritmo, permitindo, através de um conjunto de equações lineares, a solução das Equações de Yule-Walker bidimensionais para a matriz de parâmetros AR2D.

Ainda que o estudo e a utilização das Equações de Yule-Walker Bidimensionais utilizando a região de suporte QP não esteja sendo considerado, um método aproximado desenvolvido por Dutra (1990), utilizando TNSHP, será utilizado para a obtenção da matriz de parâmetros AR2D, conforme será apresentado na Seção 3.2.1.

CAPÍTULO 3

MATERIAIS E MÉTODOS EMPREGADOS

Este capítulo dedicar-se-á à descrição das metodologias utilizadas para a realização deste trabalho. Na Seção 3.1 será discutido o problema das distribuições adequadas para os dados de radar e sua relação com as hipóteses da modelagem ARMA. A Seção 3.2 descreve os métodos utilizados para a estimativas dos coeficientes dos filtros, bem com a Seção 3.3 discorre sobre a determinação preliminar de coeficientes AR Bidimensionais. A Seção 3.4 descreve o método utilizado para a síntese de texturas e a Seção 3.5, por sua vez, faz uma breve explanação sobre os softwares e equipamentos de apoio utilizados.

3.1 ADEQUAÇÃO DAS IMAGENS SAR A MODELOS ESTATÍSTICOS GAUSSIANOS UTILIZANDO CURVA DE RAIZ CÚBICA

Tendo em vista as condições de estacionariedade estrita para a série temporal a ser analisada, e devido à natureza inerentemente gaussiana do ruído branco motor dos modelos ARMA, é desejável que o histograma das amostras possua a distribuição mais próxima possível à normal, principalmente no que tange à síntese de texturas, conforme a Figura 2.1, já que um ruído branco gaussiano de média zero e variância σ^2 é inserido na entrada do filtro modelo estimado para gerar a imagem de textura sintética.

A característica não gaussiana das imagens SAR traz consigo a possibilidade de comportamento não desejado na modelagem dos parâmetros das séries temporais ARMA, tendo em vista a distribuição não normal dos dados.

Dessa forma, para avaliar o comportamento das imagens SAR, decidiu-se submeter os dados brutos da imagem original por uma curva raiz cúbica ($y = \sqrt[3]{x}$) com o objetivo de simetrizar o histograma dos dados de radar e tornar a sua distribuição mais parecida

com a distribuição gaussiana¹. Esta técnica é realizada “ad-hoc” e os resultados a serem obtidos são experimentais. A partir dos novos dados gerados, toda a modelagem estatística é efetuada, até a realização da síntese de textura e, após, uma curva $y = x^3$ (que é o inverso da curva raiz cúbica) é aplicada aos dados da imagem sintética a fim de buscar restaurar as características da imagem original (Figura 3.1).

Paralelamente a este processo, a modelagem dos parâmetros e a síntese também são realizados sobre os dados brutos (sem o reescalonamento), com o intuito de comparar e avaliar os resultados obtidos com relação aos efeitos da natureza não gaussiana das imagens SAR.



Fig. 3.1- Modelo sugerido para imagens de radar com baixo número de looks(M) (NL ≤ 4).

A metodologia empregada para avaliar a qualidade do ajuste dos modelos será explicada na Seção 3.4.4.

A Figura 3.2 representa uma imagem SAR da floresta equatorial na região do rio Tapajós, obtida pelo satélite JERS-1. A Figura 3.3 representa os histogramas da imagem original e da imagem resultante após o ajuste de contraste proporcionado pela curva cúbica. Estas figuras são apenas exemplos. Os resultados obtidos serão descritos detalhadamente no Capítulo 4.

A fim de verificar o ajuste dos histogramas das imagens reescaladas pela técnica experimental de transformação pela curva raiz cúbica, em relação à distribuição normal, foi empregado o teste de Kolmogorov-Smirnov (D'Agostino e Stephens, 1986; Boes,

¹ Este resultado faz parte de um estudo em andamento pelo Prof. Dr. Luciano Dutra (INPE-DPI)

Graybill e Mood, 1974; Mosier, 1998). Este é um teste de ajuste (*goodness-of-fit*) que verifica a conformidade da distribuição empírica dos dados observados com relação a uma distribuição teórica (neste caso, a distribuição normal), calculando a distância vertical máxima entre a distribuição empírica e a distribuição hipotética, testando a hipótese nula.

Para se aplicar o teste de Kolmogorov-Smirnov, deve-se calcular a frequência acumulada das observações e a frequência acumulada da distribuição normal, encontrando a maior discrepância entre as frequências, a qual é chamada de estatística D (*D-Statistic*). Deve-se então comparar a estatística D com os valores críticos constantes na Tabela 3.1 para o tamanho da amostra em questão e, se o valor da estatística D é maior que o valor crítico para o nível de significância escolhido, deve-se rejeitar a hipótese nula de que os dados possuem a distribuição esperada.

TABELA 3.1 - VALORES CRÍTICOS PARA A ESTATÍSTICA “D” DE KOLMOGOROV-SMIRNOV.

Níveis de Significância $\alpha =$	0,1	0,05	0,01
<i>n</i>			
1	0,900	0,975	0,995
2	0,684	0,842	0,929
3	0,565	0,708	0,829
4	0,493	0,624	0,734
5	0,447	0,563	0,669
6	0,410	0,519	0,617
7	0,381	0,483	0,576
8	0,358	0,454	0,542
9	0,339	0,430	0,513
10	0,323	0,409	0,489
11	0,308	0,391	0,468
12	0,296	0,375	0,449
13	0,285	0,361	0,432
14	0,275	0,349	0,418
15	0,266	0,338	0,404
20	0,232	0,294	0,352
30	0,190	0,242	0,290
40	0,165	0,210	0,252
Acima de 40	$\frac{1,07}{\sqrt{n}}$	$\frac{1,36}{\sqrt{n}}$	$\frac{1,63}{\sqrt{n}}$

FONTE: Mosier (1998).

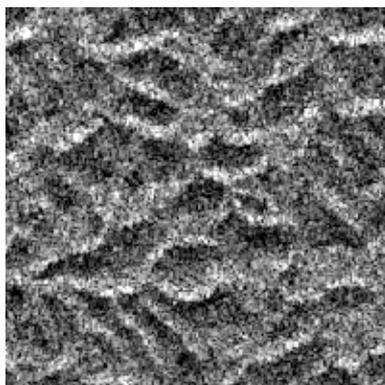


Fig. 3.2 - Imagem SAR da Floresta Nacional do Tapajós (floresta tropical densa de terreno ondulado).

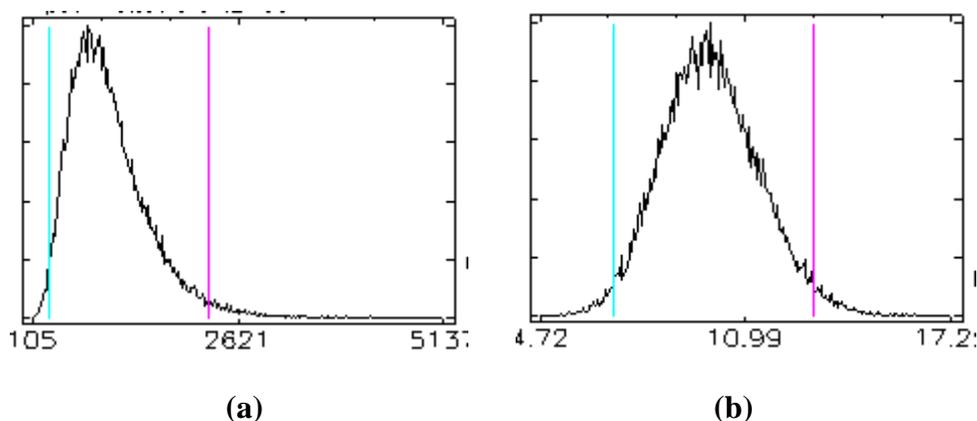


Fig. 3.3 - Histogramas da imagem SAR da região do Rio Tapajós. (a) original; (b) resultante da curva cúbica.

3.2 ESTIMATIVA DOS COEFICIENTES PARA A MODELAGEM DE FILTROS

A estimativa de parâmetros para modelos ARMA2D não é nada trivial. Neste trabalho, utilizou-se dois métodos de estimativa inicial de parâmetros, ambos baseados em modelos puramente autorregressivos, os quais supõem o conceito de computabilidade recursiva, com o intuito de garantir a causalidade, estabilidade e linearidade do filtro a ser gerado. Neste trabalho, utilizar-se-á exclusivamente a modelagem AR devido a natureza não linear do método de estimação de parâmetros MA, o que dificulta a implementação, assim como aumenta consideravelmente o custo computacional (Marple, 1987). Outro motivo é que o processo de filtragem inversa MA é

autorregressivo, de implementação mais complicada, devido à condição de estabilidade (Sessão 3.2.1.4).

O resultado de ambas as abordagens, entretanto, depende da solução das equações de Yule-Walker e da eficiente estimativa de parâmetros, o que permite uma satisfatória abordagem das funções de autocorrelação estimadas para a posterior escolha dos filtros a serem produzidos pela fase inicial de análise e estimação.

Na Seção 2.7.5 discorreu-se sobre o método de cálculo utilizando-se a região de suporte QP. Tratar-se-á, agora, das estimativas utilizando a região de suporte NSHP.

3.2.1 Primeiro Método: Concatenação dos Dados da Imagem e Utilização da Função de Autocorrelação Linear

O primeiro método é o método de concatenação proposto por Dutra (1990) e por Dutra e Sant'Ana (1995), a fim de gerar, concatenando linhas e colunas da imagem que possui a textura a ser analisada, um modelo AR unidimensional, de natureza causal. A partir das funções de autocorrelação e autocorrelação parcial da série concatenada, estimar-se-á os parâmetros iniciais e a ordem do modelo ARMA (ou simplesmente AR), posteriormente utilizando um algoritmo para transformar as coordenadas unidimensionais em bidimensionais. Tomando-se por M o tamanho do segmento de reta horizontal (M ímpar) a ser concatenado e k o número de segmentos de reta concatenados, tem-se a geração de uma seqüência linear $N = Mk$ tal qual o mostrado na Figura 3.4.

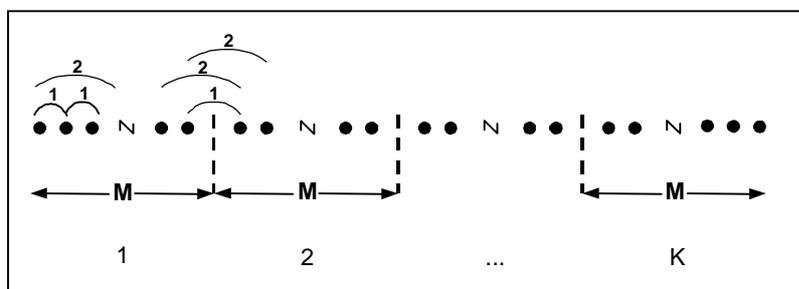
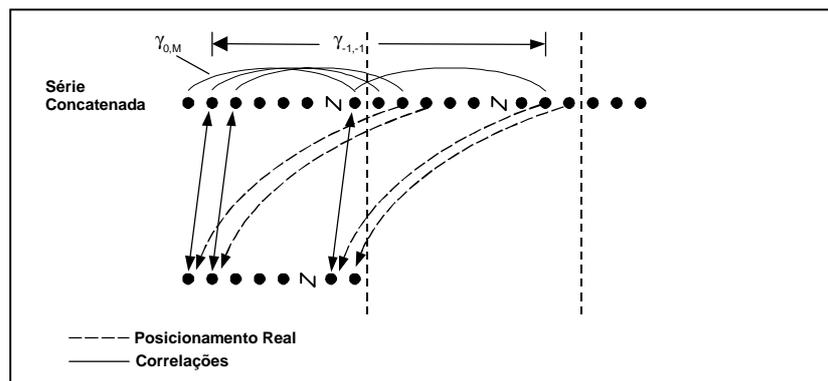


Fig. 3.4 - Transformação de uma série bidimensional em uma série unidimensional. FONTE: Dutra, 1990.

Para o cálculo da ACF em atrasos de 0 a $M/2$, tem-se na composição da somatória as correlações correspondentes ao lado direito do ponto de referência e um número limitado de fatores correspondentes a pontos cujas correlações cruzem as fronteiras entre os segmentos, ou seja, pontos da linha superior e pontos situados na região esquerda da linha inferior. Para $M/2 + 1$ a $3M/2$ (e pontos de mesma distância) tem-se os valores correspondentes às linhas sobrepostas, sendo que de $M/2 + 1$ a M tem-se maior número de fatores correspondentes às correlações relacionadas a direita das linhas superiores e inferiores, enquanto de M a $3M/2$ tem-se fatores que correspondem à esquerda destas linhas. Para correlações múltiplas de M , tem-se os fatores correspondentes às correlações bidimensionais de pontos na vertical (Dutra, 1990).

A Figura 3.5 mostra a relação entre as correlações da série concatenada e as correlações para a série bidimensional no caso do atraso $M-1$.



**Fig. 3.5 - Relação entre correlações concatenadas sobre uma série concatenada e o posicionamento no plano dos pontos, para atraso $M-1$.
FONTE: Dutra, 1990.**

Para M com valores elevados, Dutra (1990) concluiu que o cálculo da ACF sobre a série concatenada gera aproximadamente as correlações bidimensionais sobre uma região de suporte de maior plano não simétrico (NSHP), conforme o algoritmo (Dutra, 1990):

Algoritmo 3-1 - Transformação de Coordenadas Unidimensionais em Bidimensionais

Transforma-se o índice i_c , coeficiente da série concatenada para o índice (i,j) bidimensional da seguinte forma:

Tomando-se:

$$i_c = 0,1,2,3,\dots \text{ e}$$

$$t = \frac{i_c}{2} \text{ (divisão inteira)}$$

Se:

$$(t-1)M + \frac{M}{2} < i_c < tM \Leftrightarrow (i, j) = (-(M - i_c \text{Mod} M), -t), \text{ à esquerda}; \quad (3-1)$$

$$tM \leq i_c \leq tM + \frac{M}{2} \Leftrightarrow (i, j) = (i_c \text{Mod} M, -t), \text{ à direita.} \quad (3-2)$$

A literatura possui vários métodos para a estimativa unidimensional de parâmetros AR, dos quais pode-se enumerar alguns (Melsa e Cohn, 1978):

- Mínimos quadrados (“least squares” – LS);
- Máxima verossimilhança (“maximum likelihood” – ML);
- Máximo a posteriori (MAP).

A diferença entre estes reside na disponibilidade de conhecimento estatístico a respeito do parâmetro. Os métodos ML e MAP não serão utilizados neste trabalho. O método LS obtém a estimação dos parâmetros através da substituição, nas equações de Yule-Walker (YW), das correlações teóricas pelas estimadas (Kay, 1988). Neste trabalho, utilizou-se, tão somente como forma de verificação, a rotina “built-in” (pré-existente) de estimação de coeficientes AR existente no software IDL, a qual baseia-se no método descrito por Chatfield (1989).

A partir da escolha do método para a geração do modelo AR e seus coeficientes, tem-se a seguinte seqüência de procedimentos:

- a) obtenção dos dados a partir da área escolhida para treinamento, definindo regiões de estudo e concatenando segmentos de linhas ou colunas, conforme o descrito nesta Seção;
- b) remoção do valor médio dos dados e calcular a função de autocorrelação (ACF) e autocorrelação parcial (PACF), obtendo os *lags* em que as funções caem nos respectivos intervalos de confiança para a estimativa dos valores iniciais máximos de p , conforme será descrito na Seção 3.2.1.1;
- c) redução sistemática de p , seguindo o princípio da parcimônia, o qual considera que o melhor modelo é sempre o mais simples, e o método definido na Seção 3.2.1.2 (modelos menores também resultam em filtros menores, os quais têm melhor performance cruzando os limites entre as regiões de textura);
- d) obtenção das estimativas do modelo utilizando o algoritmo de Levinson, eliminando modelos que resultam em não causais ou não inversíveis, conforme o anteriormente descrito na Seção 2.6.7;
- e) usando intervalos de confiança para os coeficientes, eliminação daqueles que não são significativos, e que não serão mais considerados, conforme o descrito na Seção 3.2.1.3;
- f) filtragem inversa dos dados pelo filtro inverso obtido do modelo para a verificação do branqueamento do resíduo, ou seja, se este último corresponde a um campo ruído branco, verificando-se sua função de autocorrelação, tal qual é explicado na Seção 3.2.1.4.

3.2.1.1 Limites do Intervalo para a Consideração de Valores Nulos nas Funções de Autocorrelação e Autocorrelação Parcial

Embora a ACF a PACF não se anulem, para um modelo ARMA completo, sabe-se que a ACF se anula a partir do *lag* (atraso) q , em um modelo puramente MA, e que a PACF se anula a partir do atraso p , para um processo AR (Tou et al, 1976, e Dutra, 1990), o

que torna possível, ao se observar a ACF e a PACF, abstrair-se o modelo subjacente a um dado processo.

Dada a variância dos estimadores da ACF e da PACF, entretanto, torna-se necessário estabelecer um critério para a definição de valores não nulos para as estimativas. Segundo Dutra (1990), citando Granger e Newbold (1977), tem-se que tais estimadores são aproximadamente gaussianos para todos os *lags*, na ACF e PACF, quando o sinal gerador é um ruído branco, com variância n^{-1} (para n amostras), o que permite o uso do limite $\pm 1,96n^{-1/2}$, o qual é equivalente ao dobro do desvio padrão da distribuição do estimador, como uma indicação aproximada dos valores da função para que sejam considerados não nulos a 95% de confiança. A análise da ACF e PACF, com relação aos limites do intervalo $\left[-1,96n^{-1/2}; 1,96n^{-1/2}\right]$ também permite uma estimativa grosseira inicial para os valores p e q do modelo ARMA, considerando os valores para os quais as funções caem dentro do intervalo de confiança para a hipótese nula.

3.2.1.2 Seleção da Ordem dos Modelos

A melhor escolha da ordem p para os modelos AR não é antecipadamente conhecida, de modo que é necessário desenvolver critérios de erro a fim de escolher dentre as ordens possíveis a ideal. A escolha de uma ordem muito baixa resulta em uma estimativa espectral excessivamente suavizada, enquanto a escolha de ordens excessivamente elevadas aumenta a resolução e introduz detalhes espúrios no espectro.

Kay (1988) sugere que uma abordagem intuitiva seria construir modelos AR de ordem crescente até a variância do erro de predição alcançar um valor mínimo. Todavia, os algoritmos de estimação correntes possuem variâncias de erro de predição as quais decrescem monotonamente com o aumento da ordem p , o que indica ser esta abordagem inadequada.

Diversos critérios utilizando funções objetivas para a seleção da ordem de modelos AR foram, então, desenvolvidos, sempre penalizando, outrossim, o aumento da ordem do

modelo. Alguns destes critérios são implementados neste trabalho, sendo descritos a seguir. Tais critérios são considerados como indicadores adicionais para a validação da abordagem natural empregada, descrita no final desta Seção.

- **“Final Prediction Error” (FPE)**

Critério proposto por Akaike (1969) que seleciona a ordem do processo AR de maneira a minimizar a variância do erro médio para a predição. A variância do erro é considerada como a soma da potência da parte não predizível do processo com a representação das incorreções da estimativa AR, ou seja:

$$FPE(p) = \hat{\rho}_p \left(\frac{N + (p + 1)}{N - (p - 1)} \right), \quad (3-3)$$

onde N é o número de amostras, p é a ordem e $\hat{\rho}_p$ é a variância estimada do ruído branco (2-46), sendo a variância do erro de predição linear utilizada para esta estimativa. (3-3) supõe que a média foi subtraída dos dados. A ordem p é selecionada para o valor mínimo de FPE . Embora funcione perfeitamente para processos AR puros, FPE aparenta ser conservativa quando submetida a sinais reais, normalmente selecionando uma ordem muito baixa (Jones, 1976).

- **“Akaike Information Criterion” (AIC)**

Outro critério de seleção sugerido por Akaike (1974), este critério utiliza a abordagem de máxima verossimilhança, sendo conhecido como Akaike Information Criterion (AIC). AIC determina a ordem p do modelo minimizando uma função teórica informativa. Supondo um processo gaussiano, a função tem a forma:

$$AIC(p) = N \ln(\hat{\rho}_p) + 2p. \quad (3-4)$$

O termo $2p$ representa uma penalidade por utilizar coeficientes AR extras os quais não resultam na redução da variância do erro de predição. Para $N \rightarrow \infty$, AIC e FPE são assintoticamente equivalentes, e tem-se observado (Kashyap, 1980) o mesmo comportamento para sinais reais, já que a possibilidade de

erro na escolha da ordem correta não tende a zero à medida que N aumenta. A tendência, então, é de subestimar a ordem dos dados à medida que aumenta número de amostras.

- “*Minimum Description Length*” (*MDL*)

Crítério desenvolvido por Rissanem (1983), como uma variante da função teórica informativa AIC, em resposta às limitações apresentadas, com a forma:

$$MDL(p) = N \ln(\hat{\rho}_p) + p \ln(N), \quad (3-5)$$

onde *MDL* representa Minimum Description Length. Este método é considerado estatisticamente consistente porque $p \ln(N)$ aumenta mais rápido com relação à N do que com p .

“*Criterion Autoregressive Transfer*” (*CAT*)

Outro critério, proposto por Parzen (1974), conhecido por Criterion Autoregressive Transfer (*CAT*). A ordem p , neste critério, é selecionada entre a minimização da estimativa da diferença entre os erros médios quadráticos do filtro real de predição linear (o qual pode ser de comprimento infinito) e o filtro estimado. A função é dada por:

$$CAT(p) = \left(\frac{1}{N} \sum_{j=1}^p \bar{\rho}_j^{-1} \right) - \bar{\rho}_p^{-1}, \quad (3-6)$$

onde $\bar{\rho}_j = \left[\frac{N}{(N-j)} \right] \hat{\rho}_j$.

Uma maneira natural, utilizada neste trabalho, para a escolha da ordem máxima para o modelo, entretanto, é observar o último valor do atraso (*lag*) para o qual a PACF se anula, ou seja, cai dentro do intervalo de confiança, e tomar este valor como a ordem p máxima para o modelo AR.

3.2.1.3 Estimação Preliminar de Valores dos Coeficientes Autorregressivos e Definição de Intervalos de Confiança

Embora a utilização do algoritmo de Levinson para a estimativa dos parâmetros de um modelo autorregressivo solucionando as Equações de Yule-Walker já tenha sido discutida na Seção 2.6.7, sabe-se que a determinação de um modelo $AR(p)$ apropriado para representar uma série temporal estacionária envolve uma série de problemas interrelacionados, o que inclui a seleção da ordem p e a estimação dos parâmetros remanescentes, ou seja, a média, os coeficientes $\{\phi_i | i = 1, \dots, p\}$ e a variância do ruído branco σ^2 . Assim sendo, esta Seção aprofunda a discussão a respeito das Equações de Yule-Walker e a sua solução pela recursividade de Levinson-Durbin, no que tange à estimação dos coeficientes autorregressivos.

Tomando-se as Equações de Yule-Walker, $\Gamma_p \phi = \gamma_p$ e $\sigma^2 = \gamma_0 - \phi' \gamma_p$, obtém-se $\hat{\phi} = \hat{R}_p^{-1} \hat{\rho}_p$, onde \hat{R}_p é a matriz de autocorrelações estimadas.

Se $\{X_t\}$ é um processo $AR(p)$ causal cujo ruído branco motor é $\{Z_t\} \sim \text{IID}(0, \sigma^2)$ (independente e identicamente distribuído de média zero e variância σ^2) e o vetor de coeficientes $\hat{\phi}$ é o estimador de Yule-Walker de ϕ , então $n^{1/2}(\hat{\phi} - \phi) \Rightarrow N(0, \sigma^2 \Gamma_p^{-1})$, ou seja, $n^{1/2}(\hat{\phi} - \phi)$ tem uma distribuição normal de média zero e variância $\sigma^2 \Gamma_p^{-1}$, onde Γ_p é a matriz de covariâncias $\Gamma_p = [\gamma_{i-j}]_{i,j=1}^p$ (Brockwell e Davis, 1987).

A distribuição normal permite a especificação de regiões de confiança para ϕ ao se utilizar amostras grandes (n grande). Se a ordem real de um processo AR é p e se tenta ajustar um processo de ordem m , espera-se que o vetor de coeficientes $\hat{\phi}_m = (\hat{\phi}_{m1}, \dots, \hat{\phi}_{mm})'$ tenha valores pequenos de $\hat{\phi}_{mm}$ para cada $m > p$. Embora a distribuição exata de $\hat{\phi}_{mm}$ não seja conhecida mesmo para o caso gaussiano, consegue-se um resultado assintótico $n^{1/2} \hat{\phi}_{mm} \Rightarrow N(0,1)$ para $m > p$ e $\hat{\phi}_m = \hat{R}_m^{-1} \hat{\rho}_m$ que permite a identificação apropriada da ordem do processo a ser ajustado.

A consequência imediata é a possibilidade de aplicação do algoritmo de Levinson-Durbin para ajustar modelos AR sucessivamente aumentando a sua ordem a partir dos dados. Os vetores de coeficientes estimados $\hat{\phi}_m$ e variâncias estimadas do ruído branco \hat{v}_m são computadas recursivamente a partir das covariâncias amostrais.

O uso da recursividade de Levinson evita a inversão de matriz requerida inicialmente para o cálculo do vetor de coeficientes $\hat{\phi}_m$ (2.44) e do vetor de variâncias \hat{v}_m (2.46), além de prover as estimativas $\hat{\phi}_{11}, \hat{\phi}_{22}, \dots$, da PACF para atrasos 1, 2, ..., estimativas valiosas para a determinação da natureza autorregressiva do modelo, bem como de sua ordem aproximada, levando-se em conta, novamente, que, para um processo AR(p), as autocorrelações parciais $\alpha(m) = \hat{\phi}_{mm}$, $m > p$, são zero (Dutra, 1990; Brockwell e Davis, 1987), assim como para um processo AR(p) o estimador $\hat{\phi}_{mm}$ (ou seja, a PACF) é normalmente distribuído com média zero e variância n^{-1} , para valores grandes de n (Brockwell e Davis, 1987).

Dessa forma, se um modelo autorregressivo for apropriado aos dados existirá um *lag* finito através do qual os valores observados de $\hat{\phi}_{mm}$ sejam compatíveis com a distribuição $N(0, 1/n)$, ou seja, chega-se às conclusões definidas na Seção 3.2.1.1 que sugere se tomar por um estimador preliminar de p o menor valor de r tal que r seja o *lag* antecedente a m que atenda a $|\hat{\phi}_{mm}| < 1,96n^{-1/2}$ para $m < r$.

Seguindo raciocínio similar, no que tange à assunção da distribuição normal, Granger e Newbold (1977) e Brockwell e Davis (1987) citam que, no estágio final da recursividade, pode-se supor que o intervalo de confiança no nível de 95% para ϕ_m pode ser dado por $\hat{\phi}_m \pm 1.96v_{jj}^{1/2}$ onde v_{jj} é o elemento diagonal de ordem j de $n^{-1}\hat{v}_m\hat{\Gamma}_m^{-1}$, onde \hat{v}_m é dado por (2.46), n é o número de amostras e $\hat{\Gamma}_m$ é a matriz de covariâncias estimadas:

$$\hat{\Gamma}_m = \begin{bmatrix} \hat{\gamma}_0 & \hat{\gamma}_1 & \hat{\gamma}_2 & \cdots & \hat{\gamma}_{m-1} \\ \hat{\gamma}_1 & \hat{\gamma}_0 & \hat{\gamma}_1 & \cdots & \hat{\gamma}_{m-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \hat{\gamma}_{m-1} & \hat{\gamma}_{m-2} & \hat{\gamma}_{m-3} & \cdots & \hat{\gamma}_0 \end{bmatrix}. \quad (3-7)$$

Desta forma, pode-se calcular a razão entre os coeficientes estimados $\hat{\phi}_m$ e seu respectivo intervalo de confiança dado por $1.96v_{ij}^{1/2}$ (conforme o descrito na Seção 3.2.1.1), de modo a considerar os coeficientes nulos se estes estiverem dentro do intervalo de confiança (Dutra, 1990), se o valor absoluto do limite for maior que o valor

absoluto do coeficiente estimado, ou seja, $\hat{\phi}_m = 0$ se $\left| \frac{\hat{\phi}_m}{1.96v_{ij}^{1/2}} \right| < 1$.

3.2.1.4 Diagnóstico Sobre os Resíduos Gerados pela Filtragem Inversa

Tendo em vista a necessidade de verificação da adequação do modelo aos dados, procede-se o diagnóstico (Dutra, 1990) sobre os resíduos gerados. Entende-se por resíduos os valores obtidos a partir de um processo de modelagem ARMA(p,q) tal que $\phi(B)X_t = \theta(B)Z_t$, ajustado à observações $\underline{X}_n = [X_1, \dots, X_n]$ e estimativas $\hat{\phi}$ e $\hat{\theta}$, onde a quantidade \hat{Z}_t , conhecida por *resíduo*, é dada por:

$$\hat{Z}_t = \hat{\theta}^{-1}(B)\hat{\phi}(B)X_t. \quad (3-8)$$

Se a modelagem estiver adequada, os resíduos calculados devem ser não correlacionados, ou seja, os resíduos constituirão um processo ruído branco cujas correlações para atrasos (*lags*) maiores que zero devem ser aproximadamente nulas.

Tendo em vista que os coeficientes para a equação (3-7) são estimados, tem-se que a distribuição das correlações amostrais de $\hat{Z}_t(\hat{\phi}, \hat{\theta})$ é diferente de $\hat{Z}_t(\phi, \theta)$, e que a

seqüência \hat{Z}_t , não é independente e identicamente distribuída (Brockwell e Davis, 1987), o que seria característica do ruído branco motor original.

As correlações amostrais dos resíduos, entretanto, são capazes de fornecer informações pertinentes a respeito da adequabilidade do modelo, considerando-se que os intervalos de confiança de limites $\pm 1,96n^{-1/2}$ ainda são válidos para a consideração de valores nulos na função de autocorrelação da seqüência \hat{Z}_t (Dutra, 1990). Caso existam correlações significativas, ou seja, com valores excentes aos limites, pode-se considerar o modelo inadequado e modificá-lo.

A Figura 3.6 ilustra, a título de exemplo, a autocorrelação dos resíduos de uma modelagem AR para a imagem da Figura 3.2.

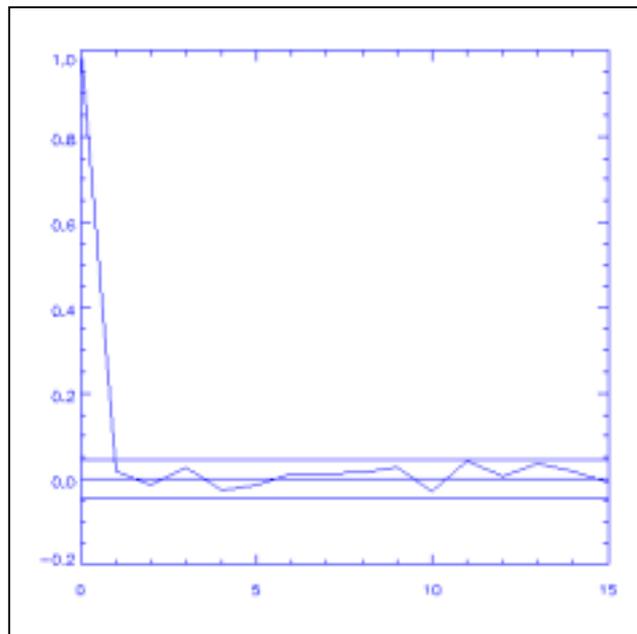


Fig. 3.6 - Autocorrelação de resíduos obtidos a partir da imagem da Figura 3.2.

A operação de cálculo dos resíduos também é chamada de filtragem inversa, já que a filtragem direta é considerada no sentido da configuração teórica do modelo, se o processo for observado no campo de processamento de sinais. Outro fator interessante neste campo de estudo é que, tendo em vista as características das equações diferença dos modelos AR e MA, tem-se que o filtro inverso de um filtro AR é um filtro MA, e

vice-versa, tendo os coeficientes, tão somente, seu sinal invertido, já que, dado um filtro AR(p):

$$X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + Z_t \quad (3-9)$$

pode-se realizar a inversão para:

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + X_t,$$

obtendo-se:

$$X_t = Z_t - \phi_1 Z_{t-1} - \dots - \phi_q Z_{t-p}$$

fazendo-se os ajustes, trocando, a fim de manter a notação,

$-\phi_k \Leftrightarrow \theta_k$ ($k = 1, 2, \dots, p$) e $p \Leftrightarrow q$, tem-se:

$$X_t = Z_t + \theta_1 Z_{t-1} + \dots + \theta_q Z_{t-q} \quad (3-10)$$

obtendo-se um modelo MA(q) cujo vetor de coeficientes θ relaciona-se com o vetor de coeficientes ϕ do modelo AR original de maneira tal que $\theta = -\phi$. O processo é coerente de maneira que, a partir de um filtro MA, pode-se obter um filtro AR pela filtragem inversa. Como já foi citado na Seção 3.2, este trabalho limitou-se à modelagem AR, e, assim, utiliza-se o filtro MA inverso sempre estável, portanto.

3.2.2 Segundo Método: Concatenação da Função de Autocorrelação Bidimensional

O outro método utilizado, paralelamente ao anterior, utiliza uma função de autocorrelação bidimensional (ACF2D). O resultado da ACF2D é então concatenado em termos de intervalos (*lags*) horizontais e verticais, produzindo uma seqüência linear, segundo o esquema de linearização por varredura do meio plano não simétrico, conforme a Figura 3.7. O objetivo desta operação é evitar a acumulação de erros nos valores de correlações indesejadas geradas pela concatenação simples das linhas e

colunas da imagem gerando uma seqüência linear dos dados. Tais erros acumulam-se o quão mais os atrasos afastam-se de 0, M , $2M$, ... em direção a $\frac{(2n+1)M}{2}$. Para atrasos $\frac{(2n+1)M}{2}+1$, os fatores acumulados preponderam para atrasos bidimensionais de uma linha abaixo (Dutra, 1990).

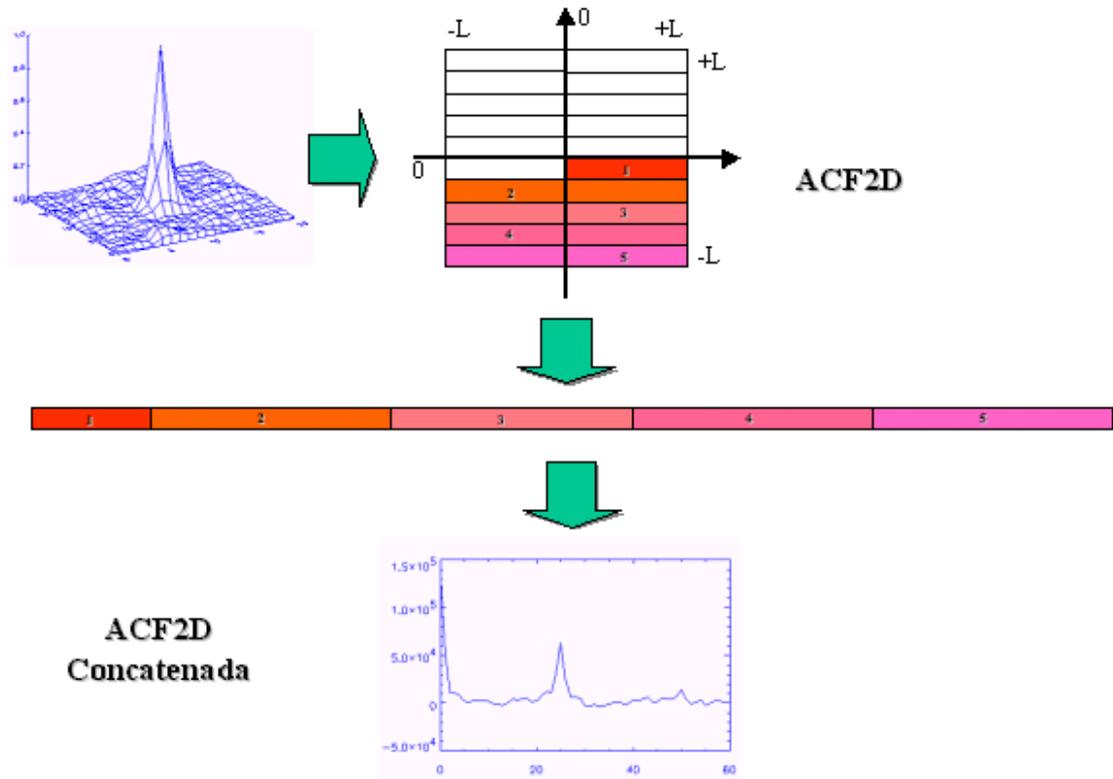


Fig. 3.7 - Processo de obtenção da meia ACF2D linearizada (concatenação).

Note-se, porém, que as correlações mais próximas aos pontos de referência são as que acumulam menos fatores errôneos, de maneira que a concatenação simples das linhas e colunas para a obtenção da ACF (método anterior) não é um método inconsistente. O uso da ACF2D concatenada, no entanto, será uma melhoria para o método em questão, já que é uma forma de evitar a acumulação de erros, mesmo nos pontos mais distantes.

O processo de estimativa dos parâmetros é semelhante ao anterior, exceto pela utilização da ACF2D concatenada para as estimativas necessárias ao método LS. A

concatenação da ACF2D é realizada da mesma forma que a concatenação dos dados apresentada anteriormente (Seção 3.2.1 e Figura 3.4). A Figura 3.8 representa o gráfico da seqüência de autocorrelação 2D da imagem representada na Figura 3.2.

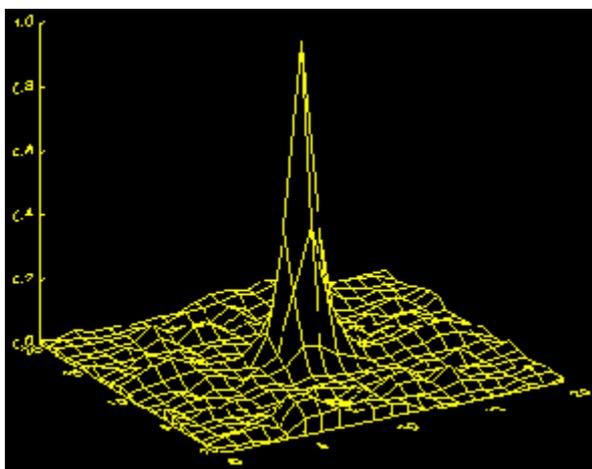


Fig. 3.8 - ACF 2D estimada da imagem SAR da área do rio Tapajós (Figura 3.2).

Para a seleção da ordem do modelo, também são utilizados os critérios descritos na Seção 3.2.1.2. Também será realizado o mesmo processo de normalização das imagens SAR, descrito na Seção 3.1.

3.3 DETERMINAÇÃO PRELIMINAR DE COEFICIENTES PARA MODELOS AR BIDIMENSIONAIS

Após a fase inicial de análise e estimação de parâmetros, a qual pode utilizar quaisquer dos métodos baseados na função de autocorrelação descritos anteriormente para a estimação de parâmetros AR, pode-se buscar o mapeamento dos coeficientes AR na seqüência unidimensional para o posicionamento no plano AR2D.

Assim como a ACF unidimensional concatenada é equivalente à ACF2D nos intervalos menores e próximos à origem (0,0), pode-se supor que é possível ajustar um modelo AR(p), com $p > M$, ao plano, com a mesma correspondência entre índices e posições no plano descrita na Seção 3.2.1, utilizando suporte NSHP.

Dutra (1990) prova que, utilizando o método da concatenação, as equações de Yule-Walker unidimensionais podem ser mapeadas no plano, gerando todos os coeficientes correspondentes às equações de Yule-Walker bidimensionais até os limites $M/2$ nos limites da linha concatenada. Adicionalmente, tendo em vista que os coeficientes 2D não existem fora dos limites da região de suporte $S_x(i,j,k)$, considera-se que os coeficientes gerados pela concatenação fora dos limites do NSHP são iguais a zero, de maneira que os resultados das equações de Yule-Walker são correspondentes em suas versões unidimensional (concatenada) e bidimensional, gerando estimativas correspondentes.

Uma observação interessante, com relação ao fato dos coeficientes autorregressivos serem nulos fora do suporte NSHP é que, na identificação do modelo 2D a partir do ajuste de um modelo AR unidimensional de ordem convenientemente escolhida, ao se considerarem nulos os coeficientes localizados no intervalo de confiança, tal qual o descrito na Seção 3.2.1.3, tem-se a definição automática da região de suporte. Este mapeamento é feito de forma similar ao apresentado na Figura 3.7, só que no sentido inverso.

3.4 SÍNTESE DE TEXTURAS

Pode-se entender por síntese de textura, em termos práticos, como o uso de um algoritmo para a geração de uma matriz bidimensional de dados pictóricos que correspondem a uma textura de mesma natureza. Se o modelo adotado para a realização da síntese for adequado, o processo de síntese deve ser capaz de gerar novas texturas que devem reconstituir as características das texturas originais.

As texturas fonte utilizadas, sobre as quais busca-se, inicialmente, estimar os filtros para a síntese, com o uso do processo analítico anterior, foram imagens SAR (Figura 3.9) e óticas (Figura 3.10) obtidas a partir de sensoriamento remoto e também texturas naturais digitalizadas, semelhantes às do álbum de Brodatz (1966), contidas na Figura 3.11. Como os métodos de estimativa provavelmente gerarão filtros diferentes, diferentes sínteses para cada tipo de textura são realizadas e comparadas.

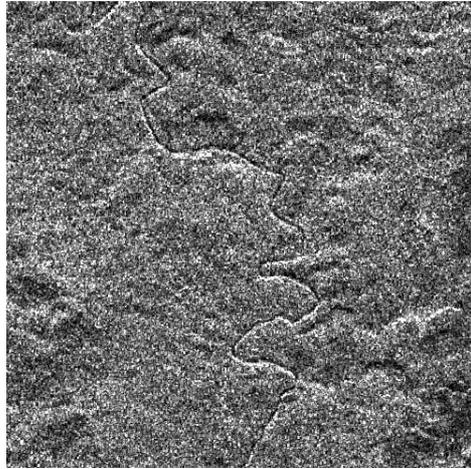


Fig. 3.9- Imagem SAR da área do rio Tapajós obtida pelo satélite JERS-1.

Tou et al (1976) mostram que, embora a abordagem ligada a séries temporais para síntese de texturas naturais possa utilizar modelos de estimação baseados nos valores dos *pixels* vizinhos superior e esquerdo, analogamente à previsão de valores futuros a partir dos passados em seqüências temporais, a aplicação desta técnica não é ideal, já que os dados texturais tendem a se tornar determinísticos a partir de um certo número de passos. A síntese com a utilização de um gerador de ruído branco é preferível, a fim de manter a natureza aleatória das texturas de aparência natural.

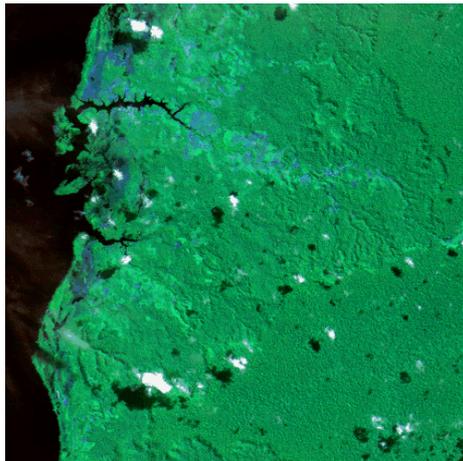


Fig. 3.10 - Imagem ótica obtida pelo satélite Landsat-5 (área do Tapajós).

A idéia é gerar uma matriz de ruído aleatório de média zero e mesma variância que os resíduos $\hat{Z}_{m,n}$ obtidos a partir da modelagem estatística, e aplicar como entrada do modelo obtido. A nova matriz gerada provavelmente não será a duplicação exata da textura original, mas deverá possuir as mesmas propriedades estatísticas, já que a textura original e a sintética nada mais são do que realizações amostrais de um *ensemble* de texturas que caracterizam o modelo estatístico.

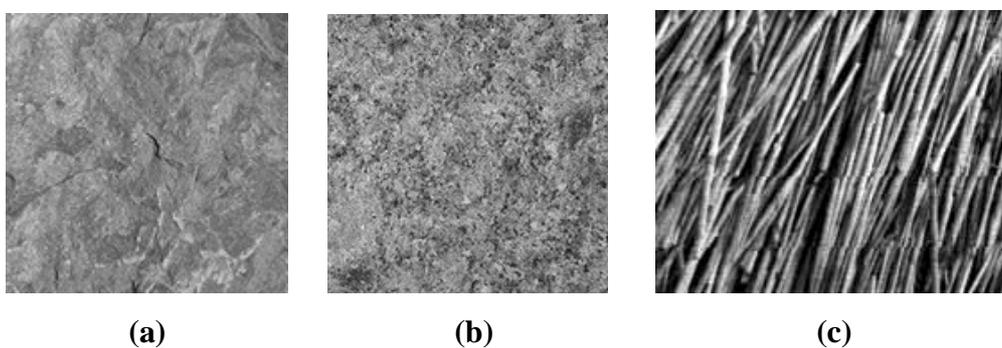


Fig. 3.11 - Texturas naturais granito (a), mármore (b) e junco(c).

Em termos de processamento de sinais, tem-se que, a partir da estimação dos filtros, faz-se uma regeneração das texturas reais a partir dos resíduos dos métodos anteriores, utilizando os filtros inversos, e comparando-as com as fontes, a fim de verificar a acuidade do método, prioritariamente à geração de uma textura de comportamento visual de mesma natureza que a textura fonte, através de utilização de um campo aleatório branco (ruído branco bidimensional) de média zero e variância σ^2 , igual a variância dos resíduos da textura da fonte.

Resumindo, segue-se o seguinte ciclo de testes:

- análise das texturas das imagens naturais e modelagem estatística;
- filtragem inversa, a fim de obter-se os resíduos;
- utilização da filtragem direta, com os resíduos gerados, para a tentativa de regeneração das texturas das imagens naturais;

- geração de um campo aleatório branco, de mesmas características estatísticas que os resíduos obtidos a partir das imagens naturais, a fim de, pela filtragem direta, gerar imagens sintéticas;
- comparação visual das imagens obtidas sinteticamente, além da avaliação dos momentos de segunda ordem, para verificar se os resultados aproximam-se das texturas das imagens naturais.

Algumas das fases do ciclo de testes são exploradas a seguir.

3.4.1 Obtenção dos Resíduos da Imagem

Para a obtenção dos resíduos a partir da imagem original, aplica-se na mesma o filtro inverso do filtro autorregressivo bidimensional obtido pela modelagem, conforme o descrito na Seção 3.3, utilizando-se a equação:

$$\hat{Z}_{m,n} = \sum_{(i,j) \in S_p} \hat{\phi}_{i,j} \tilde{X}_{m-i,n-j} \quad (3-11)$$

No formato de filtro inverso, o modelo terá seus coeficientes com sinal invertido (Dutra, 1990), conforme cita a Seção 3.2.1.4.

Tendo em vista que este trabalho está voltado para a síntese, e não para a classificação de diferentes padrões em uma imagem, utilizando modelagem estatística de séries temporais, abstrai-se facilmente que, o quão mais homogênea, em termos de textura, for a imagem, melhor será o diagnóstico sobre os resíduos, e também a síntese utilizando ruído branco de mesmas características estatísticas.

3.4.2 Regeneração da Imagem Natural

Uma maneira simples de verificar o ajuste do modelo aos dados da imagem é, a partir dos resíduos gerados pela filtragem inversa, aplicá-los ao filtro direto estimado inicialmente, gerando, a final do ciclo, uma imagem igual, a menos de imperfeições numéricas, à imagem original e suas texturas.

A questão do ajuste é interessante porque é capaz de verificar o perfeito funcionamento do algoritmo de inversão, já que, mesmo que o filtro gerado não esteja gerando um resíduo cujas correlações amostrais não estejam dentro dos limites do intervalo de confiança, ou seja, não seja muito aproximado a um ruído branco, ao se utilizar as regiões de suporte NSHP ou QP e o algoritmo for correto, o ciclo deve se completar.

Para a regeneração, utiliza-se a equação:

$$\tilde{X}_{m,n} = - \sum_{(i,j) \in S'_p} \hat{\phi}_{i,j} \tilde{X}_{m-i,n-j} + \hat{Z}_{m,n} \quad (3-12)$$

que nada mais é do que a equação de um processo AR(i,j) bidimensional, tal qual o definido em (2-51), porém utilizando-se dos resíduos $\hat{Z}_{m,n}$ como campo branco de entrada e tendo como suporte de meio plano não simétrico $S'_p = S_p - (0,0)$, a fim de se permitir a computabilidade recursiva que caracteriza a autorregressividade.

Se o modelo estiver ajustado, deve-se obter um campo texturado idêntico ao original, conforme a Figura 3.12.



Fig. 3.12 - Verificação de Ajuste do Modelo

3.4.3 Geração de Texturas a Partir de um Campo Aleatório Branco

A partir da regeneração das texturas reais a partir dos resíduos e comparando-as com as fontes, para verificar a acuidade do método, parte-se para a geração de uma textura de comportamento visual de mesma natureza que a textura fonte, através de utilização de um campo aleatório branco de média zero e variância σ^2 , igual a variância dos resíduos da textura da fonte.

A geração da matriz bidimensional que constituirá o ruído é feita através da utilização de uma rotina de geração de números aleatórios de distribuição normal, de desvio padrão 1 e média zero, utilizando o método de Box-Müller (Park e Miller, 1988). Para a obtenção da variancia desejada σ^2 , é só multiplicar-se o desvio padrão inicial por σ desejado.

A equação para a geração do campo texturado sintético é a mesma equação (3.12), onde, porém, $\hat{Z}_{m,n}$ é substituído por $Z_{m,n}$, o qual representa um ruído branco bidimensional de mesmas propriedades estatísticas dos resíduos.

$$\tilde{X}_{m,n} = -\sum_{(i,j) \in S'_p} \hat{\phi}_{i,j} \tilde{X}_{m-i,n-j} + Z_{m,n} \quad (3-13)$$

Após esta utilização do filtro-modelo sobre o campo aleatório branco, gera-se a textura, a qual deve possuir aparência visual semelhante à imagem de origem. Adiciona-se aos pontos processados a média da região, já que $\tilde{X}_{m,n} = X_{m,n} - \mu$ (Dutra, 1990).

3.4.4 Avaliação dos Resultados

A fim de proceder a necessária avaliação dos resultados da síntese proposta, foram utilizadas, além das condições de acuidade intrínsecas aos métodos estudados, tal qual a avaliação direta de momentos de segunda ordem, formas adicionais.

Uma forma seria a comparação das PSD originais e sintetizadas, obtidas através das transformadas de Fourier das funções de autocorrelação, ou seja, dos periodogramas, porém não será utilizada neste trabalho.

Outra forma é retransformar as matrizes de parâmetros AR bidimensionais em vetores de parâmetros AR de uma dimensão, realizando o processo inverso à concatenação, e calculando as distâncias euclidianas entre os vetores da modelagem resultante da textura original (ϕ) e da textura sintetizada (α), conforme (3-14):

$$d_{\phi\alpha} = \sqrt{(\phi_1 - \alpha_1)^2 + (\phi_2 - \alpha_2)^2 + \dots + (\phi_p - \alpha_p)^2} \quad (3-14)$$

Deve-se calcular também a distância entre os vetores obtidos a partir de outras texturas sintetizadas e a textura em estudo. As distâncias entre o vetor da textura fonte e vetores obtidos de modelos sintetizados a partir desta fonte devem ser menores que as distâncias obtidas a partir de outros modelos.

A melhor avaliação, no entanto, dentro das características subjetivas inerentes à própria definição de textura, é a avaliação visual. As texturas sintéticas devem possuir efeitos visuais semelhantes às texturas fonte para o resultado ser considerado satisfatório.

3.5 SOFTWARE E EQUIPAMENTOS DE APOIO

A implementação do método é feita utilizando-se o ambiente de desenvolvimento de software científico IDL versão 5.0. O programa estatístico PEST é utilizado na fase de estimativa inicial da ordem do modelo, bem como MATLAB, tendo em vista a análise das funções de autocorrelação e autocorrelação parcial, para verificar resultados.

O ambiente IDL opera em estações de trabalho Sun SPARC, IBM RS/6000 e Intergraph existentes no DPI, as quais utilizam processadores RISC (as primeiras) e Intel Pentium, com sistemas operacionais Unix (Solaris 2.5 e AIX) e Windows 95/NT Workstation. Tal característica é importante em termos de portabilidade para o programa que implementa o método proposto. O programa PEST, para previsão estatística, opera em PC, utilizando DOS, e servirá como ferramenta adicional de apoio e validação dos trabalhos desenvolvidos em IDL, em menor escala. O pacote científico MATLAB opera em sistemas operacionais Windows e Unix.

O software desenvolvido segue as características da metodologia orientada a eventos e utiliza a versatilidade e poder intrínsecos dos sistemas operacionais Unix e Windows 95/NT, a fim de conduzir a um desempenho computacional aceitável.

O IDL foi escolhido como ferramenta principal de desenvolvimento por suas características de linguagem de quarta geração, com características de programação visual, orientada a eventos, além da sua rapidez e eficiência de execução.

O Anexo A contém uma descrição detalhada da estrutura do software desenvolvido, apresentando seu diagrama hierárquico de funções (FHD) e o diagrama de interação entre os processos.

CAPÍTULO 4

RESULTADOS OBTIDOS

Este capítulo apresenta os resultados alusivos à identificação dos modelos autorregressivos em texturas de imagens, bem como a geração de imagens com texturas sintéticas obtidas a partir dos modelos definidos.

A Seção 4.1 discorre sobre os resultados da modelagem autorregressiva, enquanto a Seção 4.2 traz os resultados obtidos para a síntese de texturas. A Seção 4.1 é dividida em subseções relativas aos diversos tipos de imagem escolhidos, onde para cada tipo se vêem resultados para a modelagem simples pela concatenação de linhas, resultados para a modelagem utilizando a ACF2D concatenada e o diagnóstico sobre os resíduos. A Seção 4.2, por sua vez, é estruturada de maneira semelhante, por tipo de imagem escolhido, porém descrevendo, para cada tipo, a regeneração das imagens fonte a partir dos resíduos, a geração de texturas sintéticas a partir de campos aleatórios brancos e apresentando a avaliação final comparativa dos resultados.

Para a melhor avaliação do processo de modelagem, foram escolhidas imagens de radar de abertura sintética (SAR) da região da Floresta Nacional do Tapajós, obtidas pelo satélite JERS-1, imagens Landsat do Rio de Janeiro e óticas JERS-1 de Tokyo, bem como imagens de texturas naturais digitalizadas semelhantes às do álbum de Brodatz (1966).

Para a obtenção dos resultados descritos, foi utilizado o programa desenvolvido em IDL especialmente para este fim. Também foram utilizados, na fase inicial de estimativa de modelos e cálculo das funções de autocorrelação e autocorrelação parcial, os programas PEST (Brockwell e Davis, 1987) e MATLAB, como paradigmas para a verificação da correção de resultados iniciais em pequena escala. Para as regiões de estudo retangulares obtidas a partir de cada textura, após os testes de verificação de correção do algoritmo, foi utilizado tão somente o programa desenvolvido, abandonando os softwares de verificação inicial.

As regiões de estudo correspondiam geralmente de regiões de relativamente elevado número de linhas de 25 pontos cada, o que permitiria a definição de *lags* grandes para a ACF e a PACF, bem como modelos AR de ordem de grandeza consideravelmente superiores ao limite suportado pelo programa PEST.

4.1 MODELAGEM ESTATÍSTICA AUTORREGRESSIVA

A modelagem estatística autorregressiva unidimensional empregada segue a sistemática descrita nas Seções 3.2.1 e 3.2.2, no que tange à modelagem autorregressiva empregando a concatenação de linhas e colunas das imagens, porém utilizando, conforme o método proposto, a função de autocorrelação unidimensional ou bidimensional concatenada.

Dentro da seqüência de procedimentos adotados para a modelagem, seguiu-se basicamente a sistemática proposta por Dutra (1990) e descrita, em linhas gerais, na Seção 3.2.1:

- a) Aquisição dos dados relativos às áreas de treinamento, com a concatenação de segmentos de linhas e colunas;
- b) Retirada da média do sinal e observação dos gráficos da ACF e PACF, a fim de observar a tendência autorregressiva ou média móvel do modelo, de acordo com o comportamento dos *lags* (atrasos), em termos de sua tendência a se tornarem nulos ou permanecerem dentro dos intervalos de confiança;
- c) Obtenção das estimativas preliminares para $AR(p)$, de acordo com o observado no gráfico da PACF e com auxílio aos índices descritos na Seção 3.2.1.2;
- d) Observar o erro padrão para os coeficientes, considerando como nulos os não significativos;
- e) Revelar a região de suporte do filtro, obtida automaticamente pela natureza bidimensional dos dados;
- f) Realizar o diagnóstico sobre o modelo a fim de verificar se o resíduo é um ruído branco, testando outros modelos, caso esta condição não seja obtida.

Para as imagens SAR, foi também utilizado procedimento descrito na Seção 3.1, a fim de simetrizar o histograma da imagem radar e tornar a sua distribuição mais parecida com a distribuição gaussiana, utilizando as curvas cúbica e raiz cúbica.

4.1.1 Imagens SAR

O uso de imagens de radar de abertura sintética está consolidado como uma importante fonte de obtenção de dados para uso em estudos sobre a superfície terrestre e aplicações de sensoriamento remoto. Para este trabalho, foram utilizadas imagens SAR de 200 linhas e 200 colunas da Floresta Nacional do Tapajós obtidas pelo satélite de sensoriamento remoto JERS-1 (Banda L), conforme a Figura 4.1.

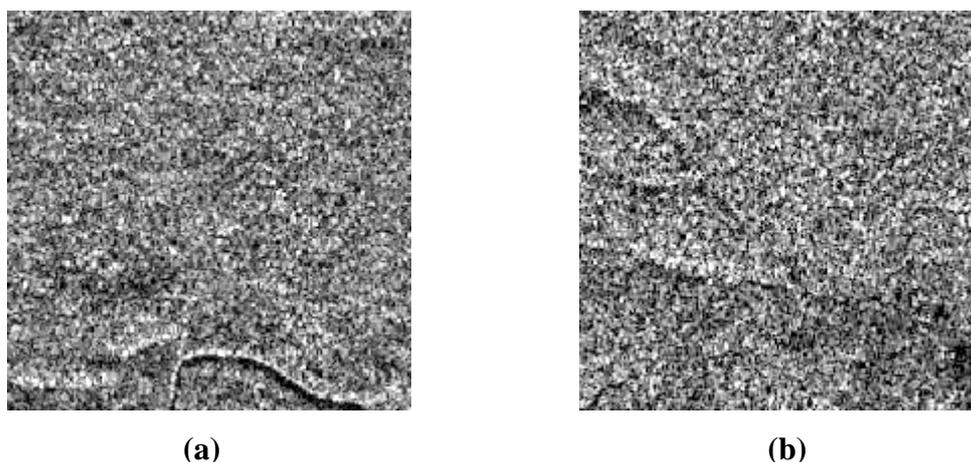


Fig. 4.1 - Imagens SAR da Floresta Nacional do Tapajós obtidas pelo satélite JERS-1. (a) Floresta tropical aberta (FTA) (b) Floresta tropical densa de relevo plano (FTDP).

4.1.1.1 Utilização das Curvas Cúbicas para a Gaussianização dos Dados

Conforme o descrito na Seção 3.1, as imagens SAR tornaram-se objeto de estudo, devido ao seu comportamento não gaussiano, através da transformação dos dados originais utilizando uma curva raiz cúbica. Esta transformação ou reescalonamento experimental visa reorganizar o histograma da imagem radar de modo a torná-lo mais parecido com a distribuição gaussiana. Tal avaliação fez-se necessária para verificar se

existe uma melhoria nos resultados da síntese utilizando-se a imagem transformada no processo de modelagem autorregressiva.

A Figura 4.2 representa a imagem obtida após a submissão da imagem da floresta tropical aberta (Figura 4.1.a), ou FTA, à curva raiz cúbica e a Figura 4.3 apresenta os histogramas correspondentes ao processo, assim como a Figura 4.4 representa, da mesma forma, o resultado do reescalonamento da imagem da floresta tropical densa de relevo plano (Figura 4.1.b), ou FTDP. A Figura 4.5 representa os correspondentes histogramas para FTDP e FTDP reescalada.

Observa-se visualmente que os resultados da aplicação da curva raiz cúbica deslocam o histograma em direção da média da nova imagem, apresentando uma distribuição mais parecida com a gaussiana. Submetendo-se os histogramas das imagens da FTA e FTDP reescaladas ao teste de Kolmogorov-Smirnov, em relação a ruídos brancos gaussianos de mesma média e desvio padrão - $N(\mu, \sigma)$ - que as imagens reescaladas, tomados como distribuição hipotética, obteve-se os resultados apresentados na Tabela 4.1. As distribuições teóricas foram geradas a partir do método de Box-Miller e para o mesmo número de amostras (40000).

TABELA 4.1 – COMPARAÇÃO ENTRE OS VALORES DA ESTATÍSTICA “D” DE KOLMOGOROV-SMIRNOV PARA AS IMAGENS REESCALONADAS E OS VALORES CRÍTICOS PARA NÍVEIS DE SIGNIFICÂNCIA 0,01 E 0,05 (n = 4000)

TIPO	D	0,05	0,01
FTA	0,0072500	0,0068	0,00815
FTDP	0,0059750	0,0068	0,00815

Pode-se observar que a estatística D (0,00725) para a imagem da FTA reescalada é menor que o valor crítico de 0,00815 para o nível de significância 0,01 e 40000 amostras (as imagens são de dimensão 200x200). Para a imagem FTDP reescalada, o resultado foi melhor se considerarmos que o valor da estatística D (0,0059750) é menor que o valor crítico de 0,0068 para o mesmo $n = 40000$, porém para um nível de significância de 0,05.

Conclue-se, então, que os dados para as duas imagens reescaladas não mostram uma distribuição significativamente diferente que a Normal de mesma média e desvio padrão, se for adotado um nível de significância de 0,01 para a FTA e 0,05 para a FTDP, respectivamente.

As imagens da Figura 4.2 (FTA reescalada pela raiz cúbica) e da Figura 4.4 (FTDP reescalada pela raiz cúbica) foram também utilizadas no processo de modelagem para a geração de texturas sintéticas, e seus resultados são apresentados adiante, na Seção 4.2.1.3.2. Vale citar que as imagens contendo as texturas sintéticas são escalonadas pela curva cúbica, ou seja, o inverso da curva raiz cúbica, para a comparação dos resultados ante as imagens originais.

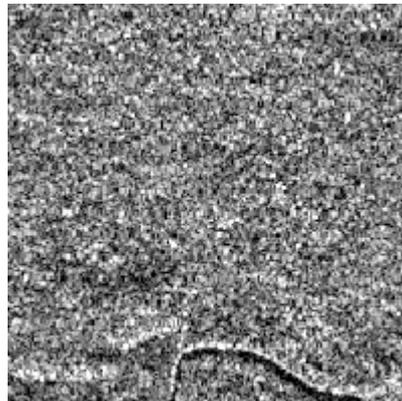


Fig. 4.2 - Imagem obtida a partir da imagem da FTA (Figura 4.1.a) utilizando a curva raiz cúbica.

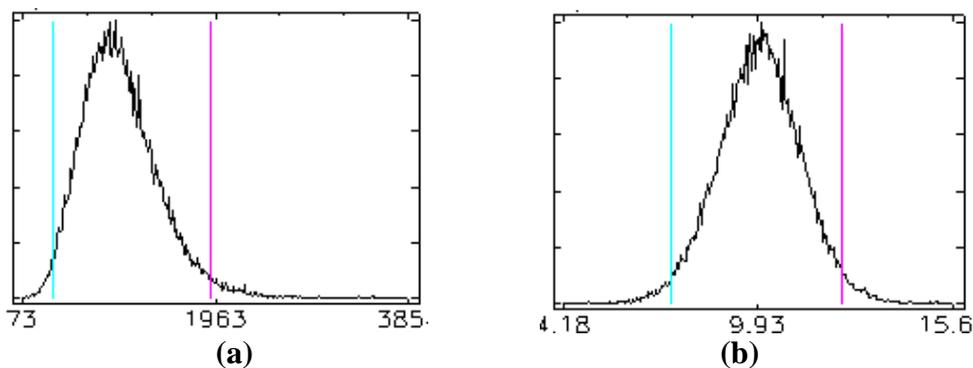


Fig. 4.3 - Histogramas das imagens da FTA (Figura 4.1.a) (a) e da FTA após reescalamento pela raiz cúbica (Figura 4.2) (b), respectivamente.

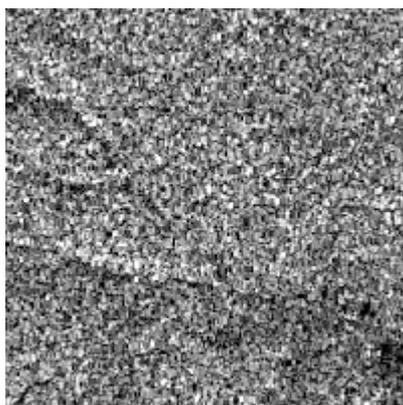


Fig. 4.4 - Imagem obtida a partir do reescalonamento da imagem da da FTDP (Figura 4.1.b) pela curva raiz cúbica.

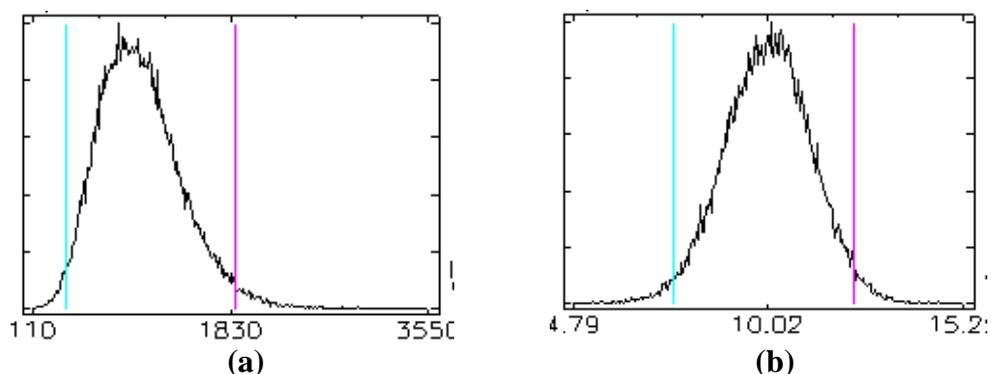


Fig. 4.5 - Histogramas das imagens da FTDP (Figura 4.1.b) (a) e do reescalonamento da FTDP pela raiz cúbica (Figura 4.4) (b), respectivamente.

4.1.1.2 Estimação de Parâmetros Utilizando Modelagem Autorregressiva a Partir da Concatenação dos Dados da Imagem e a Função de Autocorrelação Unidimensional

Utilizando o método definido na Seção 3.2.1, foram estimados os coeficientes autorregressivos para as texturas predominantes nas imagens da FTA (Figura 4.1.a) e FTDP (Figura 4.1.b), assim como seus respectivos reescalonamentos pela curva raiz cúbica (Figura 4.2 para FTA e Figura 4.4 para FTDP).

Para cada uma das imagens foram selecionadas amostras em regiões de estudo retangulares de 25 colunas e 100 linhas como fonte para a estimativa de parâmetros, concatenando segmentos de 25 pontos para a obtenção da série unidimensional.

A partir da definição da série temporal para cada uma das regiões de estudo, foi aplicado o método apresentado, definindo-se a melhor ordem do modelo a partir da estimativa inicial utilizando a função de autocorrelação parcial e testando os índices definidos em 3.2.1.2, obtidos a partir de funções de minimização (AIC, FPE, MDL e CAT), utilizando o critério de parcimônia. Confirmou-se, entretanto, a tendência dos índices apresentarem valores muito baixos para amostras grandes, tendo em vista a verificação da existência de coeficientes significativos em índices maiores que os sugeridos pelas funções de minimização, em alguns casos. A ordem escolhida foi, dessa maneira, a do índice do maior coeficiente significativo identificado para a PACF.

A Figura 4.6 e a Figura 4.7 ilustram, respectivamente, a ACF e a PACF para as imagens originais da FTA e FTDP. Os saltos das correlações nas figuras representam o *lag* 25 e seus múltiplos, com atenuação à medida que cresce o atraso. Este intervalo corresponde à largura da linha concatenada, o que justifica o súbito aumento das correlações.

A seleção dos coeficientes considerados dentro do intervalo de confiança foi seguida por posterior mapeamento no plano, definindo automaticamente uma região TNSHP e gerando um filtro AR2D.

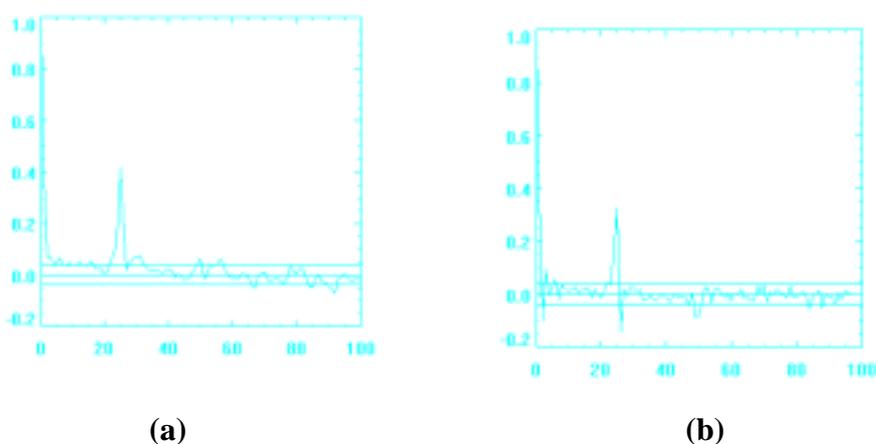


Fig. 4.6 - ACF (a) e PACF (b) da floresta tropical aberta (FTA).

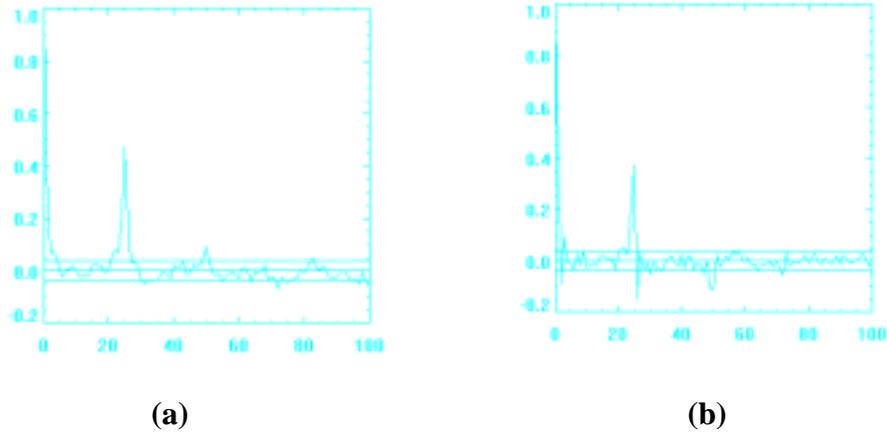
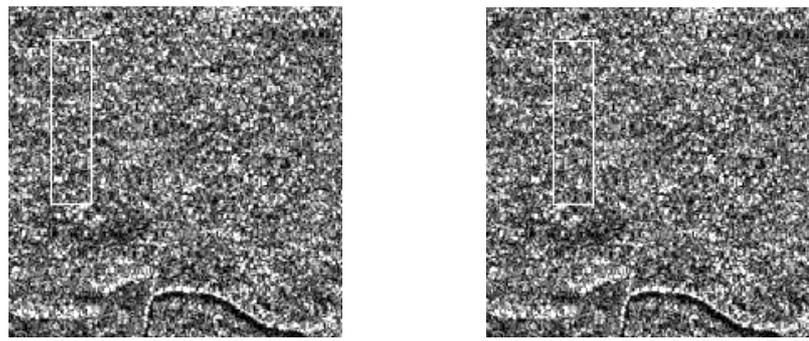


Fig. 4.7 – ACF (a) e PACF (b) da floresta tropical densa de relevo plano (FTDP).

Caso 1: Floresta Tropical Aberta (FTA)

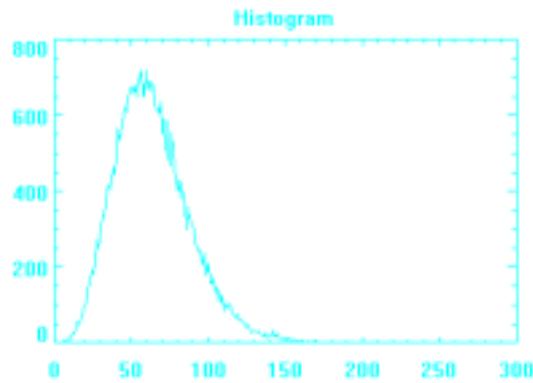
Para a imagem da FTA original (Figura 4.1.a), sem reescalamento pela raiz cúbica, cujo histograma é apresentado na Figura 4.8.c, foram escolhidas as regiões de estudo A_1 e A_2 , com cinco colunas de sobreposição, mostradas na Figura 4.8.a e na Figura 4.8.b. Foram gerados modelos AR2D obtidos a partir de modelos AR(50). Os coeficientes e a distribuição espacial dos modelos AR2D no TNSHP são apresentados na Figura 4.9.

A escolha de duas áreas de treinamento justifica-se pela necessidade de se observar o comportamento do método em diferentes regiões da textura existentes na imagem fonte.



(a) Região A_1

(b) Região A_2



(c)

Fig. 4.8 – Áreas de Treinamento (regiões de estudo) A_1 (a) e A_2 (b) escolhidas para a imagem FTA original, cujo histograma é apresentado em (c).

	⊗	0.407242	-0.107920	
	0.464144	-0.162268	0.000000	
	-0.0987466	0.000000	0.000000	
Modelo α_1 para as amostras da Região A_1				
	⊗	0.401439	-0.134663	0.0686138
0.0523201	0.415517	-0.143876	0.000000	0.000000
-0.0497221	-0.0819567	0.000000	0.000000	0.000000
Modelo α_2 para as amostras da Região A_2				

Fig. 4.9 - Modelos α_1 e α_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTA (Figura 4.1.a), sem reescalonamento pela raiz cúbica, para as áreas de treinamento A_1 e A_2 .

O valor mínimo de AIC foi coincidente para ambas as regiões de estudo no índice $p = 50$, tendência natural já observada por Dutra, (1990), em modelos obtidos a partir da mesma classe, sendo que o comportamento dos coeficientes significativos da PACF também levou à escolha deste índice como ordem do modelo (Figura 4.6.b). Na figura,

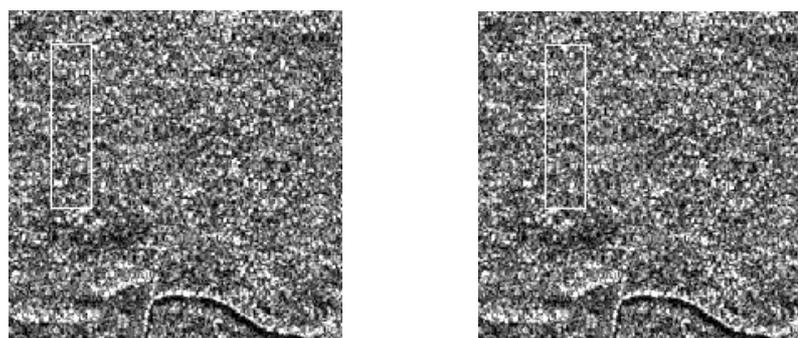
os coeficientes do filtro são representados de acordo com sua distribuição espacial relativa, e o símbolo \otimes representa a coordenada (0,0), a origem da região de suporte NSHP. Tal representação se faz necessária porque a coordenada (0,0) é excluída da região de suporte, para o cálculo do modelo autorregressivo bidimensional, conforme a Seção 2.7.4, tendo em vista a computabilidade recursiva.

Embora pertençam à mesma imagem, a escolha de diferentes áreas de treinamento, A_1 e A_2 , gerou filtros com diferente número de coeficientes significativos, fato que já era esperado, devido à natureza originariamente estatística da textura fonte. Observe-se, no entanto, que os valores dos coeficientes mais significativos são bastante próximos e que os coeficientes presentes no modelo α_2 para as amostras da região A_2 e ausentes no modelo α_1 da área de treinamento A_1 são de baixo valor (inferiores a 0,07), permitindo-se a assunção de que terão pequena influência no processo de filtragem inversa, o qual levará a obtenção da variância do ruído branco motor e da filtragem direta para a posterior síntese.

Caso 2: Floresta Tropical Aberta (FTA) Transformada pela Curva Raiz Cúbica

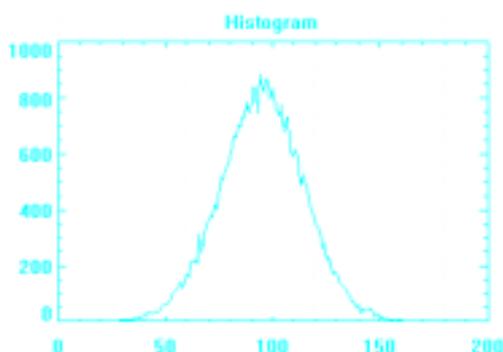
Para a textura existente na imagem da floresta tropical aberta reescalada pela curva raiz cúbica (Figura 4.2), cujo histograma é apresentado na Figura 4.10.c, foram utilizadas as áreas de treinamento B_1 e B_2 , conforme mostram a Figura 4.10.a e Figura 4.10.b, as quais possuíam os mesmos limites e dimensões das regiões escolhidas para a modelagem feita a partir da textura da imagem da FTA (Figura 4.8).

Embora o mínimo valor para AIC tenha sido obtido como $p = 26$, sugerindo modelos AR(26), encontrou-se coeficientes significativos para valores de $p = 50$, em ambos os casos, confirmando a tendência de seleção de ordem baixa para o modelo utilizando-se a função definida por Akaike (1976), o que levou a utilização deste valor para p em detrimento do valor sugerido pela função de minimização.



(a) Região B₁

(b) Região B₂



(c)

Fig. 4.10 – Áreas de Treinamento (regiões de estudo) B₁ (a) e B₂ (b) escolhidas para a imagem FTA reescalada pela curva raiz cúbica, cujo histograma é apresentado em (c).

	⊗	0.328492	-0.0510471	
0.0497421	0.339485	-0.0646826	0.000000	
0.000000	-0.0454662	0.000000	0.000000	
Modelo β_1 para as amostras da Região B₁				
	⊗	0.312307	-0.0836254	0.0605052
0.0554202	0.316225	-0.0648647	0.000000	0.000000
0.000000	-0.0385719	0.000000	0.000000	0.000000
Modelo β_2 para as amostras da Região B₂				

Fig. 4.11 - Modelos β_1 e β_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTA com reescalamento pela raiz cúbica (Figura 4.2), para as áreas de treinamento B₁ e B₂.

Os coeficientes obtidos pela estimação autorregressiva unidimensional com posterior mapeamento bidimensional são mostrados na Figura 4.11, definidos para os modelos β_1 e β_2 obtidos para as áreas de treinamento B₁ e B₂.

A ordem do modelo e os valores dos coeficientes apresentaram-se diferentes dos valores obtidos para a textura da imagem original (sem a transformação da raiz cúbica), o que era de certa forma esperado, pois influenciará na diferença de resultados obtidos para a posterior síntese. Este fato será avaliado adiante, na Seção 4.2.1.3.2.

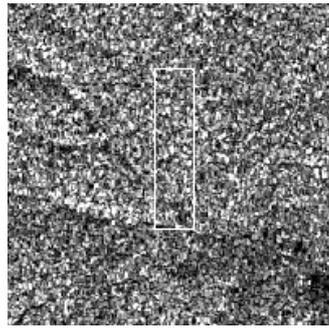
Com relação às diferenças entre os modelos β_1 e β_2 obtidos para as áreas de treinamento B_1 e B_2 , as mesmas observações anteriores se fazem aplicáveis, no que tange a semelhança entre os valores mais significativos e o pequeno valor de coeficientes que, de maneira singular, aparecem tão somente em um dos modelos.

Caso 3: Floresta Tropical Densa de Relevo Plano (FTDP)

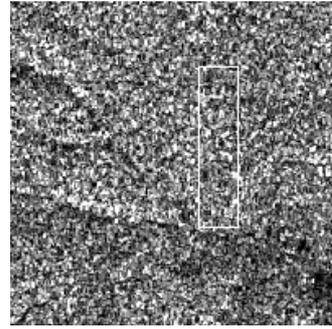
Os resultados obtidos para a modelagem AR2D da imagem da FTDP (Figura 4.1.b), a qual contém um padrão diferente de textura em relação à imagem da FTA (Figura 4.1.a), são apresentados na Figura 4.13. A Figura 4.12 apresenta as duas regiões de estudo Γ_1 e Γ_2 escolhidas a partir da textura fonte, também de 25 colunas e 100 linhas, bem como o histograma da imagem FTDP sem reescalonamento pela curva raiz cúbica.

Os valores mínimos obtidos para o índice AIC foram $p = 26$ e $p = 50$, respectivamente, para as áreas de treinamento Γ_1 e Γ_2 . A identificação de valor significativo na PACF em $p = 50$, também no primeiro caso, levou a escolha de dois modelos AR(50).

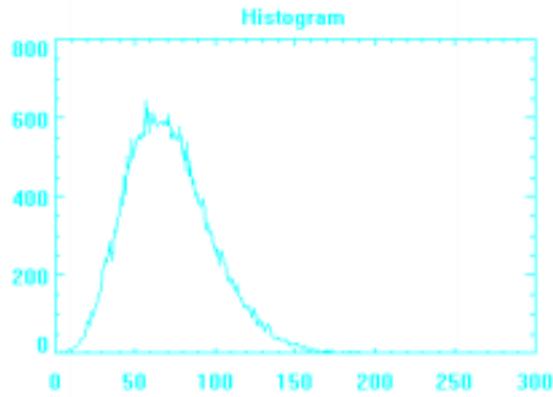
Percebe-se, a partir dos valores obtidos para os coeficientes significativos mapeados na forma AR2D, que as texturas obtidas a partir das áreas de treinamento tem um comportamento menos homogêneo que as texturas das regiões de estudo da imagem da FTA, embora exista similaridade entre os valores obtidos para o par de modelos e continue sendo observado o baixo valor dos coeficientes singulares existentes no modelo da região Γ_1 e inexistentes em Γ_2 . A causa da menor diferença entre o par de modelos γ_1 e γ_2 obtidos a partir da imagem da FTA reside no fato de que as regiões de estudo esta continham uma sobreposição de 5 colunas, enquanto as regiões de estudo da imagem da FTDP eram tão somente adjacentes, sem sobreposição (Figura 4.8 e Figura 4.10).



(a) Região Γ_1



(b) Região Γ_2



(c)

Fig. 4.12 – Áreas de Treinamento (regiões de estudo) Γ_1 (a) e Γ_2 (b) escolhidas para a imagem FTDP, sem reescalonamento pela curva raiz cúbica, cujo histograma é apresentado em (c).

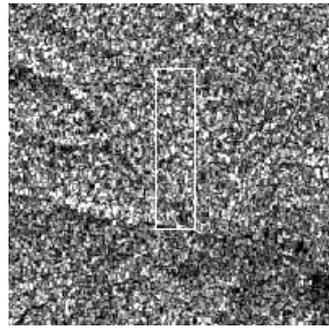
	⊗	0.381968	-0.131896	0.0789676
0.0645582	0.484549	-0.153063	0.0580679	0.000000
-0.0567367	-0.112066	0.000000	0.000000	0.000000
Modelo γ_1 para as amostras da Região Γ_2				
	⊗	0.433742	-0.101563	
	0.492030	-0.174146	0.000000	
	-0.0811416	0.000000	0.000000	
Modelo γ_2 para as amostras da Região Γ_2				

Fig. 4.13 - Modelos γ_1 e γ_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTDP sem reescalonamento pela raiz cúbica (Figura 4.1.b), para as áreas de treinamento Γ_1 e Γ_2 .

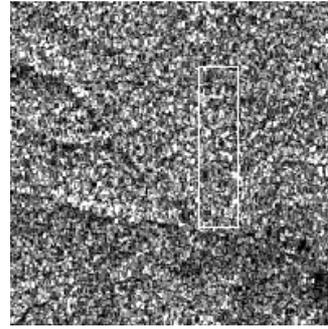
Caso 4: Floresta Tropical Densa de Relevo Plano (FTDP) Transformada pela Curva Raiz Cúbica

Para a imagem obtida a partir da transformação da imagem da FTDP a partir da curva raiz cúbica (Figura 4.4), os resultados são semelhantes aos obtidos anteriormente, gerando modelos AR(50) e AR(26) para as duas regiões de estudo, obtidos a partir das funções de minimização e dos coeficientes significativos na PACF.

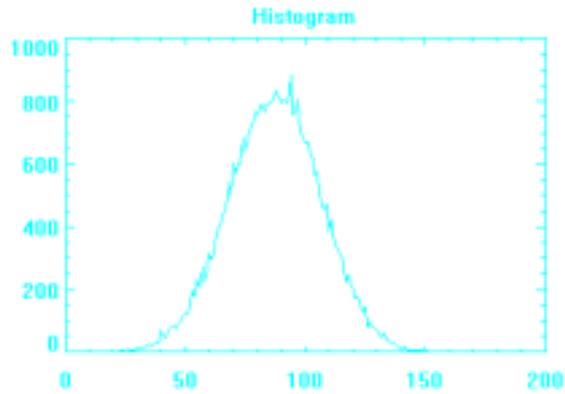
O comportamento da modelagem foi uniforme no sentido de que as texturas das regiões de estudo apresentaram o mesmo índice AIC que as texturas da imagem original, embora a imagem original apresentasse coeficientes significativos para $p = 50$ em ambos os casos. Uma tendência a menor número de coeficientes, no entanto, indica que os modelos reescalados pela curva raiz cúbica são potencialmente mais ajustados. Os modelos δ_1 e δ_2 , para as regiões Δ_1 e Δ_2 , obtidos a partir do mapeamento dos modelos AR para modelos AR2D, são representados espacialmente na Figura 4.15, enquanto a Figura 4.14 ilustra as áreas de treinamento e o histograma da imagem FTDP reescalada pela raiz cúbica.



(a) Região Δ_1



(b) Região Δ_2



(c)

Fig. 4.14 – Áreas de Treinamento (regiões de estudo) Δ_1 (a) e Δ_2 (b) escolhidas para a imagem FTDP, com reescalonamento pela curva raiz cúbica, cujo histograma é apresentado em (c).

	\otimes	0.285381	-0.0542360
0.0450278	0.438499	-0.0913197	0.000000
0.000000	-0.0897282	0.000000	0.000000
Modelo δ_1 para as amostras da Região Δ_1			
	\otimes	0.326523	-0.0455739
	0.373743	-0.0778314	0.000000
Modelo δ_2 para as amostras da Região Δ_2			

Fig. 4.15 - Modelos δ_1 e δ_2 AR2D obtidos a partir de modelos AR(26) e AR(50), respectivamente, para a textura fonte contida na imagem da FTDP com reescalonamento pela raiz cúbica (Figura 4.4), para as áreas de treinamento Δ_1 e Δ_2 .

4.1.1.3 Estimação de Parâmetros Utilizando Modelagem Autorregressiva de Dados Concatenados e a Função de Autocorrelação Bidimensional Concatenada

Conforme descrito na Seção 3.2.2, o segundo método utilizado para a estimativa de parâmetros para os coeficientes autorregressivos é semelhante em procedimentos ao método anterior de estimação, porém utiliza a função de autocorrelação bidimensional concatenada ao invés da função de autocorrelação linear, ou seja, procede-se duas concatenações, uma para a função de autocorrelação bidimensional gerada a partir dos dados da região bidimensional de estudo, e outra para os próprios dados, transformando-os em uma seqüência linear. A partir das concatenações, tanto os dados obtidos como a autocorrelação concatenada são aplicados às equações unidimensionais, bem como o mapeamento no plano é realizado, obtendo-se a definição automática da região de suporte.

Tendo em vista que a seleção da ordem do modelo AR não é influenciada pela ACF, mas pela PACF (Seção 3.2.1.1), utilizou-se, para cada caso descrito, da mesma ordem definida no decorrer dos procedimentos do método anterior.

O propósito da utilização da ACF2D é evitar a acumulação de erros nos valores de correlações indesejadas geradas pela concatenação simples das linhas e colunas da imagem. A concatenação da ACF2D é uma forma de alterar a estimativa da ACF linear, restringindo a somatória dos produtos de forma a não cruzar “fronteiras” entre linhas distintas na série concatenada. As ACF2D concatenadas para as imagens da FTA e da FTDP são apresentadas na Figura 4.16.

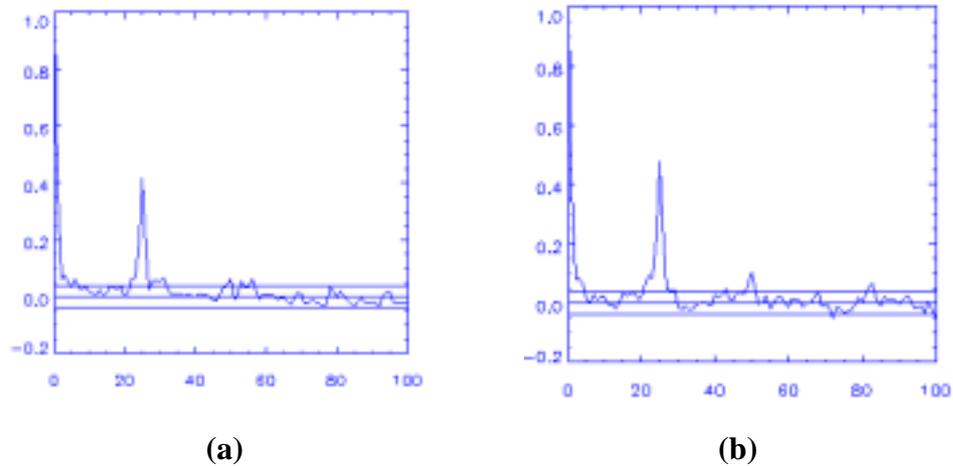


Fig. 4.16 – ACF2D concatenada para a FTA (a) e FTDP (b), respectivamente.

Caso 1: Floresta Tropical Aberta (FTA)

Para a imagem da FTA sem transformação pela curva raiz cúbica (Figura 4.1.a), os dois modelos AR(50) foram estimados a partir da concatenação das mesmas regiões de estudo A_1 e A_2 utilizadas anteriormente (Figura 4.8), produzindo os modelos AR2D ϵ_1 e ϵ_2 mostrados na Figura 4.17. Para a representação, aplicaram-se as mesmas notações descritas no método anterior, inclusive quanto ao uso do símbolo \otimes para a demarcação da origem.

	\otimes	0.412357	-0.101822	
	0.469150	-0.168145	0.000000	
	-0.0994155	0.000000	0.000000	
Modelo ϵ_1 para as amostras da Região A_1				
	\otimes	0.399581	-0.136729	0.0766763
0.0553095	0.415185	-0.137688	0.000000	0.000000
-0.0482370	-0.0881947	0.000000	0.000000	0.000000
Modelo ϵ_2 para as amostras da Região A_2				

Fig. 4.17 - Modelos ϵ_1 e ϵ_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTA (Figura 4.1.a), sem reescalonamento pela raiz cúbica, para as áreas de treinamento A_1 e A_2 (Figura 4.8), utilizando a ACF2D concatenada.

Comparando-se a Figura 4.17 com a Figura 4.9 (uso da FTA sem a transformação pela raiz cúbica, porém com a autocorrelação linear), observa-se que as diferenças entre os modelos estimados não são de valores significativamente elevados.

Caso 2: Floresta Tropical Aberta (FTA) Transformada pela Curva Raiz Cúbica

A imagem da FTA reescalada pela curva raiz cúbica (Figura 4.2), gerou os modelos ACF2D ϕ_1 e ϕ_2 após o mapeamento dos modelos AR(50), utilizando as mesmas áreas de treinamento B_1 e B_2 (Figura 4.10) e o segundo método de estimativa de parâmetros, tal qual o visualizado na Figura 4.18. As mesmas observações relativas à imagem submetida à transformação pela curva raiz cúbica aqui também se fazem aplicáveis, tal qual o descrito anteriormente.

Comparando-se a Figura 4.18 com a Figura 4.11, já que ambas são referentes a modelos obtidos a partir da FTA transformada pela curva raiz cúbica, porém utilizando a ACF2D concatenada e a ACF linear, respectivamente, observa-se que as diferenças dos valores dos coeficientes são significativas. O efeito da combinação do método de estimação utilizando a ACF2D e o reescalamento pela curva raiz cúbica, provável causador destas diferenças, é comentado na Seção 4.2.1.3.2.

	⊗	0.394879	-0.0935550	
	0.452712	-0.165909	0.0403939	
	-0.0870333	0.000000	0.000000	
	Modelo ϕ_1 para as amostras da Região B_1			
	⊗	0.381563	-0.129582	0.0678882
0.0538345	0.377423	-0.116045	0.000000	0.000000
-0.0401060	-0.0745098	0.000000	0.000000	0.000000
	Modelo ϕ_2 para as amostras da Região B_2			

Fig. 4.18 - Modelos ϕ_1 e ϕ_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTA com reescalamento pela raiz cúbica (Figura 4.2), para as áreas de treinamento B_1 e B_2 (Figura 4.10), utilizando a ACF2D concatenada.

Caso 3: Floresta Tropical Densa de Relevo Plano (FTDP)

A imagem da FTDP sem reescalonamento pela curva raiz cúbica (Figura 4.1.b) gerou os modelos AR2D ϕ_1 e ϕ_2 , a partir de modelos AR(50), utilizando novamente as áreas de treinamento Γ_1 e Γ_2 (Figura 4.12), conforme o representado na Figura 4.19. A semelhança dos fatos observáveis se mantém, no que tange à estimativa de parâmetros, se comparado com o método que se utiliza da ACF linear. As diferenças apresentar-se-ão no decorrer dos resultados do procedimento de síntese, adiante (Seção 4.2).

	⊗	0.385818	-0.124352	0.0687091
0.0604151	0.492204	-0.160655	0.0594824	0.000000
-0.0485828	-0.112360	0.000000	0.000000	0.000000
Modelo ϕ_1 para as amostras da Região Γ_1				
	⊗	0.424620	-0.0936698	
	0.491119	-0.167097	0.000000	
	-0.0737783	4.000000	0.000000	
Modelo ϕ_2 para as amostras da Região Γ_2				

Fig. 4.19 - Modelos ϕ_1 e ϕ_2 AR2D obtidos a partir de modelos AR(50), para a textura fonte contida na imagem da FTDP sem reescalonamento pela raiz cúbica (Figura 4.1.b), para as áreas de treinamento Γ_1 e Γ_2 (Figura 4.12), utilizando a ACF2D concatenada.

A equivalente da Figura 4.19 é a Figura 4.13, ambas representando modelos para FTDP sem a transformação pela raiz cúbica, porém com esta utilizando a ACF linear e aquela a ACF2D concatenada.

Caso 4: Floresta Tropical Densa de Relevo Plano (FTDP) Transformada pela Curva Raiz Cúbica

A FTDP com reescalonamento pela raiz cúbica (Figura 4.6) gerou os modelos AR2D η_1 e η_2 , utilizando as mesmas áreas de treinamento Δ_1 e Δ_2 definidas para a FTDP com transformação (Figura 4.14), a partir de modelos AR(26) e AR(50), respectivamente, conforme o representado na Figura 4.20. Foi mantida a mesma ordem definida para a FTDP reescalonada, ao ser utilizado o método anterior (ACF linear), já que a ordem dos modelos AR é tão somente influenciada pela PACF (Seção 3.2.1.1). A indicação de um modelo mais bem ajustado devido a presença de um menor número de coeficientes se

manteve, tal qual o ocorrido para FTDP reescalada no método de estimação de parâmetros utilizando a ACF linear. O paralelo da Figura 4.20 é a Figura 4.15. Novamente, as diferenças entre os coeficientes são significativas ao se combinar o método ACF2D e a transformação pela curva raiz cúbica.

	⊗	0.352060	-0.0942908	0.0514944
0.0589046	0.468360	-0.129459	0.0459813	0.000000
-0.0422512	-0.108399	0.000000	0.000000	0.000000
Modelo η_1 para as amostras da Região Δ_1				
	⊗	0.403137	-0.0823181	
	0.454107	-0.143585	0.000000	
	-0.0593275	0.000000	0.000000	
Modelo η_2 para as amostras da Região Δ_2				

Fig. 4.20 - Modelos η_1 e η_2 AR2D obtidos a partir de modelos AR(26) e AR(50), para a textura fonte contida na imagem da FTDP com reescalonamento pela curva raiz cúbica (Figura 4.4), para as áreas de treinamento Δ_1 e Δ_2 (Figura 4.14), utilizando a ACF2D concatenada.

4.1.1.4 Diagnóstico Sobre os Resíduos

A fim de verificar a adequação dos modelos gerados, os resíduos de cada modelo foram calculados, e, caso os modelos provassem ser bem ajustados, os resíduos calculados deveriam ser não correlacionados, ou seja, obter-se-ia um processo ruído branco cujas correlações para *lags* maiores que zero seriam aproximadamente nulas (Seção 3.2.1.4).

O processo de obtenção dos resíduos, ou, como também é chamado, filtragem inversa (Dutra, 1990), permite que, a partir da variância dos resíduos, sejam definidos campos aleatórios brancos que utilizem os filtros-modelo, em sua forma direta, para a posterior síntese.

A forma inversa dos filtros-modelo é obtida conforme o descrito na Seção 3.2.1.4, utilizando-se filtros MA2D, de mesmos coeficientes que os correspondentes filtros AR2D, porém de sinal invertido. Considerou-se que, no formato MA, a região de suporte é S_p e não S'_p , e que o coeficiente $\theta_{00} = -1$ para $u_{m,n}$ na equação (2-51), já que a

condição de computabilidade recursiva não obriga a exclusão da origem da região NSHP nos modelos MA2D.

Assim sendo, a representação para os modelos escolhidos toma forma semelhante aos modelos inversos α_1^{-1} e α_2^{-1} , obtidos a partir das Regiões A_1 e A_2 da textura fonte da imagem da FTA (Figura 4.8), sem reescalonamento pela raiz cúbica, tal qual o representado na Figura 4.21. Deve-se comparar com os filtros diretos representados na Figura 4.9. O mesmo padrão de representação pode ser aplicado à inversão dos modelos até aqui definidos, ao serem utilizados como modelos MA2D inversos. Tendo em vista a simplicidade da idéia, apenas os modelos α_n^{-1} foram representados, evitando a enfadonha repetição ocasionada pela apresentação de todos os modelos inversos.

	1	-0.407242	0.107920	
	-0.464144	0.162268	0.000000	
	0.0987466	0.000000	0.000000	
	Modelo α_1^{-1} para as amostras da Região A_1			
	1	-0.401439	0.134663	-0.0686138
-0.0523201	-0.415517	0.143876	0.000000	0.000000
0.0497221	0.0819567	0.000000	0.000000	0.000000
	Modelo α_2^{-1} para as amostras da Região A_2			

Fig. 4.21 - Modelos MA2D inversos obtidos a partir de modelos AR2D, para a textura fonte contida na imagem da FTA (Figura 4.1.a). Foi considerada a definição automática de regiões de suporte NSHP.

Para todos os modelos obtidos a partir das texturas fonte das imagens da FTA e da FTDP com e sem transformação pela raiz cúbica, representadas nas Figuras 4.1(a e b), 4.2 e 4.4, foram calculados os resíduos verificando se os valores da função de autocorrelação observaram o intervalo de confiança $\pm 2n^{-1/2}$, podendo ser considerados nulos (Seção 3.2.1.1), e o ruído, branco. A Figura 4.22 representa resultados do cálculo das funções de autocorrelação para os resíduos de alguns dos modelos utilizando valores máximos de atraso (*lag*) iguais a 300.

O observado foi que, para todos os modelos, a autocorrelação tem o comportamento esperado, mantendo-se a os valores dentro do intervalo de confiança, ou extremamente

próximos, apresentando correlações significativas apenas no *lag* 0, demonstrando que os dois métodos produziram modelos adequados para imagens SAR.

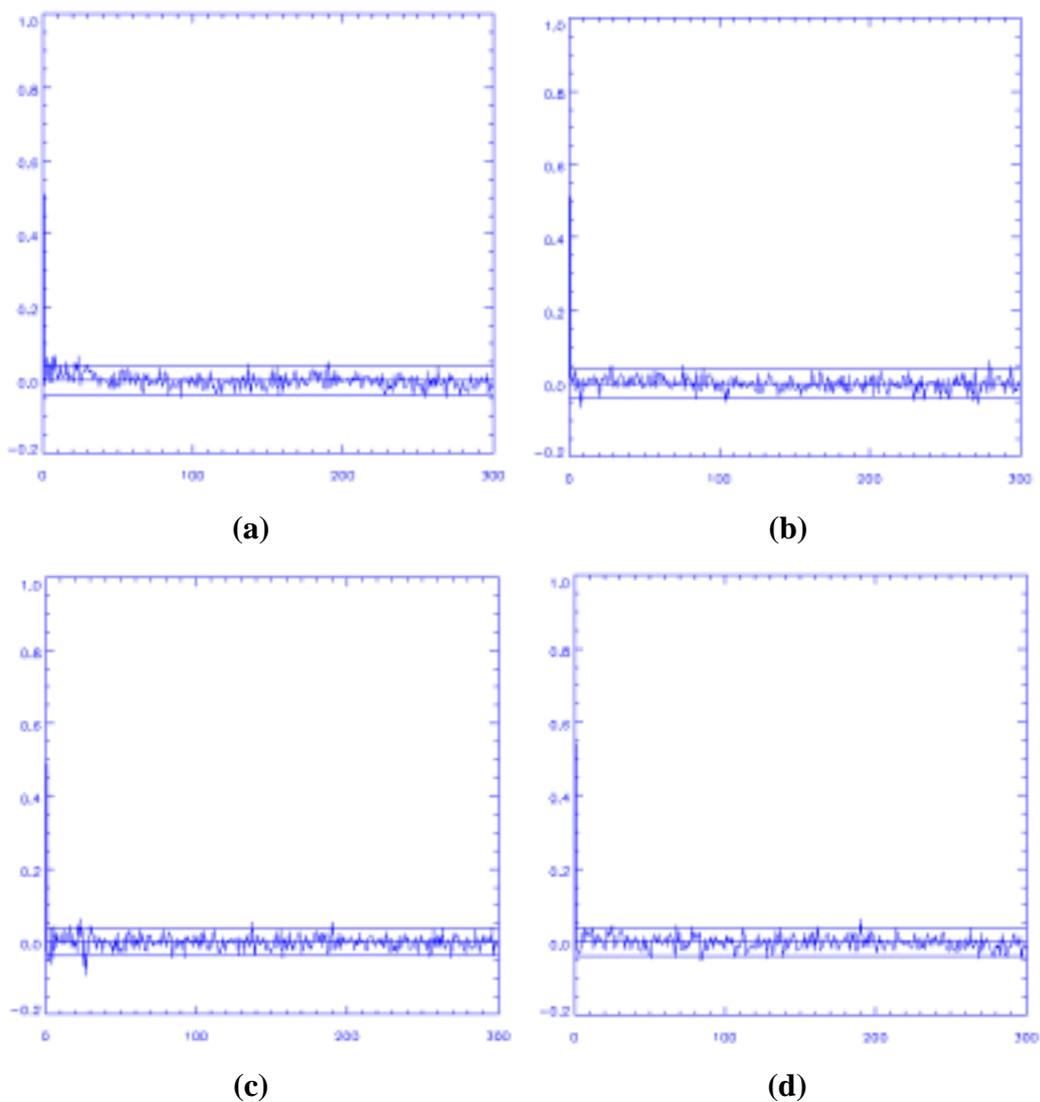


Fig. 4.22 - Autocorrelações dos resíduos gerados a partir das texturas das imagens: (a) modelo α_1 para FTA; (b) modelo α_2 para FTA; (c) modelo ϵ_1 (utilizando ACF2D concatenada) para FTA; (d) modelo β_1 para FTA com reescalonamento pela raiz cúbica; ($Lag_{m\acute{a}x} = 300$) (continua).

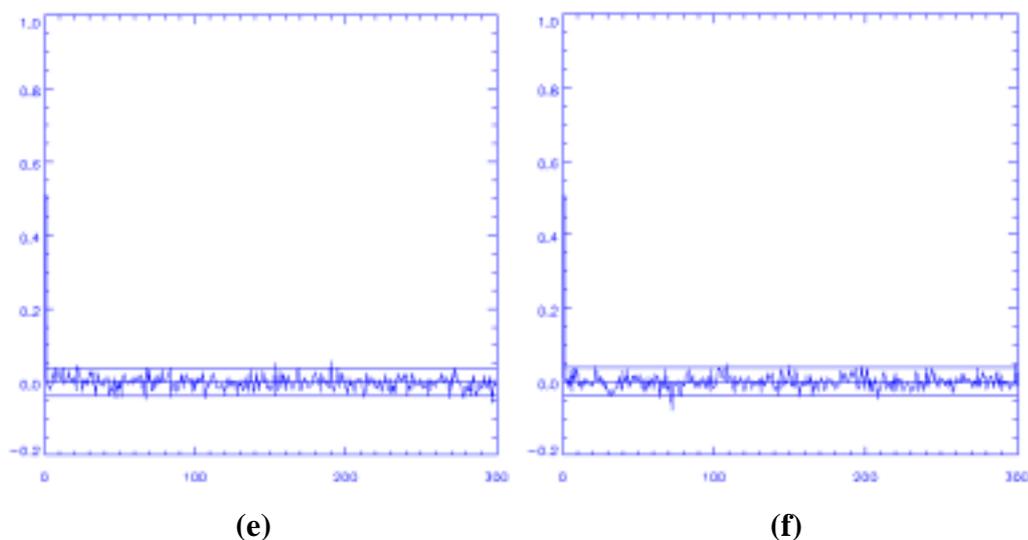
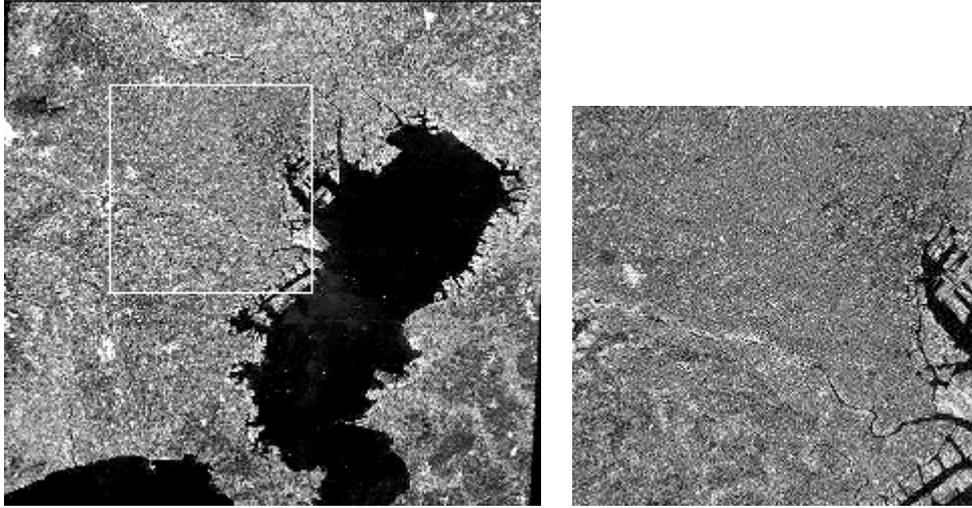


Fig. 4.22 - Continuação - (e) modelo ϕ_1 (utilizando ACF2D concatenada) para FTDP; (f) modelo γ_1 para FTDP; ($Lag_{\text{máx}} = 300$).

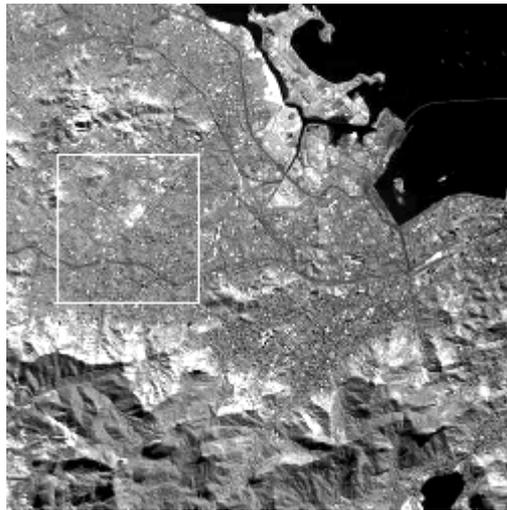
4.1.2 Imagens Óticas (JERS e Landsat)

Os métodos também foram testados em fragmentos de imagens óticas obtidas a partir dos satélites JERS-1 (um sumário das características do sensor ótico deste satélite é apresentado no Apêndice B) e Landsat-5, respectivamente, das regiões das cidades de Tokyo (Japão) e Rio de Janeiro, conforme o apresentado na Figura 4.23. Para cada fragmento, é apresentada a imagem fonte, com a respectiva demarcação.

Tendo em vista que o histograma das imagens obtidas de sensores óticos são próximos da gaussiana, não houve necessidade, para o processo de modelagem, da utilização de reescalonamento pela curva raiz cúbica, tais quais as imagens SAR. A Figura 4.24 apresenta os histogramas das novas imagens obtidas a partir dos fragmentos, as quais foram utilizadas no processo de modelagem.



(a)



(b)

Fig. 4.23 - Imagens óticas. (a) Tokyo (JERS-1); (b) Rio de Janeiro (Landsat-5).

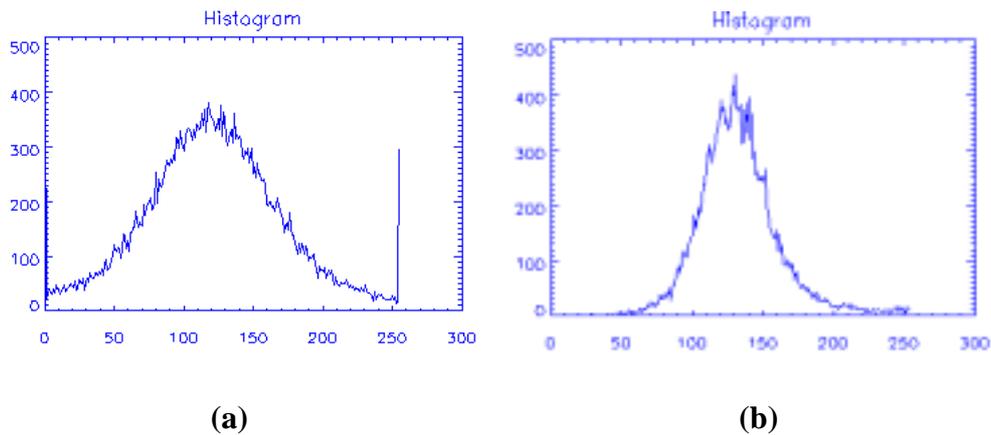


Fig. 4.24 - Histogramas de imagens óticas. (a) Tokyo; (b) Rio de Janeiro.

4.1.2.1 Estimativa de Parâmetros Utilizando Modelagem Autorregressiva a Partir da Concatenação dos Dados da Imagem e a Função de Autocorrelação Unidimensional

O método definido na Seção 3.2.1 foi novamente utilizado para a estimação dos parâmetros autorregressivos para as imagens óticas.

A ordem do modelo foi definida a partir da estimativa provida pelos coeficientes significativos da PACF e os índices obtidos pelas funções de minimização (Seção 3.2.1.2). Os mesmos comportamentos apresentados nas imagens de radar foram observados, no que tange a definição automática das regiões de suporte NSHP.

As regiões de estudo Λ e M utilizadas para as imagens estudadas são representadas na Figura 4.25. Para os dois casos, as regiões de estudo utilizadas foram de 25 colunas e 70 linhas. A escolha de regiões de estudo menores justificou-se pela menor uniformidade das texturas observadas na imagem.

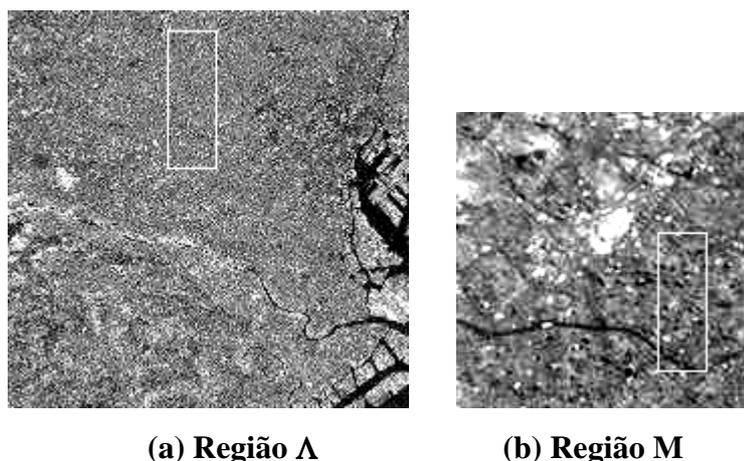


Fig. 4.25 - Imagens óticas com representação das áreas de treinamento (regiões de estudo) para Tokyo (Λ) e Rio de Janeiro (M).

Para a imagem JERS de Tokyo, a escolha para a ordem do modelo após a concatenação das linhas e colunas recaiu no valor de $p = 36$, obtido a partir do índice de Akaike (AIC). Os valores de coeficientes significativos da PACF apresentaram-se dentro dos limites do intervalo de confiança para valores maiores que p sugerido pela função de minimização (de fato, o maior coeficiente significativo da PACF foi $p = 36$). A Figura 4.26 apresenta o modelo λ , AR2D, gerado a partir do modelo AR(36) utilizando a área de treinamento Λ .

\otimes	-0.158536	0.000000
-0.142252	0.000000	0.0636185
Modelo λ para as amostras da Região Λ		

Fig. 4.26 - Modelo AR2D obtido a partir de modelo AR(36), para a textura fonte obtida a partir da imagem de Tokyo (Figura 4.23.a). Foi considerada a definição automática de região de suporte NSHP.

Considerando a imagem Landsat do Rio de Janeiro (Figura 4.23.b), o método foi aplicado escolhendo-se a área de treinamento M, e a escolha da melhor ordem para o modelo recaiu em $p = 78$. O modelo para Landsat foi gerado a partir do mapeamento do modelo AR(78) sobre o plano, obtendo-se uma região NSHP, pela aplicação dos valores nulos para os coeficientes de valores dentro dos limites do intervalo de confiança $\pm 2n^{-1/2}$. O modelo μ obtido foi apresentado na Figura 4.27.

	⊗	0.850444	-0.504821	0.235197
0.0804761	0.671111	-0.585024	0.337344	-0.146385
-0.0712584	-0.387525	0.344644	-0.196176	0.0858991
0.000000	0.198203	-0.157920	0.120712	-0.0851060
Modelo μ para as amostras da Região M				

Fig. 4.27 - Modelo AR2D obtido a partir de modelo AR(78), para a textura fonte obtida a partir da imagem do Rio de Janeiro (Figura 4.23.b).

4.1.2.2 Estimativa de Parâmetros Utilizando Modelagem Autorregressiva de Dados Concatenados e a Função de Autocorrelação Bidimensional Concatenada

As mesmas imagens de Tokyo e do Rio de Janeiro (Figura 4.23) e áreas de treinamento Λ e M definidas na Figura 4.25 foram utilizadas para a obtenção estimada de parâmetros autorregressivos para o segundo método estudado, definido na Seção 3.2.2. Como anteriormente citado, a diferença entre os dois métodos consiste na utilização da função de autocorrelação bidimensional concatenada visando evitar a acumulação de valores errôneos devido à concatenação.

Para a imagem de Tokyo (JERS), o modelo AR(36) foi concatenado levando à obtenção do modelo π AR2D definido na Figura 4.28.

Quanto à imagem Landsat do Rio de Janeiro, o modelo AR(78) concatenado obteve o modelo τ AR2D apresentado na Figura 4.28.

A ordem para cada um dos modelos foi a mesma que a estimada para o método anterior, levando-se em conta considerações já efetuadas na Seção 4.1.1.3. Um fator a ser considerado é a semelhança evidente entre o modelo λ da Figura 4.26 e o modelo π da Figura 4.28, os quais representam modelos obtidos a partir da imagem de Tokyo utilizando a ACF linear e a ACF2D concatenada, respectivamente, bem como entre o modelo μ da Figura 4.27 e o modelo τ da Figura 4.28 (situação semelhante à imagem de Tokyo, no que tange ao uso da ACF linear e da ACF2D concatenada, porém para a imagem do Rio de Janeiro).

	⊗	-0.158754	0.000000	0.000000	
	-0.130310	0.000000	0.0707853	0.0636954	
Modelo π para as amostras da Região Λ					
	⊗	0.878112	-0.514134	0.252958	0.000000
0.0558601	0.687146	-0.594328	0.321578	-0.121534	-0.0592291
-0.0566008	-0.409299	0.377210	-0.218403	0.118238	0.000000
0.000000	0.255245	-0.206401	0.156717	-0.104189	0.000000
Modelo τ para as amostras da Região M					

Fig. 4.28 - Modelos AR2D obtidos a partir das texturas fonte obtidas das imagens da Figura 4.23. O modelo π referencia a imagem ótica JERS de Tokyo e o modelo τ referencia a imagem Landsat do Rio de Janeiro, utilizando a autocorrelação bidimensional concatenada para a estimação de parâmetros.

4.1.2.3 Diagnóstico Sobre os Resíduos

Os resíduos obtidos a partir da filtragem inversa também se comportaram estatisticamente como campos brancos (ruídos brancos bidimensionais), tendo em vista que os valores das autocorrelações mantiveram a tendência de estarem dentro dos limites do intervalo de confiança, tal qual o já observado anteriormente para imagens SAR, demonstrando a coerência da abordagem escolhida.

Os filtros MA2D inversos para os modelos gerados utilizando os dois métodos de modelagem para as duas imagens óticas em estudo são apresentados na Figura 4.29. Da mesma forma, a Figura 4.30 apresenta as autocorrelações dos resíduos obtidos para os modelos definidos, também segundo os dois métodos apresentados, para atrasos (*lags*) inferiores a 300.

	1	0.158536	0.000000		
	0.142252	0.000000	-0.0636185		
	Modelo λ^{-1} para as amostras da Região Λ				
	1	0.158754	0.000000	0.000000	
	0.130310	0.000000	-0.0707853	-0.0636954	
	Modelo π^{-1} para as amostras da Região Λ				
	1	-0.850444	0.504821	-0.235197	
-0.0804761	-0.671111	0.585024	-0.337344	0.146385	
0.0712584	0.387525	-0.344644	0.196176	-0.0858991	
0.000000	-0.198203	0.157920	-0.120712	0.0851060	
	Modelo μ^{-1} para as amostras da Região M				
	1	-0.878112	0.514134	-0.252958	0.000000
-0.0558601	-0.687146	0.594328	-0.321578	0.121534	0.0592291
0.0566008	0.409299	-0.377210	0.218403	-0.118238	0.000000
0.000000	-0.255245	0.206401	-0.156717	0.104189	0.000000
	Modelo τ^{-1} para as amostras da Região M				

Fig. 4.29 - Modelos MA2D inversos obtidos a partir das texturas fonte obtidas das imagens óticas de Tokyo (Região Λ) e do Rio de Janeiro (Região M), utilizando os dois métodos de modelagem.

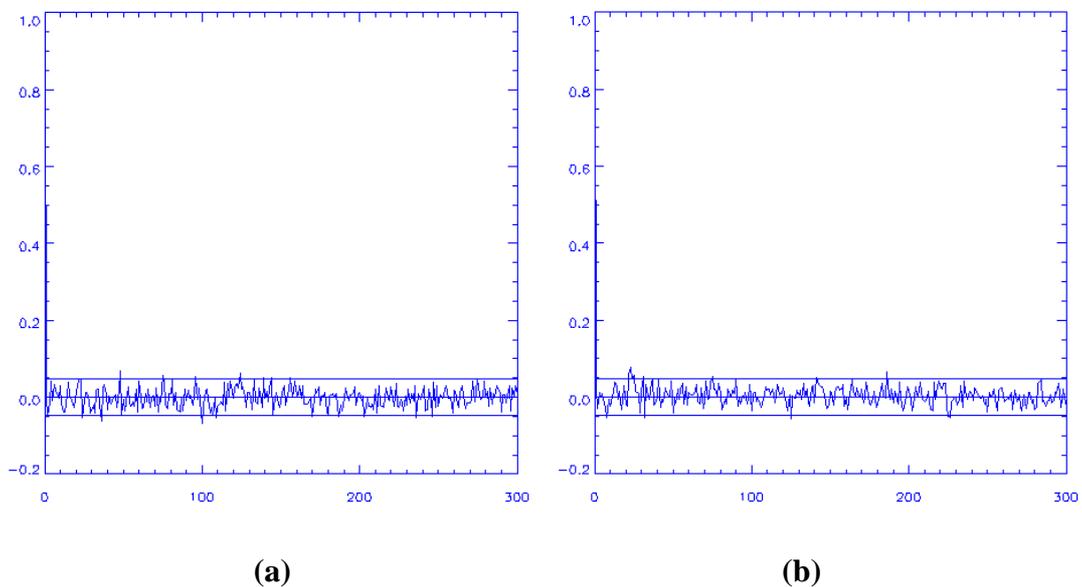


Fig. 4.30 - Autocorrelações dos resíduos das imagens óticas da Figura 4.23 com o uso da ACF linear para estimação. (a) Modelo λ (Tokyo); (b) Modelo μ (Rio de Janeiro).

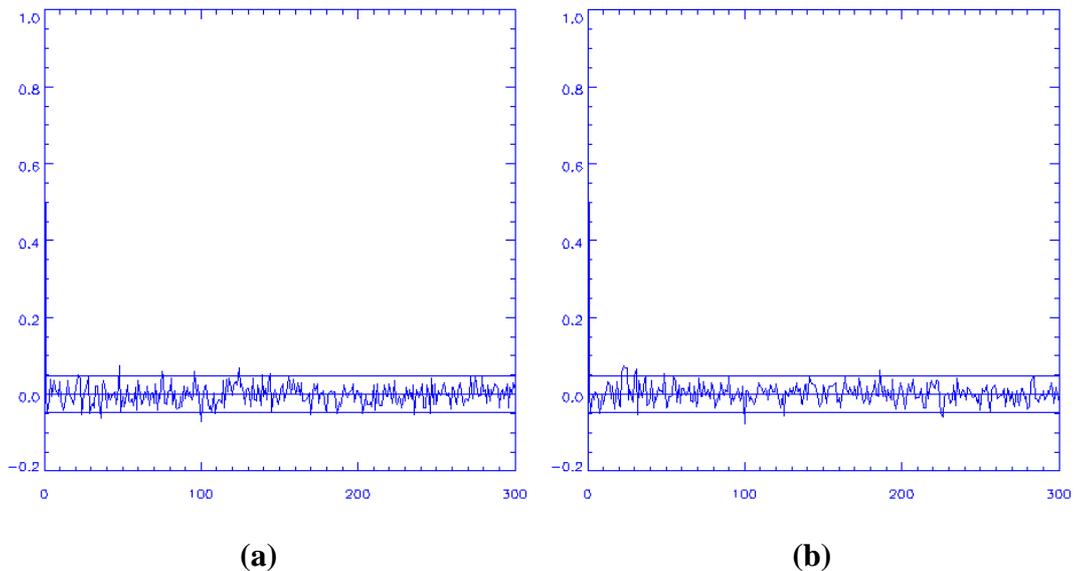


Fig. 4.31 - Autocorrelações dos resíduos das imagens óticas da Figura 4.23 com o uso da ACF2D concatenada para estimação. (a) Modelo π (Tokyo); (b) Modelo τ (Rio de Janeiro).

4.1.3 Texturas de Brodatz

Imagens contendo padrões de texturas naturais, tais quais as integrantes do álbum de Brodatz (1966), formaram o último grupo de texturas em estudo. Modelos AR2D também foram determinados para cada classe de textura. A Figura 4.32 ilustra as classes escolhidas para mármore e granito, tendo em vista a sua natureza não estruturada (determinística).

Classes de texturas altamente estruturadas, tais quais paredes de tijolos, foram previamente abandonadas devido à natureza estatística dos métodos de modelagem autorregressiva. A Seção 4.2.3.3 ilustra, entretanto, alguns exemplos para texturas contendo componentes determinísticos mais suaves. Para as texturas naturais, o método de transformação pela curva raiz cúbica também não se fez necessário, tendo em vista que os histogramas das imagens utilizadas possuíam distribuição gaussiana, como condição inicial.

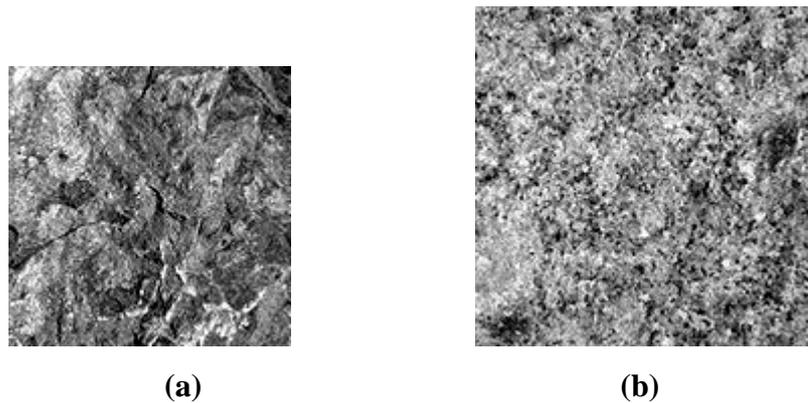


Fig. 4.32 - Texturas de Brodatz. (a) Granito; (b) Mármore.

4.1.3.1 Estimativa de Parâmetros Utilizando Modelagem Autorregressiva a Partir da Concatenação dos Dados da Imagem e a Função de Autocorrelação Unidimensional

O método utilizando a concatenação simples de linhas e colunas foi novamente aplicado a regiões de estudo obtidas a partir das texturas naturais mármore e granito apresentadas na Figura 4.32. Para a classe granito, a área de treinamento Ω era composta por 25 colunas e 60 linhas, e a região Ψ , para a classe mármore, era de 25 colunas e 100 linhas. A diferença entre os tamanhos das regiões de estudo justifica-se pela necessidade de definição de regiões uniformes de textura para a aplicação do método. A Figura 4.33 ilustra as áreas de treinamento escolhidas.

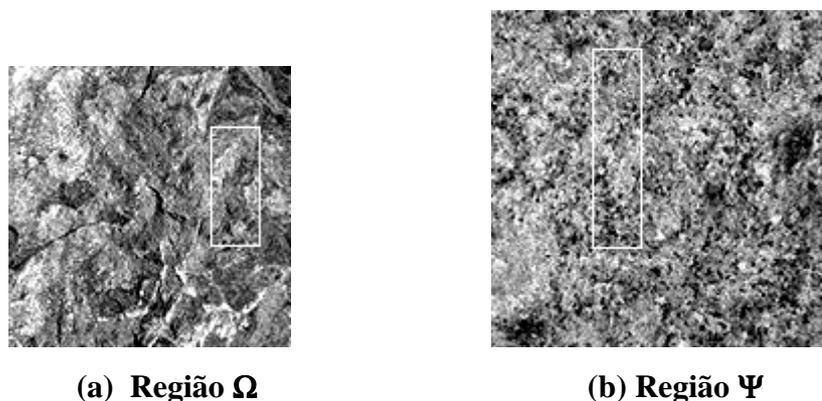


Fig. 4.33 – Áreas de treinamento Ω e Ψ para as classes granito (a) e mármore (b), respectivamente.

Para a classe granito, a escolha para a melhor ordem do modelo recaiu sobre a ordem $p = 51$, gerando um modelo AR(51). A definição automática da região de suporte produziu o modelo ω apresentado na Figura 4.34, ao ser utilizado o mesmo critério anterior de escolha de maior índice de coeficiente significativo para o modelo e conseqüente obtenção do modelo AR2D.

A classe mármore teve como ordem escolhida para o modelo o valor de $p = 75$, após a aplicação da função de minimização (AIC) e a observação de coeficientes significativos. O modelo ψ AR2D foi obtido a partir do mapeamento do modelo AR(75) no plano e também é apresentado na Figura 4.34.

		⊗	0.325851	-0.149785	0.137996
0.000000		0.476288	0.000000	0.0544099	0.000000
0.0634118		-0.168854	0.0775527	0.000000	0.000000
Modelo ω para as amostras da Região Ω					
		⊗	0.388198	-0.185954	0.103862
0.128075	0.418281	0.000000	0.000000	0.000000	-0.0440430
-0.070753	-0.186252	0.0481544	0.000000	0.000000	0.000000
0.061073	0.0702400	0.000000	0.000000	0.000000	0.000000
Modelo ψ para as amostras da Região Ψ					

Fig. 4.34 - Modelos AR2D obtidos a partir das texturas de Brodatz (Figura 4.32). O modelo ω referencia a classe granito e o modelo ψ referencia a classe mármore.

4.1.3.2 Estimativa de Parâmetros Utilizando Modelagem Autorregressiva de Dados Concatenados e a Função de Autocorrelação Bidimensional Concatenada

O segundo método (ACF2D concatenada) também foi utilizado para a estimatimação de parâmetros autorregressivos e produção de modelos AR2D, para as texturas de Brodatz das classes granito e mármore (Figura 4.32).

As mesmas áreas de treinamento Ω e Ψ utilizadas anteriormente foram consideradas, bem como a seleção da ordem para cada um dos modelos foi mantida. Assim, a classe

granito foi gerada a partir do mapeamento de um modelo AR(51), gerando o modelo ρ AR2D. De forma semelhante, para a classe mármore, um modelo AR(75) gerou o modelo θ AR2D, conforme ilustrado na Figura 4.35. Da mesma forma que anteriormente, a semelhança entre os modelos ρ e θ apresentados na Figura 4.35 é facilmente observável em relação aos modelos correspondentes ω e ψ da Figura 4.34, respectivamente para as classes granito e mármore.

	\otimes	0.323598	-0.136121	0.125332	
0.0531184	0.480058	0.000000	0.000000	0.000000	
0.0552336	-0.167917	0.0861677	0.000000	0.000000	
Modelo ρ para as amostras da Região Ω					
	\otimes	0.388198	-0.185954	0.103862	-0.0440430
0.128075	0.418281	0.000000	0.000000	0.000000	0.000000
-0.0707538	-0.186252	0.0481544	0.000000	0.000000	0.000000
0.0610737	0.070240	0.000000	0.000000	0.000000	0.000000
Modelo θ para as amostras da Região Ψ					

Fig. 4.35 - Modelos AR2D obtidos a partir das texturas de Brodatz mostradas na Figura 4.32, utilizando a ACF2D concatenada . O modelo ρ referencia a classe granito e o modelo θ referencia a classe mármore.

4.1.3.3 Diagnóstico Sobre os Resíduos

Tal qual as imagens SAR e óticas, os resíduos gerados a partir das texturas de Brodatz também se comportaram como ruídos brancos bidimensionais (campos brancos), fato observado ao se verificar as autocorrelações geradas para os resíduos obtidos para as classes granito e mármore com atrasos (*lags*) inferiores a 300.

Os modelos MA2D inversos para a classe granito são apresentados na Figura 4.36, enquanto a Figura 4.37 apresenta os modelos inversos para a classe mármore. Percebe-se que os modelos inversos correspondem aos modelos apresentados anteriormente na Figura 4.34 e na Figura 4.35, porém com os sinais trocados.

Os modelos inversos foram utilizados no processo de obtenção dos resíduos, conforme o descrito na Seção 3.2.1.4. As autocorrelações dos resíduos são apresentadas Figura 4.38.

	1	-0.325851	0.149785	-0.137996	
0.000000	-0.476288	0.000000	-0.0544099	0.000000	
-0.0634118	0.168854	-0.0775527	0.000000	0.000000	
Modelo ω^{-1} para as amostras da Região Ω					
	1	-0.323598	0.136121	-0.125332	
-0.0531184	-0.480058	0.000000	0.000000	0.000000	
-0.0552336	0.167917	-0.0861677	0.000000	0.000000	
Modelo ρ^{-1} para as amostras da Região Ω					

Fig. 4.36 - Modelos MA2D inversos para a classe granito, utilizando os dois métodos em estudo.

	1	-0.388198	0.185954	-0.103862	0.0440430
-0.128075	-0.418281	0.000000	0.000000	0.000000	0.000000
0.070753	0.186252	-0.0481544	0.000000	0.000000	0.000000
-0.061073	-0.0702400	0.000000	0.000000	0.000000	0.000000
Modelo ψ^{-1} para as amostras da Região Ψ					
	1	-0.388198	0.185954	-0.103862	0.044043
0.128075	0.418281	0.000000	0.000000	0.000000	0.000000
0.0707538	0.186252	-0.0481544	0.000000	0.000000	0.000000
-0.0610737	-0.070240	0.000000	0.000000	0.000000	0.000000
Modelo θ^{-1} para as amostras da Região Ψ					

Fig. 4.37 - Modelos MA2D para a classe mármore, utilizando os dois métodos em estudo.

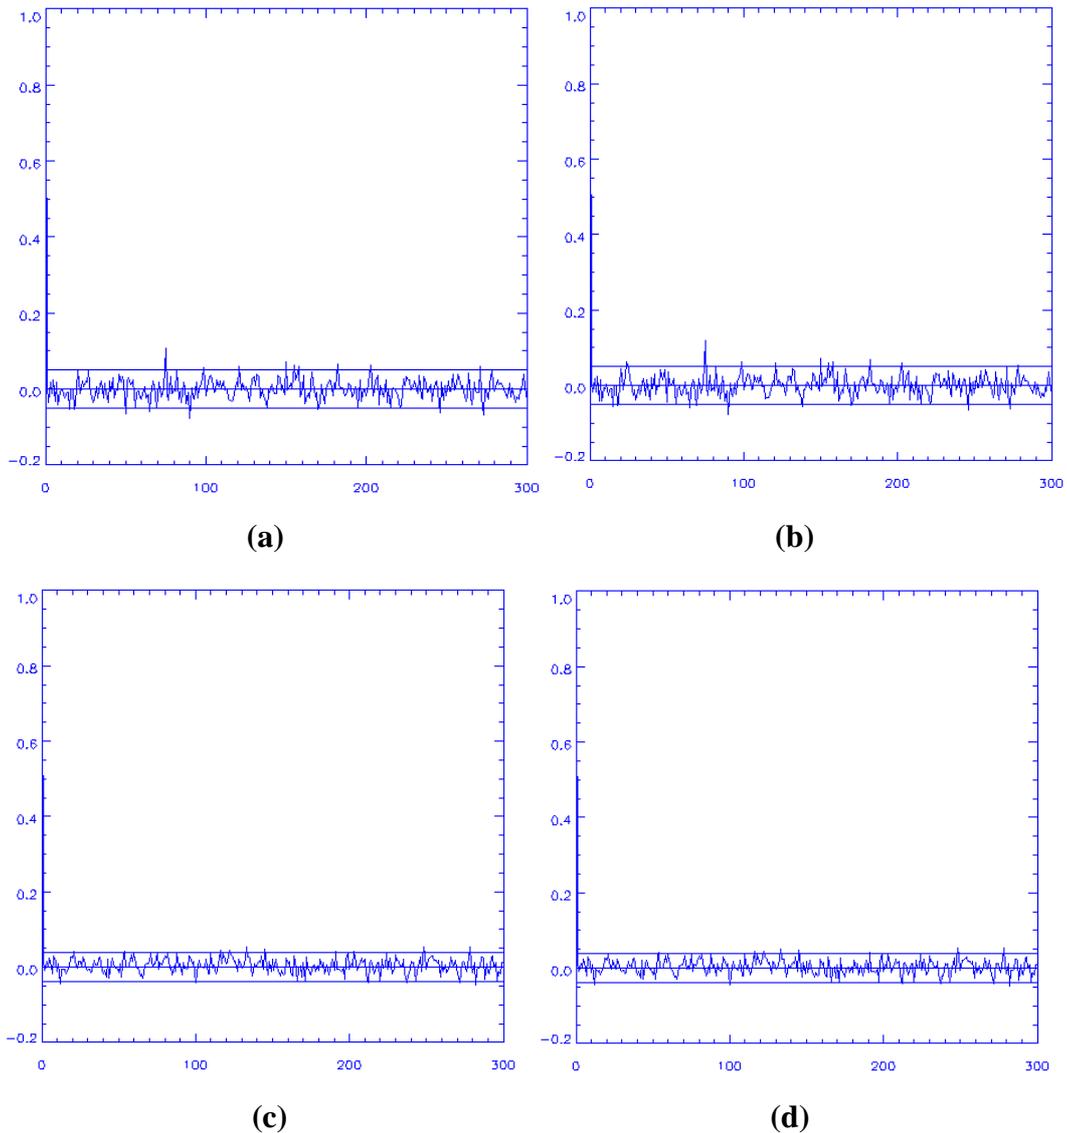


Fig. 4.38 - Autocorrelações para os resíduos das classes granito - modelos ω (a) e ρ (b) - e mármore - modelos ψ (c) e θ (d).

4.2 SÍNTESE DE TEXTURAS

Após a fase inicial de modelagem para as diversas classes de texturas contidas nas imagens dos tipos analisados, ou seja, SAR, óticas e texturas de Brodatz, a fase subsequente é a síntese de texturas a partir da utilização dos modelos obtidos. Um algoritmo de síntese será utilizado para a geração da matriz bidimensional de dados pictóricos correspondentes a uma textura de mesma natureza, ou seja, as mesmas

propriedades estatísticas, considerando que a textura original e a sintética são realizações de um mesmo *ensemble*.

A Seção 3.4 justifica a escolha do método de geração de texturas sintéticas utilizando ruídos brancos gaussianos de média zero e mesma variância que os resíduos $\hat{a}_{i,j}$ obtidos a partir da modelagem estatística, tendo em vista a própria natureza dos modelos ARMA, que são, por definição, excitados a partir de ruídos brancos (*white noise driven*) de média zero e variância σ^2 .

O ciclo de testes utilizado também está definido na Seção 3.4, e, nas seções subsequentes, ter-se-á a descrição da operacionalização das seguintes tarefas:

- regeneração das texturas das imagens naturais utilizando filtragem direta;
- geração de um campo aleatório branco, a fim de gerar imagens sintéticas;
- verificação dos resultados, através de comparação visual, avaliação dos momentos de segunda ordem e vetores de distâncias.

4.2.1 Imagens SAR

O processo de síntese de texturas para as imagens SAR da FTA e da FTDP apresentadas na Figura 4.1 levou em consideração as características inerentes às imagens de radar, as quais levaram a inclusão do reescalonamento pela curva raiz cúbica no escopo da metodologia utilizada e na avaliação dos resultados.

4.2.1.1 Regeneração das Imagens Fonte

O objetivo da regeneração da imagem fonte através de filtragem inversa, obtenção de resíduos e posterior filtragem direta para regeneração é a verificação do ajuste do modelo com a natural verificação da correção do algoritmo implementado para o processo de filtragem inversa/direta, o que é uma condição prévia para a síntese de texturas utilizando ruídos brancos.

Tendo em vista que o resíduo é considerado como um ruído branco do mesmo *ensemble* que os ruídos brancos a serem utilizados na síntese (de fato, os momentos de segunda ordem do resíduo são os responsáveis pela identificação do *ensemble*), é importante que a filtragem direta, ou seja, a síntese, a partir dos resíduos, regenere as texturas presentes na imagem original.

Os algoritmos de obtenção dos resíduos (filtragem inversa) e o de síntese (filtragem direta) foram então testados no sentido em que, a partir dos resíduos gerados, o filtro direto deve ser capaz de regenerar a imagem original em seus detalhes de textura, conforme o citado na Seção 3.4.2.

A Figura 4.39 e a Figura 4.40 apresentam a regeneração das imagens da FTA e da FTDP, sem reescalonamento, (Figura 4.1), ao serem utilizados os modelos α_1^{-1} e γ_1^{-1} para a obtenção do resíduo.

A Tabela 4.2 e a Tabela 4.3 apresentam os momentos de segunda ordem para a imagens natural e regenerada, bem como para o resíduo, ao ser verificado o ajuste dos modelos α_1 e γ_1 , respectivamente. A Tabela 4.4 ilustra o mesmo processo para a imagem da FTA reescalada pela curva raiz cúbica (Figura 4.2), ao ser utilizado o modelo β_1 , apresentando os dados relativos aos momentos de segunda ordem.

Todos os resíduos obtidos para as imagens SAR, a partir dos modelos apresentados nas Seções 4.1.1.2 e 4.1.1.3, quando submetidos à filtragem direta, regeneraram a imagem original, salvo imperfeições numéricas, demonstrando a exatidão dos algoritmos de filtragem inversa/direta e o nível de ajuste dos modelos escolhidos. A média dos mesmos sempre apresentou-se próxima a zero, tendo em vista que a média é extraída da imagem no início do processo de estimativa de parâmetros, o que também é uma característica desejável para os ruídos brancos motores de modelos ARMA completos ou simplesmente AR (Seção 2.6).

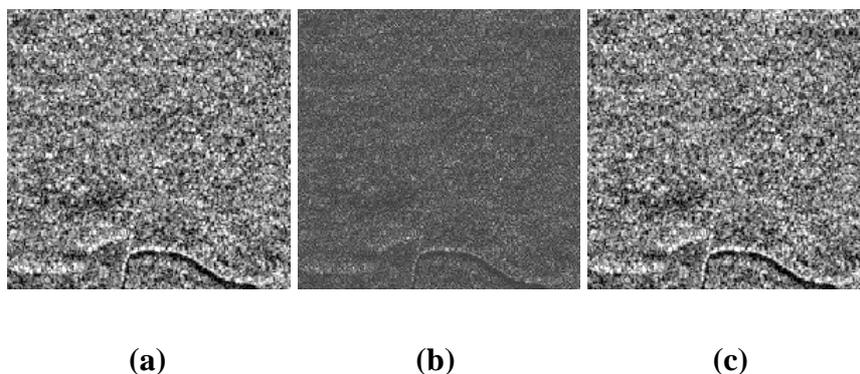


Fig. 4.39 - Processo de verificação do ajuste dos algoritmos utilizados para o processo de filtragem inversa (obtenção do resíduo) e direta (regeneração) para a imagem da FTA (Figura 4.1.a) utilizando o modelo α_1 . (a) Imagem SAR original; (b) resíduo; (c) Imagem regenerada.

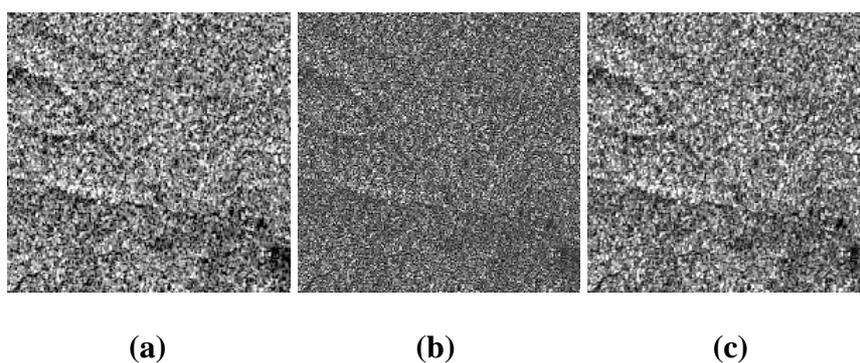


Fig. 4.40 - Processo de verificação do ajuste dos algoritmos utilizados para o processo de filtragem inversa (obtenção do resíduo) e direta (regeneração) para a imagem da FTDP (Figura 4.1.b) utilizando o modelo γ_1 . (a) Imagem SAR original; (b) resíduo; (c) Imagem regenerada.

TABELA 4.2 - MOMENTOS DE SEGUNDA ORDEM RELATIVOS AO MODELO α_1 (FTA)

TIPO	MÉDIA	VARIÂNCIA
Imagem Original	1040,77	138446
Resíduo	0,0155012	89555
Imagem Regenerada	1040,77	138446

TABELA 4.3 - MOMENTOS DE SEGUNDA ORDEM RELATIVOS AO MODELO γ_1 (FTDP)

TIPO	MÉDIA	VARIÂNCIA
Imagem Original	1050,85	126885
Resíduo	-0,106939	81951
Imagem Regenerada	1050,84	121784

TABELA 4.4 - MOMENTOS DE SEGUNDA ORDEM RELATIVOS AO MODELO β_1 (FTA REESCALONADA)

TIPO	MÉDIA	VARIÂNCIA
Imagem Original	9,98985	1,46378
Resíduo	0,000245	0,99063
Imagem Regenerada	9,98999	1,40649

4.2.1.2 Geração de Texturas a Partir de Campo Aleatório Branco

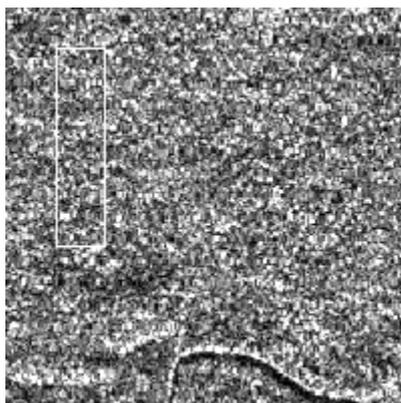
A partir da verificação do ajuste do modelo, um gerador de ruído branco de média zero e variância σ^2 próxima à variância do resíduo foi construído a partir de uma rotina de geração de números aleatórios de distribuição normal utilizando o método de Box-Müller (Park e Miller, 1988), conforme o descrito na Seção 3.4.3.

Para cada modelo estimado a partir dos métodos em estudo, foi obtido o ruído branco bidimensional (ou campo branco) pertencente ao mesmo *ensemble* que o resíduo, e considerou-se o mesmo como o ruído branco motor do processo AR2D. Em outras palavras, os coeficientes estimados foram utilizados para a filtragem direta e obtenção de um campo texturado sintético de mesmas características que as regiões de estudo das imagens SAR estudadas. A cada ponto processado pelo modelo, adicionou-se, ainda, a média da região de estudo da imagem que contém a textura fonte.

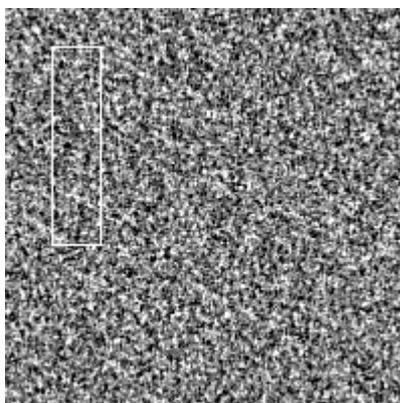
A Figura 4.41 ilustra os resultados obtidos para a imagem da FTA (Figura 4.1.a), e sua transformação pela curva raiz cúbica (Figura 4.2), enquanto a Tabela 4.5 contém um sumário das características de cada campo sintético gerado, incluindo os campos gerados pela recuperação utilizando a terceira potência (cubo) para os modelos que haviam sido produzidos pelo reescalonamento pela curva raiz cúbica, conforme a Seção 4.1.1.1. Tendo em vista que, em termos de apresentação visual, estes últimos são idênticos aos campos texturados gerados a partir das imagens com as transformações

cúbicas (tal qual a semelhança de apresentação entre as imagens da FTA na Figura 4.1.a e na Figura 4.2), sua apresentação visual foi omitida.

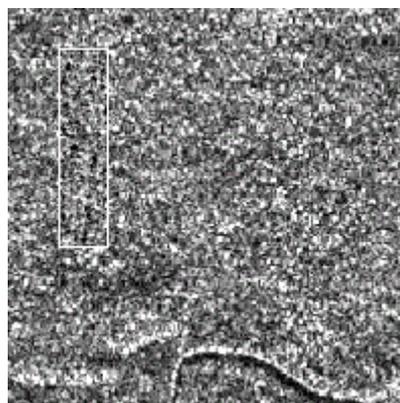
Para a imagem da FTDP (Figura 4.1.b) e sua transformada pela curva raiz cúbica (Figura 4.4), os resultados foram consolidados na Figura 4.42 e na Tabela 4.6.



(a)

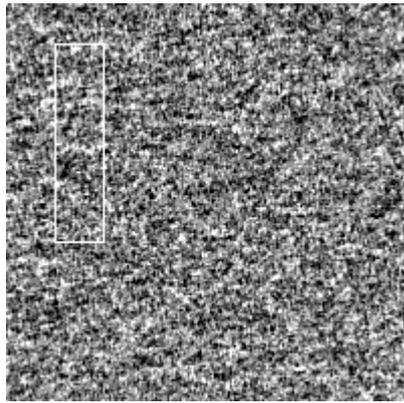


(b)

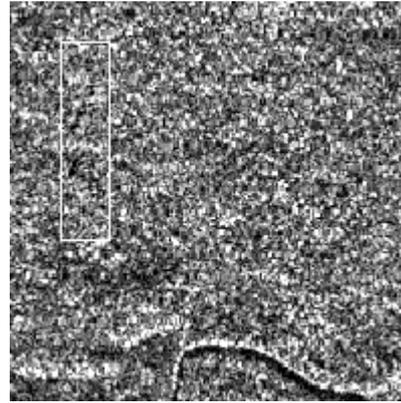


(c)

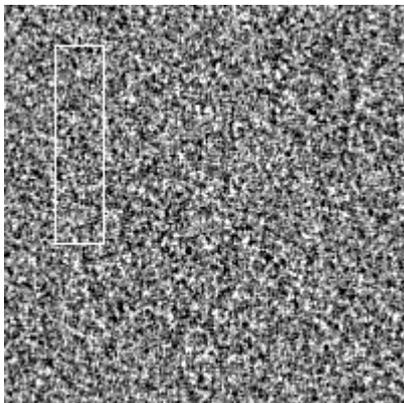
Fig. 4.41 - Seqüência de imagens para a avaliação do processo de síntese de texturas de imagens SAR da FTA: (a) Imagem original; (b) Campo sintético - modelo α_1 ; (c) Inserção do campo sintético (continua);



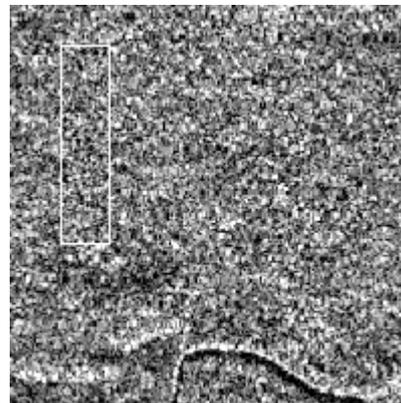
(d)



(e)



(f)



(g)

Fig. 4.41 - Continuação - (d) Campo sintético - modelo ϵ_1 ; (e) Inserção do campo sintético; (f) Campo sintético - modelo β_1 ; (g) Inserção do campo sintético (continua);

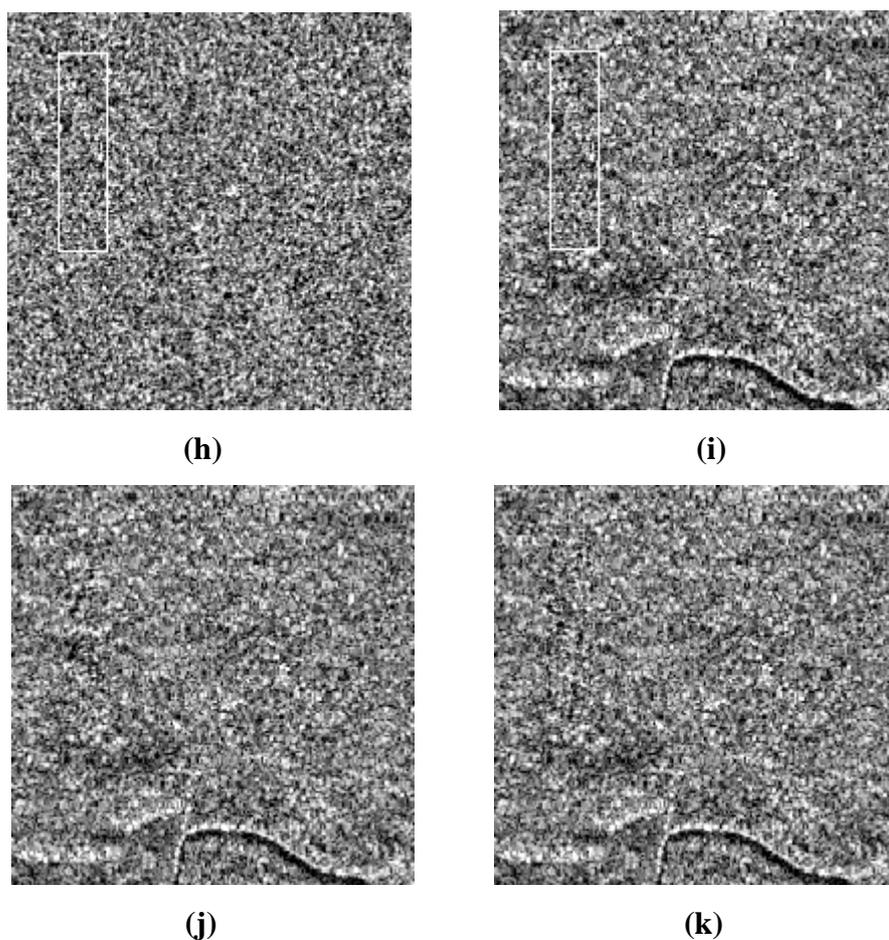
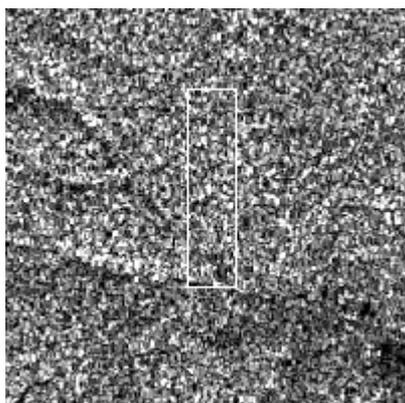


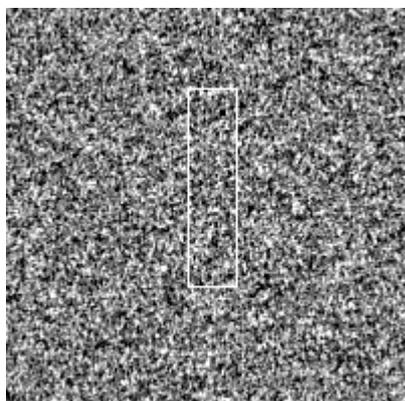
Fig. 4.41 - Conclusão - (h) Campo sintético - modelo φ_1 ; (i) Inserção do campo sintético; (j) Inserção do campo sintético - modelo α_1 - sem moldura; (k) Inserção do campo sintético - modelo β_1 - sem moldura.

TABELA 4.5 - CARACTERÍSTICAS DOS CAMPOS TEXTURADOS EM ESTUDO

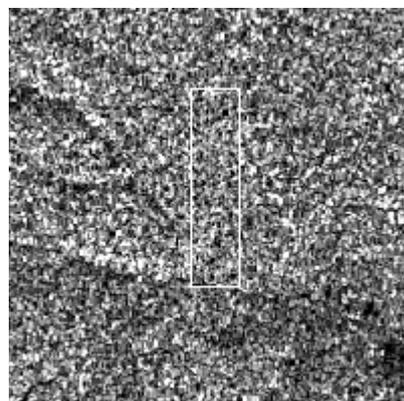
TIPO DE TEXTURA DA REGIÃO DE ESTUDO	MÉDIA	VARIÂNCIA
Imagem FTA Original	1048,19	129554
Modelo α_1 – ACF linear	1041,91	128782
Modelo ε_1 – ACF2D concatenada	1050,18	130050
Modelo β_1^3 – inverso transformação pela curva raiz cúbica	1047,63	131867
Modelo φ_1^3 – ACF2D concatenada e inverso da transformação pela curva raiz cúbica	1037,41	120141
Imagem FTA com transformação pela curva raiz cúbica	10,0256	1,34607
Modelo β_1 – ACF linear transformação pela curva raiz cúbica	10,0192	1,39662
Modelo φ_1 – ACF2D concatenada e transformação pela curva raiz cúbica	10,0727	1,38051



(a)

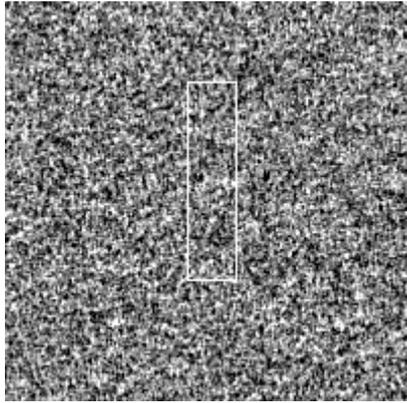


(b)

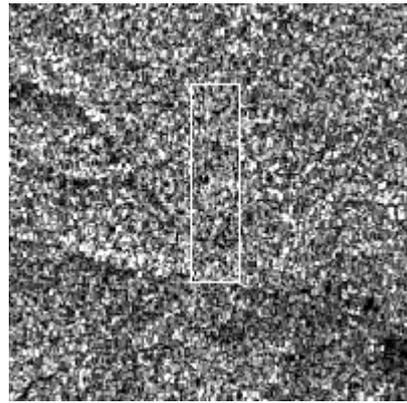


(c)

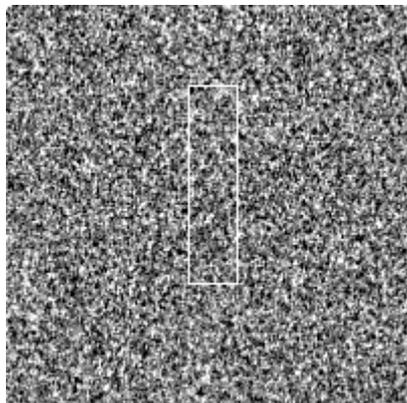
Fig. 4.42 - Seqüência de imagens para a avaliação do processo de síntese de texturas de imagens SAR da FTDP: (a) Imagem original; (b) Campo sintético - modelo γ_1 ; (c) Inserção do campo sintético (contínua);



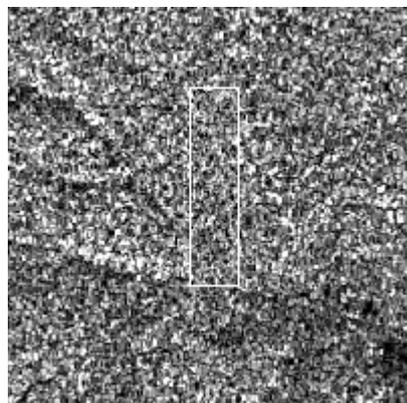
(d)



(e)



(f)



(g)

Fig. 4.42 -Continuação - (d) Campo sintético - modelo ϕ_1 ; (e) Inserção do campo sintético; (f) Campo sintético - modelo δ_1 ; (g) Inserção do campo sintético (continua);

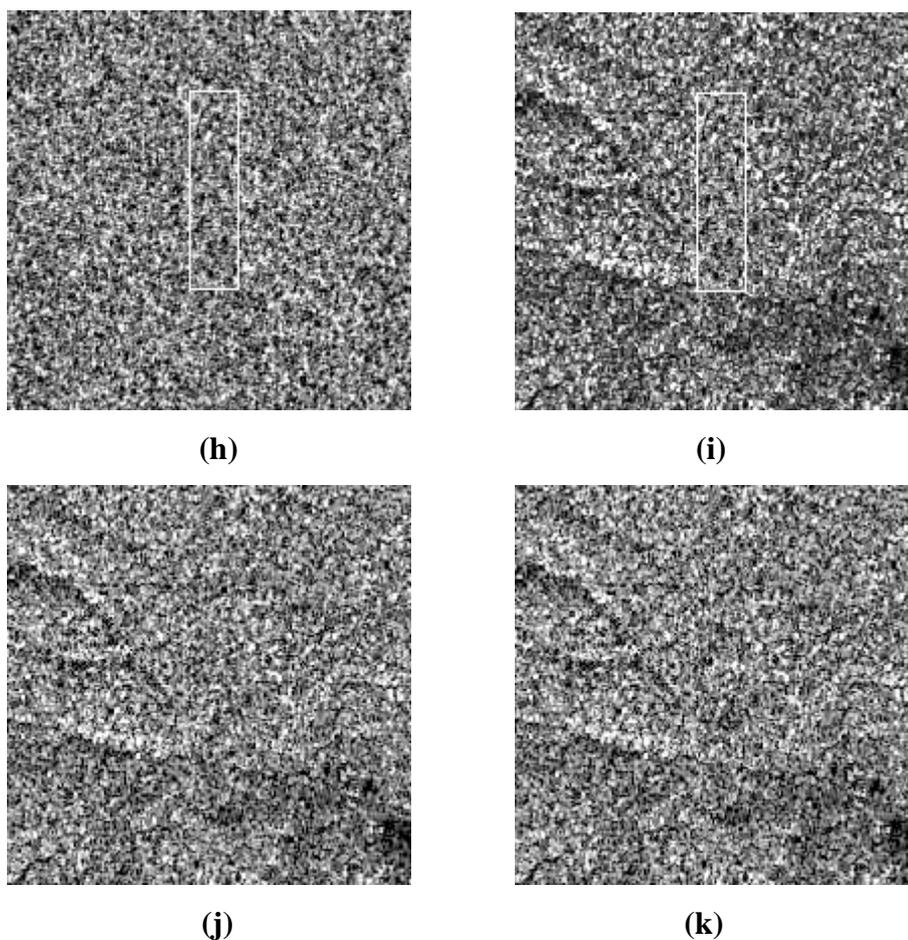


Fig. 4.42 -Conclusão - (h) Campo sintético - modelo η_1 ; (i) Inserção do campo sintético; (j) Inserção do campo sintético - modelo γ_1 - sem moldura; (k) Inserção do campo sintético - modelo δ_1 - sem moldura.

TABELA 4.6 - CARACTERÍSTICAS DOS CAMPOS TEXTURADOS EM ESTUDO

TIPO DE TEXTURA DA REGIÃO DE ESTUDO	MÉDIA	VARIÂNCIA
Imagem FTDP Original	1050,85	126855
Modelo γ_1 – ACF linear	1055,84	123769
Modelo δ_1 – ACF2D concatenada	1046,47	126417
Modelo ϕ_1^3 – inverso transformação pela curva raiz cúbica	1048,29	113301
Modelo η_1^3 – ACF2D concatenada e inverso da transformação pela curva raiz cúbica	1050,43	124173
Imagem FTDP com transformação pela curva raiz cúbica	10,1728	1,31052
Modelo ϕ_1 – ACF linear transformação pela curva raiz cúbica	10,0424	1,17862
Modelo η_1 – ACF2D concatenada e transformação pela curva raiz cúbica	10,0385	1,28886

4.2.1.3 Avaliação dos Resultados

A síntese de texturas para as imagens SAR apresentou resultados visualmente aceitáveis para todas as possibilidades em estudo, o que é um fator desejável e condição *sine qua*

non para a validade da metodologia. Foi observado, porém, um ligeiro melhor desempenho para os resultados obtidos utilizando o reescalonamento pela curva raiz cúbica e a ACF2D concatenada.

A própria natureza da definição de textura, em sua subjetividade, permite que o maior peso dado à avaliação de um resultado de síntese de textura seja a similaridade da textura sintética com a original, em termos visuais. Uma avaliação quantitativa, no entanto, é necessária e desejável, e poderia, a princípio, ser realizada ao se efetuar a comparação entre os momentos de segunda ordem dos campos texturados sintéticos com os das regiões de estudo, o que é visualizado na Tabela 4.5 e na Tabela 4.6. A comparação, outrossim, é limitada pela natureza do gerador de ruído branco, já que a rotina que emprega o algoritmo de Box-Müller (Park e Miller, 1988) não gera um ruído branco de média exatamente zero, nem de variância idêntica à variância do resíduo, induzindo, de certa forma, incorreções no processo de avaliação e permitindo tão somente uma estimativa inicial para a visualização da acuracidade dos resultados em um sentido amplo. Sua utilização, entretanto, atinge ao objetivo proposto, que é utilizar um algoritmo computacionalmente eficiente e de custo computacional viável que permitisse a implementação e teste do método proposto com um mínimo de incorreção, deixando a avaliação quantitativa a cargo de outro procedimento.

A fim de realizar uma avaliação quantitativa mais objetiva, utilizou-se o procedimento proposto na Seção 3.4.4, retransformando modelos AR2D em vetores de parâmetros AR de uma dimensão e calculando as distâncias euclidianas entre os vetores da modelagem resultante da textura original e da textura sintetizada.

A Tabela 4.7 ilustra os resultados alcançados para alguns dos modelos gerados a partir da textura da imagem da FTA (Figura 4.1.a), comparando-se as distâncias euclidianas entre os vetores obtidos a partir das texturas sintéticas e os diversos modelos existentes, incluindo imagens óticas (JERS e Landsat) e texturas de Brodatz.

Os modelos escolhidos para a comparação foram pinçados dentre cada uma das possibilidades de escolha de modelagem, ou seja:

- autorregressiva concatenada;
- autorregressiva com ACF2D concatenada;
- transformação pela curva raiz cúbica;
- recuperação de transformação pela raiz cúbica utilizando a inversa, ou seja, a terceira potência (cubo);
- transformação pela curva raiz cúbica com o uso da ACF2D concatenada;
- recuperação de transformação pela raiz cúbica utilizando a transformação pela sua inversa e a ACF2D concatenada.

A Tabela 4.8, por sua vez, ilustra os resultados para texturas sintéticas geradas a partir da imagem da FTDP (Figura 4.1.b), seguindo o mesmo critério de escolha dos modelos para comparação.

Nas tabelas apresentadas, as menores distâncias são apresentadas em itálico.

Em geral, percebe-se claramente que as distâncias são maiores para as texturas das outras imagens, mesmo para imagens do mesmo tipo (no caso, textura da outra imagem SAR em estudo), e nitidamente grandes para as imagens óticas, conforme o esperado, ou seja, as menores distâncias, as quais representam os modelos mais ajustados, permanecem sempre entre a imagem original e sua transformada cúbica e seus modelos correspondentes, ou seja, os campos sintéticos tendem a se aproximar da textura fonte, mesmo para o caso da recuperação da transformação pela raiz cúbica.

Os dados apresentados demonstram a provável validade do método em termos quantitativos, para as imagens SAR, já que as texturas sintéticas apresentaram-se sempre mais próximas da textura fonte que das demais texturas. Outro fator interessante é que, confirmando o que foi anteriormente verificado por Dutra (1990), as imagens de radar apresentaram pequenas diferenças entre os modelos das imagens das texturas teste, levando-se a crer que o ruído multiplicativo *speckle* mascara as texturas naturais

existentes, dificultando a diferenciação entre os modelos se o método for utilizado para classificação. Em termos de resultados para a síntese, no entanto, este fator adquire importância secundária, tendo em vista que as distâncias euclidianas foram capazes, ainda assim, de discriminar os modelos, e que os resultados visuais foram consistentes.

TABELA 4.7 - DISTÂNCIAS ENTRE MODELOS OBTIDOS A PARTIR DAS TEXTURAS SINTÉTICAS E TEXTURAS ORIGINAIS, PARA O PROCESSO DE MODELAGEM E SÍNTESE UTILIZANDO A TEXTURA EXISTENTE NA IMAGEM SAR DA FTA (Figura 4.1.a)

ORIGINAIS / SINTÉTICAS	FTA ORIGINAL	FTA – RAIZ CÚBICA	FTDP	JERS TOKYO	LANDSAT RIO	BRODATZ GRANITO	BRODATZ MÁRMORE
Modelo α_1	0,011	0,100	0,031	0,571	0,447	0,085	0,023
Modelo ε_1	0,049	0,138	0,068	0,609	0,410	0,122	0,061
Modelo β_1	0,164	0,075	0,145	0,394	0,624	0,091	0,152
Modelo β_1^3	0,129	0,040	0,110	0,430	0,589	0,056	0,117
Modelo φ_1	0,012	0,007	0,018	0,547	0,471	0,062	0,013
Modelo φ_1^3	0,026	0,006	0,058	0,533	0,485	0,046	0,014

Nota: Descrição dos Modelos Apresentados na Tabela 4.7:

Modelo α_1 – ACF linear

Modelo ε_1 – ACF2D concatenada

Modelo β_1 – ACF linear transformação pela curva raiz cúbica

Modelo β_1^3 – inverso transformação pela curva raiz cúbica (cubo)

Modelo φ_1 – ACF2D concatenada e transformação pela curva raiz cúbica

Modelo φ_1^3 – ACF2D concatenada e inverso da transformação pela curva raiz cúbica (cubo)

TABELA 4.8 - DISTÂNCIAS ENTRE MODELOS OBTIDOS A PARTIR DAS TEXTURAS SINTÉTICAS E TEXTURAS ORIGINAIS, PARA O PROCESSO DE MODELAGEM E SÍNTESE UTILIZANDO A TEXTURA EXISTENTE NA IMAGEM SAR DA FTDP (Figura 4.1.b)

ORIGINAIS / SINTÉTICAS	FTDP ORIGINAL	FTDP– RAIZ CÚBICA	FTA	JERS TOKYO	LANDSAT RIO	BRODATZ GRANITO	BRODATZ MÁRMORE
Modelo γ_1	0,012	0,084	0,031	0,528	0,491	0,041	0,019
Modelo ϕ_1	0,009	0,087	0,028	0,515	0,504	0,028	0,032
Modelo δ_1	0,189	0,093	0,209	0,350	0,668	0,135	0,197
Modelo δ_1^3	0,136	0,040	0,156	0,403	0,615	0,083	0,144
Modelo η_1	0,009	0,020	0,028	0,531	0,487	0,044	0,016
Modelo η_1^3	0,018	0,011	0,037	0,522	0,496	0,035	0,025

Nota: Descrição dos Modelos Apresentados na Tabela 4.8:

Modelo γ_1 – ACF linear

Modelo δ_1 – ACF2D concatenada

Modelo ϕ_1 – ACF linear transformação pela curva raiz cúbica

Modelo ϕ_1^3 – inverso transformação pela curva raiz cúbica (cubo)

Modelo η_1 – ACF2D concatenada e transformação pela curva raiz cúbica

Modelo η_1^3 – ACF2D concatenada e inverso da transformação pela curva raiz cúbica (cubo)

4.2.1.3.1 Comparação entre os Resultados Obtidos por Texturas Gaussianizadas e Não Gaussianizadas

Devido às peculiaridades inerentes às imagens SAR, decidiu-se aplicar a transformação pela curva raiz cúbica com o intuito de tornar o histograma das imagens de radar mais parecido com a gaussiana, antes do processo de modelagem, e efetuar-se a restauração, posteriormente, realizando-se a operação inversa sobre os dados sintetizados.

Este conjunto de operações permite que os resíduos obtidos sejam mais próximos de ruídos brancos gaussianos, conforme os histogramas apresentados na Figura 4.43, o que é altamente desejável, já que os ruídos brancos motores de processos ARMA tem esta característica como parte de sua formulação, conforme a Seção 2.6. A gaussianização dos resíduos ocorre porque seu histograma mantém o comportamento observado em sua imagem geradora, ou seja, o comportamento do histograma não é afetado no processo de filtragem.

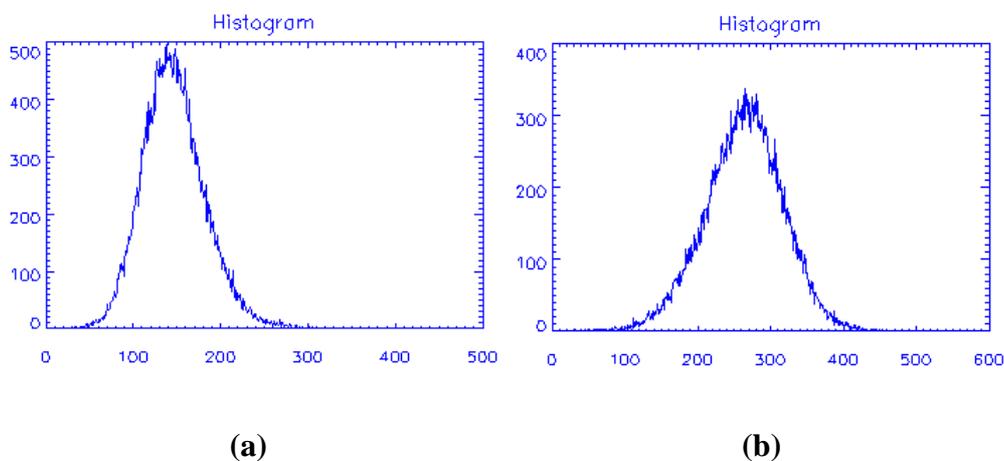


Fig. 4.43 - Histograma dos resíduos obtidos a partir do modelos: (a) α_1 - imagem FTA original (Figura 4.1.a); (b) β_1 - imagem FTA com reescalonamento pela raiz cúbica (Figura 4.2).

A Figura 4.41 e a Figura 4.42 mostram que o comportamento visual dos campos sintéticos é semelhante para os campos obtidos a partir das imagens transformadas e não transformadas, mesmo levando em conta a recuperação pela cúbica, já que o

comportamento visual desta última é idêntico à sua versão geradora, obtida pela transformada cúbica.

A Tabela 4.7 e Tabela 4.8 também mostram que, embora sejam os valores mais ajustados para a sua classe (linhas das tabelas, para os modelos β e δ), em comparação com as outras texturas, os modelos que se utilizaram tão somente da curva raiz cúbica não foram capazes de rivalizar, se for analisado o ajuste dos modelos como um todo, com os modelos que se utilizaram dos dados não transformados ou, se transformados, utilizaram-se, de forma adicional, da ACF2D concatenada, não importando se se utilizaram da recuperação cúbica ou não. Em outras palavras, os modelos mais ajustados tendem a ficar entre os não transformados (utilizando ou não ACF2D concatenada) e transformados que se utilizaram adicionalmente da ACF2D concatenada (2^o. método).

O bom desempenho dos modelos que se utilizassem da ACF2D concatenada já era esperado e é discutido na próxima Seção (4.2.1.3.2), porém a transformação pela curva raiz cúbica parece contribuir em maior grau se o resíduo se apresentar mais branco, proporcionando a aproximação adicional com a gaussiana que melhora o desempenho do ruído branco motor. Resumindo, pode-se dizer que o método parece ser muito mais afetado pela característica de branqueamento do resíduo, influenciado pelas correlações, que pelo comportamento gaussiano do histograma. Pode-se imaginar, então, o pré-processamento pela curva raiz cúbica como uma técnica adicional de modelagem a ser aplicada em conjunto com o método utilizando a ACF2D concatenada, a fim de proporcionar um ruído *branco* e *gaussiano* a partir do resíduo, e não como um procedimento isolado.

4.2.1.3.2 Comparação entre os Métodos de Modelagem Autorregressiva

Conforme o descrito na Seção 3.2.2, o objetivo da utilização de dois métodos de modelagem autorregressiva é a tentativa de viabilizar a utilização de um método que evite a acumulação de valores errôneos quando do cálculo da função de autocorrelação sobre a série concatenada, permitindo-se uma modelagem mais correta e se evitando

correlações indesejadas. Em outras palavras, busca-se um melhor ajuste do modelo aos dados, permitindo-se que os resíduos fiquem mais brancos.

Em relação aos modelos estimados, verificou-se, de fato, que os resíduos dos modelos AR2D que se utilizaram da ACF2D concatenada para a estimação dos parâmetros autorregressivos tenderam a gerar resíduos mais próximos de ruídos brancos, conforme o mostrado na Figura 4.22. Observe-se que os modelos ε_1 para FTA (c) e ϕ_1 para FTDP (e) apresentam-se quase que integralmente dentro dos limites do intervalo de confiança, enquanto os modelos gerados a partir do uso convencional da ACF ainda apresentam algumas correlações indesejadas, embora sejam suficientemente brancos a ponto de viabilizar o processo de modelagem. Este comportamento da modelagem utilizando a ACF2D concatenada tendeu a ser constante e suficientemente estável.

Uma das maiores expectativas de geração dos melhores modelos era a combinação de modelos que se utilizassem da curva raiz cúbica em conjunto com a ACF2D concatenada, tendo em vista que a gaussianização da imagem proporcionada pela transformação pela curva raiz cúbica proporciona um resíduo mais próximo à gaussiana, enquanto a ACF2D concatenada evita as correlações indesejadas, gerando um resíduo mais branco, características altamente desejáveis pertinentes à definição do ruído branco motor para processos ARMA.

De fato, embora os modelos mais ajustados oscilassem entre os modelos não transformados pela raiz cúbica que se utilizavam dos dois métodos de estimação de parâmetros e os modelos utilizando a combinação ACF2D-raiz cúbica, com e sem recuperação pela inversa, conforme a Tabela 4.7 (modelos α_1 , ε_1 , ϕ_1 e ϕ_1^3) e a Tabela 4.8 (γ_1 , ϕ_1 , η_1 e η_1^3), observou-se uma alternância entre os dois métodos não transformados, se observados isoladamente, que não permite apontar uma tendência definitiva de predominância de um método de modelagem sobre o outro, quanto à aplicação isolada da ACF2D concatenada. A combinação ACF2D-raiz cúbica, no entanto, rivalizou costumeiramente com os modelos não transformados de melhor performance para cada caso estudado, ou seja, apresentou uma certa constância de

resultados quantitativos que é justificada pela sua formulação matemática mais elaborada. Outro fato interessante que merece ser investigado em profundidade é que, ao ser feita a modelagem utilizando o reescalonamento pela raiz cúbica, tende-se a obter um número menor de parâmetros, podendo vir a ser considerado um método que facilita a parcimônia.

Em termos de resultados visuais, no entanto, não houve comportamento diferenciado aparente em termos visuais entre os campos sintéticos gerados a partir de cada um dos métodos, conforme observado na Figura 4.41 e na Figura 4.42. Aparentemente, o ajuste dos modelos, observado a partir das distâncias euclidianas, comportou-se dentro de um intervalo de confiança suficientemente aproximado a ponto de permitir a síntese dos campos texturados dentro do envelope de satisfação da percepção visual.

A modelagem utilizando a ACF linear justifica-se, entretanto, para a utilização em imagens que necessitem de grandes áreas de treinamento, em virtude da natureza e organização da textura fonte, já que o algoritmo que realiza a estimação utilizando a ACF linear é de ordem menos elevada que o método da ACF2D. Tal fato leva a imaginar que, para uma área de treinamento de n colunas e m linhas de valores elevados, a utilização da ACF linear é bastante atrativa, se o resultado esperado for de natureza prioritariamente visual, já que este apresenta um custo computacional consideravelmente menor se comparado ao cálculo da ACF2D. A título de exemplo, utilizando-se um microcomputador Packard-Bell Intel Pentium 133 MHz, 32 MB RAM, necessitou-se de 6,97 e 29,12 segundos para a estimação de modelos AR(75), utilizando, respectivamente, a ACF linear e a ACF2D concatenada, em uma área de treinamento de 25 colunas e 100 linhas. Ao se aumentar a área de treinamento para 101 colunas, mantendo as 100 linhas, os resultados foram de 7,36 segundos para o método que se utiliza da ACF linear e 973,17 segundos para o método que se utiliza da ACF2D concatenada, mostrando o progressivo aumento do custo computacional deste último método em relação ao crescimento da área de treinamento.

4.2.2 Imagens Óticas Landsat-5 e JERS-1

O processo de síntese de campos texturados a partir dos modelos estimados para as imagens óticas obtidas de satélites Landsat-5 (Rio de Janeiro) e JERS-1(Tokyo) mostradas na Figura 4.23 foi mais simples que a síntese de texturas de imagens SAR, uma vez que a distribuição do histograma das imagens já é, originalmente, próxima à gaussiana, tornando desnecessários qualquer processamento ou transformação prévios neste sentido. A resolução das imagens, no entanto, é nitidamente mais pobre, principalmente para imagens Landsat, o que dificultou a obtenção de modelos mais ajustados. Os métodos, no entanto, aparentaram ser capazes de obtenção de resultados eficientes ainda que as texturas fonte tivessem uma resolução reduzida se comparada a imagens SAR.

4.2.2.1 Regeneração das Imagens Fonte

O mesmo processo de regeneração das imagens fonte foi aplicado às imagens óticas, com objetivos idênticos aos descritos na Seção 4.2.1.1, no que tange à verificação da precisão do algoritmo e ajuste dos modelos, aplicando a seqüência de filtragem inversa/direta.

Os modelos demonstraram seu nível de ajuste, ao serem capazes de regenerar as imagens fonte, da mesma forma que o anteriormente visto para as imagens SAR.

4.2.2.2 Geração de Texturas a Partir de Campo Aleatório Branco

O passo seguinte, após a regeneração das imagens fonte, foi a geração de ruídos brancos bidimensionais (campos brancos) de momentos de segunda ordem semelhantes aos momentos dos resíduos, procedendo a aplicação do filtro MA2D em ordem direta e tendo o campo texturado sintético como resultado.

Tal qual o visto na Seção 4.2.1.2, o campo branco de mesmo *ensemble* foi gerado como o ruído branco motor do processos AR2D, utilizando os coeficientes estimados para

obtenção de campos texturados sintéticos similares às regiões de estudo, adicionando-se a média da região. A Figura 4.44 mostra os resultados obtidos para a imagem de Tokyo (Figura 4.23.a). No caso da imagem do Rio de Janeiro (Figura 4.23.b), os resultados foram apresentados na Figura 4.45.

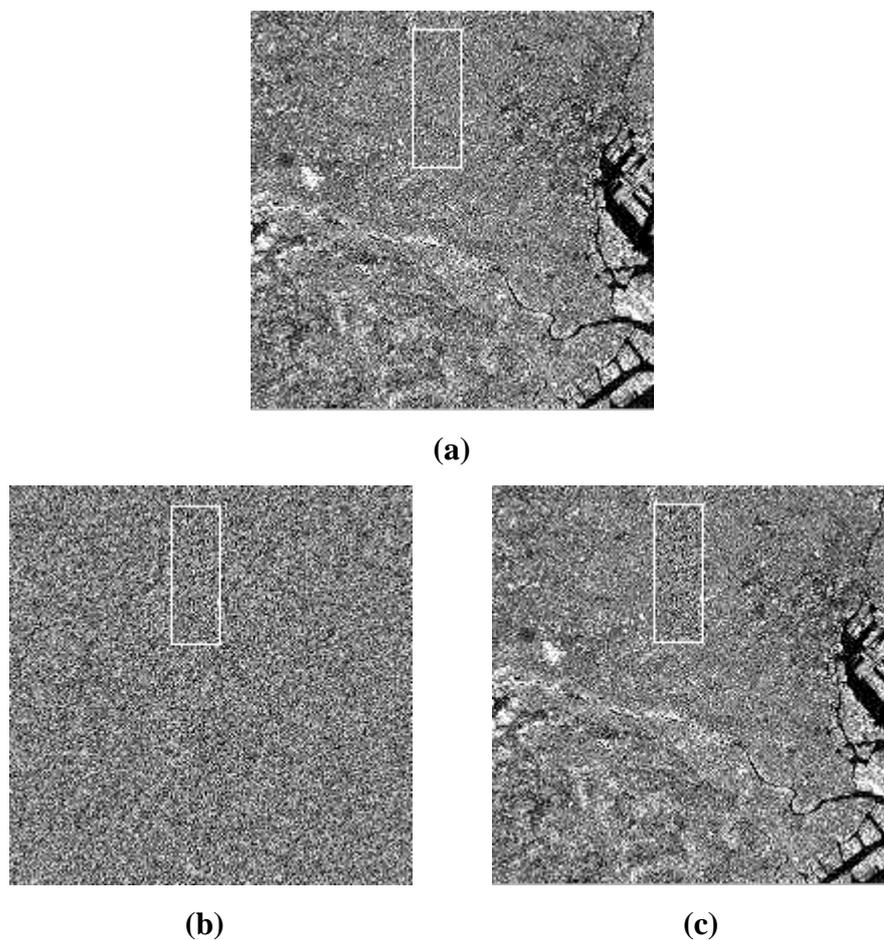
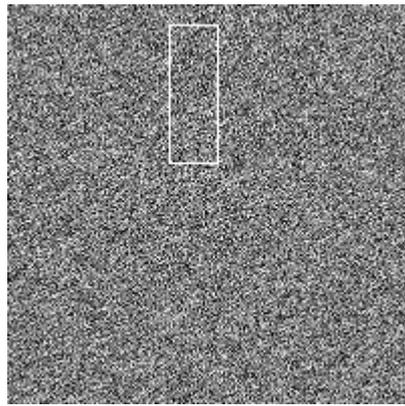
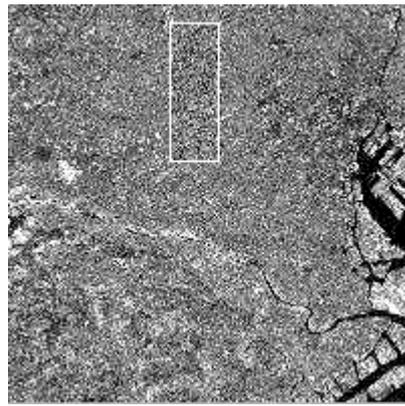


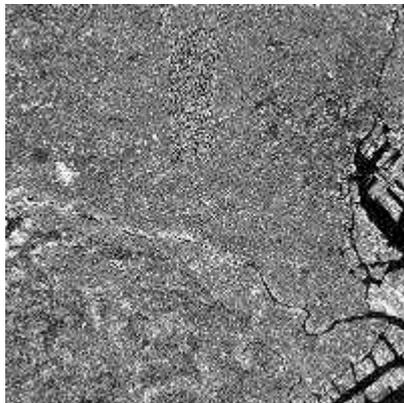
Fig. 4.44 - Sequência de imagens para a avaliação do processo de síntese de texturas da imagem ótica JERS de Tokyo: (a) Imagem original; (b) Campo sintético – modelo λ ; (c) Inserção do campo sintético (continua);



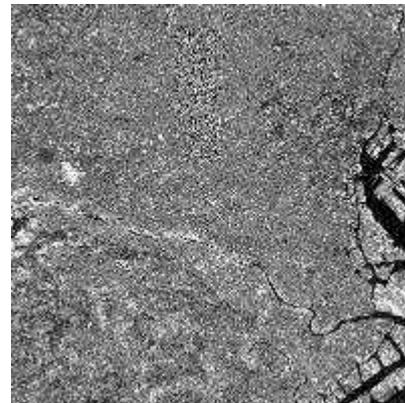
(d)



(e)

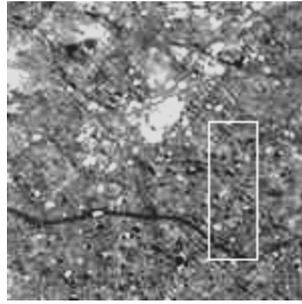


(f)

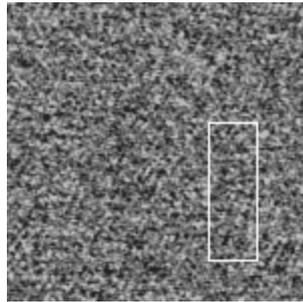


(g)

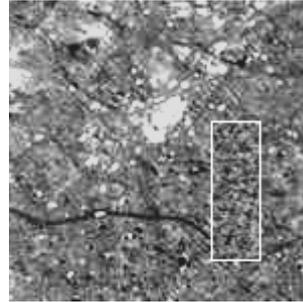
Fig. 4.44 - Continuação - (d) Campo sintético - modelo μ ; (e) Inclusão do campo sintético; (f) Inclusão do campo sintético - modelo λ - sem moldura; (g) Inclusão do campo sintético - modelo μ - sem moldura.



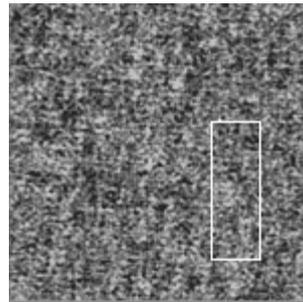
(a)



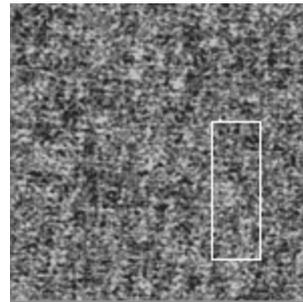
(b)



(c)



(d)



(e)

Fig. 4.45 - Seqüência de imagens para a avaliação do processo de síntese de texturas de imagens óticas Landsat: (a) Imagem original; (b) Campo sintético - modelo π ; (c) Inserção do campo sintético; (d) Campo sintético - modelo τ ; (e) Inserção do campo sintético (continua).

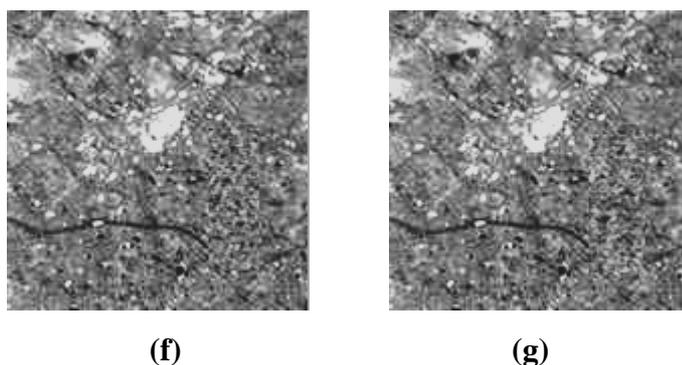


Fig. 4.45 -Continuação - (f) Inserção do campo sintético - modelo π - sem moldura; (g) Inserção do campo texturado sintético - modelo τ - sem moldura.

As texturas sintetizadas a partir de imagens óticas também foram capazes de produzir bons resultados visuais, tais quais as texturas sintetizadas a partir de imagens SAR. O resultado visual para a imagem JERS-1 de Tokyo foi claramente melhor, como era de se esperar, tendo em vista a maior resolução e uniformidade da região de estudo, se comparada à imagem Landsat-5 do Rio de Janeiro.

A avaliação quantitativa foi realizada de maneira semelhante que para as imagens de radar, seguindo os mesmos procedimentos para cálculo das distâncias euclidianas entre os vetores autorregressivos que mensuraram o ajuste relativo dos modelos, de acordo com a Seção 3.4.4.

A Tabela 4.9 ilustra os resultados alcançados para alguns dos modelos gerados a partir da textura da imagem JERS-1 de Tokyo (Figura 4.23.a), comparando-se as distâncias euclidianas entre diversos vetores de parâmetros AR, retransformados a partir de modelos AR2D sintéticos.

A Tabela 4.10 consolida os resultados para a imagem Landsat-5 da cidade de Rio de Janeiro (Figura 4.23.b), obtidos segundo a aplicação dos dois métodos em estudo, seguindo o mesmo padrão de comparação que fora aplicado para a imagem JERS-1 de Tokyo.

A tendência genérica de aproximação da textura sintética à textura fonte, com a obtenção de menores distâncias euclidianas e, conseqüentemente, de modelos mais ajustados, manteve-se, demonstrando quantitativamente a validade do método.

A resolução mais pobre e menor uniformidade da textura da imagem Landsat-5 aparentemente contribuiu para que os modelos associados aos campos sintéticos desta fossem relativamente menos ajustados (Tabela 4.10), se comparados aos resultados do ajuste dos modelos obtidos para as imagens JERS-1 (Tabela 4.9).

TABELA 4.9 - DISTÂNCIAS ENTRE MODELOS OBTIDOS A PARTIR DAS TEXTURAS SINTÉTICAS E TEXTURAS ORIGINAIS, PARA O PROCESSO DE MODELAGEM E SÍNTESE UTILIZANDO TEXTURA EXISTENTE NA IMAGEM ÓTICA JERS-1 DE TOKYO (Figura 4.23.a)

ORIGINAIS / SINTÉTICAS	JERS TOKYO	LANDSAT RIO	SAR FTA	SAR FTDP	BRODATZ GRANITO	BRODATZ MÁRMORE
Modelo λ	0,020	1,023	0,561	0,580	0,507	0,568
Modelo μ	0,006	0,996	0,534	0,553	0,480	0,541

Nota: Descrição dos Modelos Apresentados na Tabela 4.9:

Modelo λ – ACF linear

Modelo μ – ACF2D concatenada

TABELA 4.10 - DISTÂNCIAS ENTRE MODELOS OBTIDOS A PARTIR DAS TEXTURAS SINTÉTICAS E TEXTURAS ORIGINAIS, PARA O PROCESSO DE MODELAGEM E SÍNTESE UTILIZANDO TEXTURA EXISTENTE NA IMAGEM LANDSAT-5 DO RIO DE JANEIRO (Figura 4.23.b)

ORIGINAIS / SINTÉTICAS	LANDSAT RIO	JERS TOKYO	SAR FTA	SAR FTDP	BRODATZ GRANITO	BRODATZ MÁRMORE
Modelo π	0,066	0,936	0,376	0,396	0,449	0,388
Modelo τ	0,051	0,951	0,391	0,410	0,464	0,403

Nota: Descrição dos Modelos Apresentados na Tabela 4.10:

Modelo π – ACF linear

Modelo τ – ACF2D concatenada

A aplicação dos dois métodos de estimação ante as imagens óticas produziu resultados quantitativos melhores para as texturas sintetizadas a partir do segundo método, confirmando de certa forma a expectativa teórica de obtenção de melhores produtos para esta abordagem.

A Tabela 4.9 e a Tabela 4.10 mostram os melhores ajustes de modelos que se utilizaram do segundo método, tendo em vista que, nos casos estudados, apresentaram as menores distâncias euclidianas para a textura fonte (modelos μ e τ).

O comportamento visual para os resultados dos dois métodos, tanto na imagem JERS quanto na imagem Landsat, no entanto, foram semelhantes entre si, tal qual para as imagens SAR, o que reforça a idéia de que os resultados para o primeiro método, embora mais pobres quantitativamente, encontram-se dentro de um intervalo de confiança que permite a obtenção de resultados visuais convincentes.

4.2.3 Texturas de Brodatz

Os métodos de síntese também foram empregados para a geração de campos sintéticos a partir de texturas naturais semelhantes às encontradas no álbum de Brodatz (1966). Conforme o anteriormente citado na Seção 4.1.3, o uso da transformação pela curva raiz cúbica também não foi o caso para este método, o que simplificou o processo de síntese, de maneira similar ao que ocorreu com as imagens óticas.

4.2.3.1 Regeneração das Imagens Fonte

Assim como havia sido aplicado à imagens SAR e óticas, processo de regeneração das texturas fonte foi aplicado às imagens contendo as texturas naturais granito e mármore, para verificação da acuracidade do algoritmo e ajuste dos modelos. Tal processo de regeneração da textura original novamente envolveu a seqüência composta pela filtragem inversa e posterior filtragem direta a partir dos resíduos.

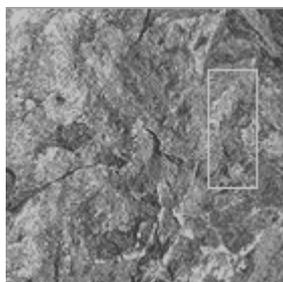
Os modelos obtidos para as texturas de Brodatz também demonstraram ser capazes de regenerar as texturas originais, da mesma forma que o anteriormente visto para as imagens SAR e óticas, coroando o ajuste do processo de modelagem e a exatidão do algoritmo.

4.2.3.2 Geração de Texturas a Partir de Campo Aleatório Branco

A geração dos ruídos brancos bidimensionais procedeu a aplicação do filtro em ordem direta, com o intuito de obter posteriormente campos texturados sintéticos. O processo de geração de texturas foi realizado utilizando os mesmos procedimentos anteriormente aplicados para as imagens SAR e óticas.

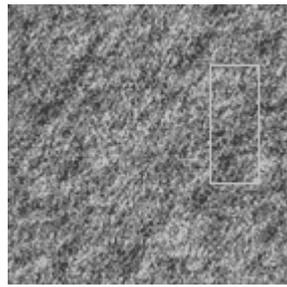
Os ruídos brancos bidimensionais foram utilizados como ruídos brancos motores dos processos AR2D, utilizando os modelos estimados, obtendo-se os campos texturados sintéticos, tendo-se o cuidado de se adicionar a média da região de estudo utilizada como fonte para a estimação.

Em termos de resultados visuais, a Figura 4.46 contém os resultados visuais obtidos para a textura granito da Figura 4.32.a. No caso da textura mármore da Figura 4.32.b, os resultados foram sumarizados na Figura 4.47.

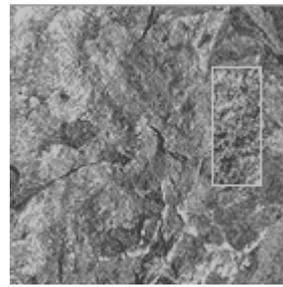


(a)

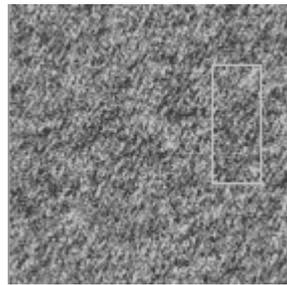
Fig. 4.46 - Seqüência de imagens para a avaliação do processo de síntese de texturas naturais da classe granito: (a) Imagem original (continua).



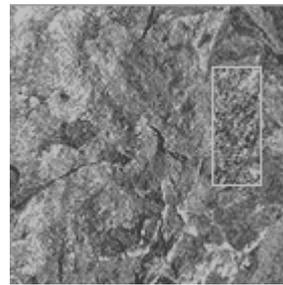
(b)



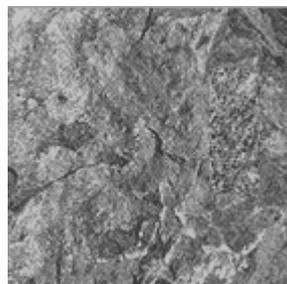
(c)



(d)



(e)

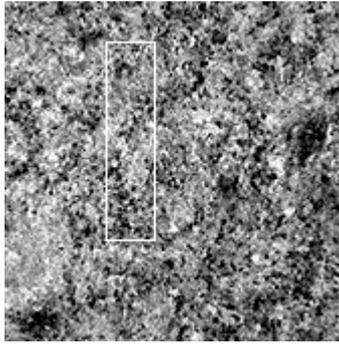


(f)

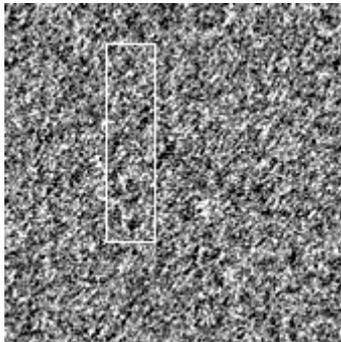


(g)

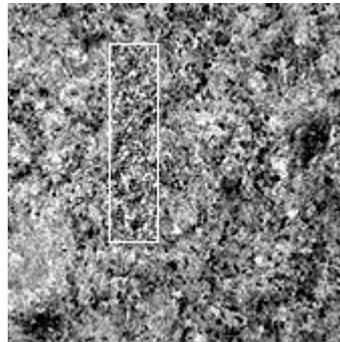
Fig. 4.46 - Continuação -(b) Campo sintético - modelo ω ; (c) Inserção do campo sintético; (d) Campo sintético - modelo ρ ; (e) Inserção do campo sintético; (f) Inserção do campo sintético - modelo ω - sem moldura; (g) Inserção do campo sintético - modelo ρ - sem moldura.



(a)



(b)



(c)

Fig. 4.47 - Seqüência de imagens para a avaliação do processo de síntese de texturas naturais da classe mármore: (a) Imagem original; (b) Campo sintético - modelo ψ ; (c) Inclusão do campo sintético (continua).

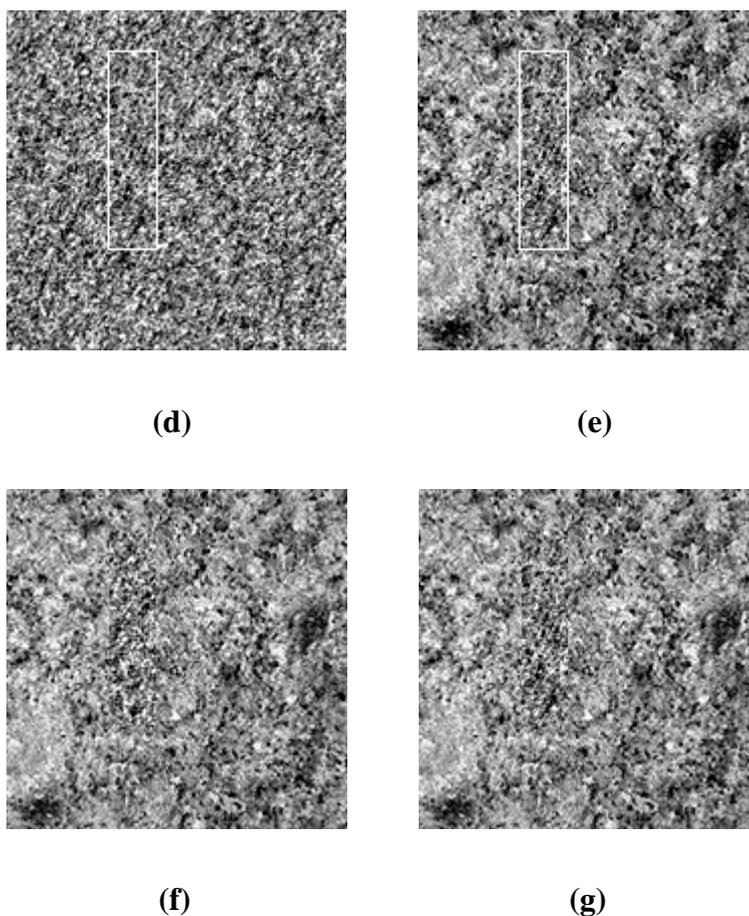


Fig. 4.47 - Continuação - (d) Campo sintético - modelo θ ; (e) Inclusão do campo sintético; (f) Inclusão do campo sintético - modelo ψ - sem moldura; (g) Inclusão do campo sintético - modelo θ - sem moldura.

A textura natural mármore obteve um melhor resultado visual, por ser mais uniforme. A modelagem da textura granito, entretanto, também produziu bons resultados.

Para a materialização dos resultados, procedeu-se a avaliação quantitativa, calculando-se as distâncias euclidianas entre os vetores autorregressivos e mensurando o ajuste dos modelos. A Tabela 4.11 ilustra os resultados alcançados para a mensuração das distâncias euclidianas entre os vetores de parâmetros AR obtidos a partir de campos sintéticos cuja fonte é a textura natural granito (Figura 4.32.a) e modelos obtidos a partir das texturas fonte granito, mármore, imagens óticas JERS e Landsat, e imagens SAR. Por sua vez, a Tabela 4.12 consolida resultados obtidos para a textura natural mármore (Figura 4.32.b).

As texturas naturais produziram resultados quantitativos que evidenciaram o ajuste dos campos sintéticos obtidos de texturas naturais às respectivas texturas fonte, em detrimento à aproximação dos modelos obtidos a partir de outras imagens. Em outras palavras, as distâncias euclidianas apresentaram valores menores para os pares compostos pela textura fonte e sintética de uma mesma classe.

TABELA 4.11 - DISTÂNCIAS ENTRE MODELOS OBTIDOS A PARTIR DAS TEXTURAS SINTÉTICAS E TEXTURAS ORIGINAIS, PARA O PROCESSO DE MODELAGEM E SÍNTESE UTILIZANDO TEXTURA NATURAL GRANITO (Figura 4.32.a)

ORIGINAIS / SINTÉTICAS	BRODATZ GRANITO ORIGINAL	BRODATZ MÁRMORE	SAR – FTA	SAR – FTDP	JERS TOKYO	LANDSAT RIO
Modelo ω	0,020	0,041	0,053	0,033	0,506	0,512
Modelo ρ	0,001	0,059	0,071	0,052	0,488	0,531

Nota: Descrição dos Modelos Apresentados na Tabela 4.11:

Modelo ω – ACF linear

Modelo ρ – ACF2D concatenada

TABELA 4.12 - DISTÂNCIAS ENTRE MODELOS OBTIDOS A PARTIR DAS TEXTURAS SINTÉTICAS E TEXTURAS ORIGINAIS, PARA O PROCESSO DE MODELAGEM E SÍNTESE UTILIZANDO TEXTURA NATURAL MÁRMORE (Figura 4.32.b)

ORIGINAIS / SINTÉTICAS	BRODATZ MÁRMORE ORIGINAL	BRODATZ GRANITO	SAR – FTA	SAR – FTDP	JERS TOKYO	LANDSAT RIO
Modelo ψ	0,020	0,084	0,028	0,021	0,571	0,448
Modelo θ	0,012	0,048	0,064	0,056	0,535	0,483

Nota: Descrição dos Modelos Apresentados na Tabela 4.12:

Modelo ψ – ACF linear

Modelo θ – ACF2D concatenada

Assim como as imagens óticas Landsat e JERS, as texturas de Brodatz também apresentaram a tendência de menores distâncias euclidianas em relação à textura fonte para o método utilizando a ACF2D, novamente mostrando a tendência a bom desempenho deste método para texturas uniformes e com histogramas aproximados da gaussiana. A Tabela 4.11 e a Tabela 4.12 reforçam estas afirmações, quando da comparação dos ajustes entre os modelos obtidos a partir dos campos sintéticos e a textura original (1^a. coluna).

Assim como em todos os resultados anteriores, o comportamento visual aceitável e semelhante para os resultados de ambos os métodos reafirma a idéia da existência de um intervalo de confiança que permite a obtenção de resultados visuais convincentes para as duas formas de modelagem autorregressiva, o que permite a implementação de quaisquer um destes se o requisito de uma determinada aplicação for apenas visual e não quantitativo, para texturas sintéticas em computação gráfica. De fato, foi observada a constatação prática de que é sempre possível ajustar-se mais de um modelo para um certo conjunto de dados, tendo em vista que, sendo finito o conjunto de dados, também o são a ACF e a PACF (Dutra, 1990).

4.2.3.3 Exemplos Suplementares de Síntese de Texturas Utilizando Texturas com Componentes Levemente Determinísticos

Alguns exemplos suplementares contendo texturas naturais com componentes levemente estruturados são apresentadas na Figura 4.48. O método procura visivelmente adaptar-se a estas estruturas, embora sejam determinísticas.

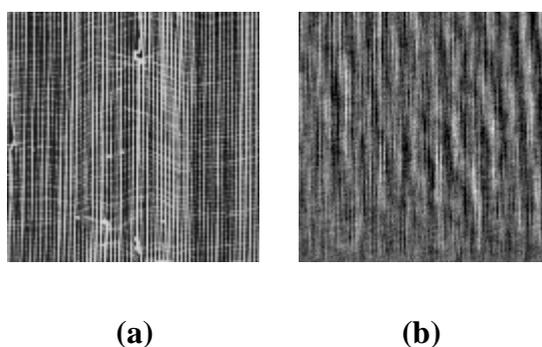
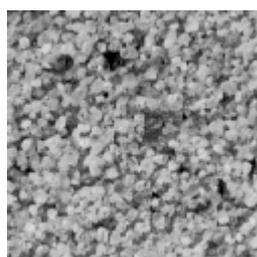
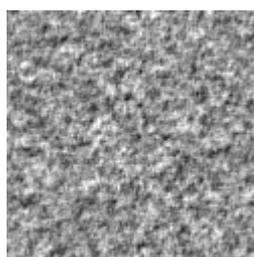


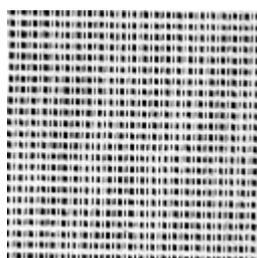
Fig. 4.48 - Texturas levemente determinísticas e campos sintéticos: tecido natural (a) e sintético (b) (continua).



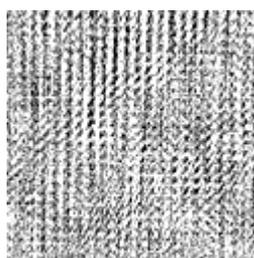
(c)



(d)



(e)



(f)

Fig. 4.48 - Conclusão - pedras (natural) (c) e sintética (d); trançado natural (e) e sintético (f).

Conforme o esperado, entretanto, texturas naturais que apresentavam componentes determinísticos muito fortes não se mostraram convenientes para a aplicação do método e não são apresentadas.

CAPÍTULO 5

CONCLUSÕES E SUGESTÕES

O presente trabalho teve por escopo métodos para a geração sintética de texturas de aparência natural capazes de utilização em cenas de aparência realística, semelhantes a texturas fonte previamente selecionadas. A conceituação adotada para textura foi a de um campo aleatório homogêneo localmente estruturado, ou seja, sua intensidade em um dado pixel é uma função probabilística das intensidades dos pixels localizados na vizinhança. A base dos métodos utilizados concentrou-se, então, em modelos estatísticos de síntese de texturas, especificamente no uso de modelos ARMA para a estimativa de parâmetros e geração dos padrões de texturas a partir de regeneração.

Dois métodos de estimativa de parâmetros foram utilizados, ambos baseados em modelos puramente autorregressivos. O primeiro método utiliza a concatenação de linhas e colunas da imagem da textura analisada. É um modelo AR unidimensional, de natureza causal, que estima os parâmetros iniciais e a ordem do modelo a partir das funções de autocorrelação e autocorrelação parcial da série concatenada, posteriormente utilizando um algoritmo para mapeamento em coordenadas bidimensionais. O outro método implementado utiliza uma função de autocorrelação bidimensional concatenada, evitando a acumulação de erros resultante de correlações indesejadas geradas pela concatenação simples das linhas e colunas da imagem, obtendo uma seqüência linear. Os resíduos de cada modelo foram calculados, a fim de verificar sua adequação, permitindo a obtenção do ruído branco motor da síntese.

Para a síntese, o processo consistiu na geração de um de ruído aleatório de média zero e mesma variância dos resíduos obtidos a partir da modelagem estatística, aplicado como entrada do processo AR2D obtido pela modelagem. Imaginou-se as texturas original e sintética como realizações do *ensemble* de texturas que caracteriza o modelo estatístico, o que provou ser uma assunção apropriada.

Para as imagens SAR, os métodos utilizaram-se de pré-processamento pela aplicação da curva raiz cúbica com o intuito de apresentar uma distribuição mais parecida com a gaussiana. O uso da curva raiz cúbica parece ser uma técnica adicional de modelagem conveniente, se em conjunto com o método utilizando a ACF2D concatenada.

Ainda com relação aos resultados das imagens de radar, estas apresentaram pequena diferença entre os modelos obtidos a partir das diferentes texturas fonte, especulando-se que o ruído *speckle* mascara as texturas naturais existentes. Em termos quantitativos, os modelos SAR mais ajustados tendem a ficar entre os não transformados pela curva raiz cúbica e transformados que se utilizaram adicionalmente da ACF2D concatenada.

A combinação ACF2D com transformação raiz cúbica, outrossim, apresentou uma constância de bons resultados quantitativos, devido à formulação matemática mais elaborada. Para os outros tipos de imagens, o método de estimação de parâmetros que se utilizava da autocorrelação bidimensional concatenada tendeu a apresentar os melhores resultados e modelos quantitativamente mais ajustados.

Com relação a verificação do ajuste dos modelos, o observado foi que a autocorrelação dos resíduos obtidos para as imagens fonte se manteve dentro dos valores limites do intervalo de confiança, ou próximos, apresentando correlações significativas tão somente no *lag* 0, mostrando que os métodos tendem a gerar modelos ajustados às texturas de origem. Os resíduos obtidos, submetidos à filtragem direta, também foram capazes de regenerar as imagens originais, salvo imperfeições numéricas, demonstrando a exatidão dos algoritmos de filtragem inversa/direta e o nível de ajuste dos modelos.

A síntese de texturas apresentou resultados visualmente aceitáveis para todas as possibilidades em estudo. Os resultados quantitativos também mostraram que ambos os métodos de modelagem produziram resultados ajustados à textura fonte, a partir do cálculo das distâncias euclidianas, embora o segundo método (ACF2D concatenada) pareça ser ligeiramente mais ajustado. O uso do método que se utiliza da ACF linear, entretanto, é útil para a modelagem de regiões grandes, já que seu custo computacional é menor e a execução do algoritmo mais veloz. Recomenda-se, entretanto, a utilização da

concatenação da ACF2D, a menos que se esteja modelando texturas muito organizadas, já que, para este caso, há necessidade de se escolher regiões de estudo de grande número de linhas e colunas, onde o método de ACF linear tem melhor performance.

Os métodos demonstraram que podem gerar texturas de forma compacta, utilizando filtros estimados cuja ordem é pequena, ou seja, de reduzida complexidade de cálculo e custo computacional normalmente aceitável. Outro fator interessante é a melhoria progressiva do modelo, que pôde iniciar implementando formas mais simples, com regiões de estudo menores, testá-las e, a partir daí, estabelecer abordagens mais complexas que permitam melhor estimativa de parâmetros do filtro para síntese.

Finalmente, foi desenvolvido um programa com interface gráfica para o usuário (GUI) capaz de operar em ambiente Motif (sistema operacional Unix) e Windows 95/NT, desenvolvido em linguagem IDL, implementando todas as funcionalidades necessárias para que o objetivo do trabalho fosse alcançado. O programa é composto por 44 módulos e é facilmente extensível, além de possuir uma descrição de funcionalidades em tempo de execução.

Para trabalhos futuros, podem ser consideradas as seguintes sugestões:

- Implementação de um método de estimação autorregressiva verdadeiramente bidimensional utilizando suporte de quarto de plano (QP).
- Extensão do método de estimação autorregressiva para um modelo ARMA completo.
- Influência da orientação da região de suporte na síntese de texturas.
- Elaboração de uma forma combinada de síntese de texturas utilizando componentes autorregressivos e determinísticos.
- Mapeamento de texturas sintéticas autorregressivas em modelos numéricos de terreno, gerando ambientes tridimensionais.
- Remoção de nuvens em imagens óticas utilizando texturas sintéticas autorregressivas.

Finalizando, pode-se facilmente imaginar a utilização do método ora proposto para as diversas aplicações de computação gráfica que necessitem de padrões de texturas, tendo em vista que, a partir de modelos fonte, uma diversidade de padrões sintéticos pode ser armazenada em um banco de dados, sob a forma de processos autorregressivos, de forma econômica e simples, com custo computacional viável.

REFERÊNCIAS BIBLIOGRÁFICAS

- Akaike, H. Power spectrum estimation through autoregressive model fitting. **Annals of the Institute of Statistical Mathematics**, v. 21, p. 407-420, 1969.
- Akaike, H. A new look at the statistical model identification. **IEEE Transactions on Automation Control**, v. AC-19, p. 716-723, Dec. 1974.
- Banon, G.L.F. **Etude d'algorithmes d'estimation des paramètres pour l'identification adaptative en temps réel des processus linéaires perturbés par un bruit corrélé**. Toulouse. These (Docteur-Ingénieur) - Université Paul Sabatier, jan. 1971, 166 p.
- Boes, D. C.; Graybill, F. A.; Mood, A. M. **Introduction to the theory of statistics**, 3. ed. New York: McGraw-Hill, 1974, 480 p.
- Brockwell, P.J.; Davis, R.A. **Time series**. New York: Springer-Verlag, 1987, 519 p.
- Brodatz, P. **Textures: a photographic album for artists and designers**. Toronto: Dover, 1966, 211 p.
- Cadzow, J.A.; Ogino, K. Two-dimensional spectral estimation. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 29, n. 6, p. 396-401, 1981.
- Chatfield, C. **Analysis of time series: an introduction**. London: Chapman & Hall, 1989, 389 p.
- Chellappa, R.; Kashyap, R.L. Synthetic generation and estimation in random field models of images. In: PRIP' 81 IEEE Computer Society Conference on Pattern Recognition and Image Processing, Dallas, 1981. **Proceedings**. Piscataway: IEEE, 1981, p. 577-582.
- Chellappa, R.; Kashyap, R.L. Texture synthesis using 2-D noncausal autoregressive models. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 33, n. 1, p. 194-203, 1985.
- Cross, G.R.; Jain, A.K. Markov random fields texture models. In: PRIP' 81 IEEE Computer Society Conference on Pattern Recognition and Image Processing, Dallas, 1981. **Proceedings**. Piscataway: IEEE, 1981, p. 597-602.
- D'Agostino, R. B.; Stephens, M. A. **Goodness-of-fit techniques**. New York: Dekker, 1986, 205 p.
- Dutra, L.V. **Classificação de texturas usando modelos ARMA e distâncias da função de autocorrelação**. São José dos Campos. (INPE-5067-TDL/406). Tese (Doutorado em Computação Aplicada) - Instituto Nacional de Pesquisas Espaciais, 1990, 136 p.

- Dutra, L.V.; Sant'ana, S.J.S. **SAR texture discrimination using AR-2D models for amazonian land use classification**. São José dos Campos, (INPE-5664-PRE/1838), Instituto Nacional de Pesquisas Espaciais, 1995, 8 p.
- Faugeras, O.D.; Pratt, W.K. Decorrelation methods of texture feature extraction. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 2, n. 4, p. 323-332, 1980.
- Fournier, A.; Fussell D.; Carpenter, L. Computer rendering of stochastic models. **Communications of the ACM**, v. 25, n. 6, p. 371-384, 1982.
- Fu, K.S.; Lu, S.Y. Computer generation of texture using a syntactic approach. **Computer Graphics**, v. 13, n. 3, p.147-152, 1978.
- Fu, K.S.; Lu, S.Y. Stochastic tree grammar for texture synthesis and discrimination. **Computer Graphics and Image Processing**, v. 9, n. 3, p.234-245, 1979.
- Garber, D.D.; Sawchuck, A.A. Texture simulation using a best-fit model. In: PRIP' 81 IEEE Computer Society Conference on Pattern Recognition and Image Processing, Dallas, 1981. **Proceedings**. Piscataway: IEEE, 1981, p. 603-608.
- Gardner, G.Y. Simulation of natural scenes using textured quadric surfaces. **Computer Graphics**, v. 18, n. 3, p.11-20, 1984.
- Goovaerts, P. **Geostatistics for natural resources evaluation**, Oxford: University Press, 1997, 496 p.
- Gonzalez, R.C.; Woods, R.E. **Digital image processing**. Reading: Addison-Wesley, 1992, 716 p.
- Granger, C.W.J.; Newbold, P. **Forecasting economic times series**. New York: Academic Press, 1977. 333 p.
- Haralick, R.M. Statistical and structural approaches to texture. **Proceedings of the IEEE**, v. 67, n. 5, p. 786-804, 1979.
- Hassner, M.; Sklansky, J. The use of Markov random fields as models of texture. **Computer Graphics and Image Processing**, v. 12, n. 3, p.357-370, 1980.
- Institute of Electrical and Electronics Engineers (IEEE). **IEEE standard glossary of image processing and pattern recognition terminology**. New York, 1990. 16 p. (IEEE Standard 610.4-1990).
- Jahne, B. **Digital image processing: concepts, algorithms, and scientific applications**. New York: Springer Verlag, 1995, 400 p.

Jain, A.K. Advances in mathematical models for image processing. **Proceedings of the IEEE**, v. 69, n. 5, p. 122-148, May 1981.

Jain, A.K. **Fundamentals of digital image processing**. Englewood Cliffs: Prentice Hall, 1988, 592 p.

Jain, A.K.; Karu, K. Learning texture discrimination masks. . **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 18, n. 2, p. 195-205, 1996.

Jones, R.H. Autoregression order selection. **Geophysics**, v. 41, n. 4, p. 771-778, Aug. 1976.

Kaufman, A.; Azaria, S. Texture synthesis techniques for computer graphics. **Computers and Graphics**, v. 9, n. 2, p. 139-145, 1985.

Kashyap R. L. Inconsistence of the AIC rule for the estimating the order of autoregressive models. **IEEE Transactions on Automation Control**, v. AC-25, p. 996-998, Oct. 1980.

Kay, S.M. **Modern spectral estimation: theory and application**. Englewood Cliffs: Prentice Hall, 1988, 543 p.

Kolmogorov, A.N. Interpolation und extrapolation von stationären zufälligen folgen. **Bulletin of the Academy of Sciences USSR, Series on Mathematics**, v. 5, p. 3-14, 1941.

Makhoul, J. Lattice methods in spectral estimation. In: Findley, D. F. ed. **Applied Time Series Analysis II**, New York: Academic Press, 1981. p. 301-324.

Mandelbrot, B. Stochastic models for the Earth's relief, the shape and fractal dimension of coastlines, and the number area rules for islands. **Proceedings of the National Academy of Sciences of the United States of America**, v. 72, n.10, p. 2825-2828, 1975.

Mandelbrot, B. The fractal geometry of trees and other natural phenomena. In: Miles, R. E.; Serra, J. ed. **Geometrical probability and biological structures: Buffon's 200th anniversary, proceedings of the Buffon's Bicentenary Symposium on Geometrical Probability, Image Analysis, Mathematical Stereology, and their Relevance to the Determination of Biological Structures**, held in Paris, June 1977. New York: Springer, 1978, p. 235-249.

Mandelbrot, B. **The fractal geometry of nature**. San Francisco: W.H. Freeman, 1982, 468 p.

Marple, S.L. **Digital spectral analysis**. Englewood Cliffs: Prentice Hall, 1987, 492 p.

- Mezei, L.; Puzin, M.; Conroy, P. Simulation of patterns of nature by computer graphics. **Information Processing**, v. 74, n. 1, p. 52-56, 1974.
- Melsa, J.L.; Cohn, D.L. **Decision and estimation theory**. New York: McGraw-Hill, 1978, 152 p.
- Mosier, C.T. **Kolmogorov-Smirnov test**. [online]. <http://phoenix.som.clarkson.edu/~cmosier/simulation/Week_6/ks.html>. Jul. 1998.
- Musgrave, F. K. Fractals and procedural models of nature. In: SIGGRAPH '95 International Conference on Computer Graphics and Interactive Techniques, Los Angeles, Aug. 1995. **Procedural modeling and rendering techniques course notes**, New York: ACM, 1995.v. 33, p. 345-462.
- Oppenheim, A.V.; Shafer, R.W. **Digital signal processing**. Englewood Cliffs: Prentice Hall, 1975, 585 p.
- Park S.K.; Miller, K.W. Random number generators: good ones are hard to find. **Communications of the ACM**, v. 31, n.10, p. 1192, Oct. 1988.
- Parzen, E. Some recent advantages in time series modeling. **IEEE Transactions on Automation Control**, v. AC-19, p. 723-730, Dec. 1974.
- Pendrel, J.V. **The maximum entropy principle in two-dimensional spectral analysis**. York. Thesis (Ph.D. dissertation) - York University, 1979. 254 p.
- Perlin, K. Hypertexture. **Computer Graphics**, v. 23, n.3, p. 112-137, 1989.
- Porat, B. **Digital processing of random signals: theory & methods**. Englewood Cliffs: Prentice Hall , 1994, 449 p.
- Rissanem, J. A universal prior for the integers and estimation by minimum description length. **Annals of Statistics**, v. 11, n. 4, p. 417-431, 1983.
- Robinson, E. A.; Treitel, S. **Geophysical signal analysis**. Englewood Cliffs: Prentice Hall, 1980, 316 p.
- Schachter, B.J; Ahuja, N. Random pattern generation process. **Computer Graphics and Image Processing**, v. 10, n. 1, p. 95-114, 1979.
- Schachter, B.J. Long crested waves models. **Computer Graphics and Image Processing**, v. 12, n. 2, p.187-201, 1980.
- Sklansky, J. Image segmentation and feature extraction **IEEE Transactions on Systems, Man and Cybernetics**, v. 8, n. 2, p.237-247, 1978.

- Thalmann, N.M.; Thalmann, D. **Image synthesis: theory and practice**. New York: Springer-Verlag, 1987, 389 p.
- Tou, J.T.; Kao, D.B.; Chang, Y.S. Pictorial texture analysis and synthesis. In: International Joint Conference on Pattern Recognition, 3., Coronado, Nov. 1976. **Proceedings**. Long Beach: IEEE, 1976. p. 590a-590p.
- Wernecke, S.J.; D'Addario, L.R. Maximum entropy image reconstruction. **IEEE Transactions on Information Theory**, v. 26, n. 4, p. 831-844, Apr. 1977.
- Wilson, R.; Spann, M. Image segmentation and uncertainty. In: Kittler, J. ed. **Pattern Recognition and Image Processing Series**, Herts: RSP, 1988. v. 9, p. 354-385.
- Wold, H. **A study in the analysis on stationary time series**. Stockholm: Almqvist & Wiksell, 1954, 176 p.
- Woods, J.W. Two-dimensional discrete markovian fields. **IEEE Transactions on Information Theory**, v. 18, n. 3, p. 232-240, Mar. 1972.
- Walker, G. On periodicity in series of related terms. **Proceedings of the Royal Society of London**, v. A 131, n. 5, p. 518-532, 1931.
- Yule, G. U. On a method for investigating periodicities in disturbed series with special reference to Wolfer's sunspot numbers. **Philosophical Transactions of the Royal Society of London**, v. A 226, n. 3, p. 267-268, 1927.

APÊNDICE A

CARACTERÍSTICAS DO SOFTWARE SINTETIZADOR DE TEXTURAS AUTORREGRESSIVAS

Diagrama Hierárquico de Funções (FHD)

O Diagrama Hierárquico de Funções para o software Sintetizador de Texturas Autorregressivas, desenvolvido em IDL, é apresentado na Figura A.1.

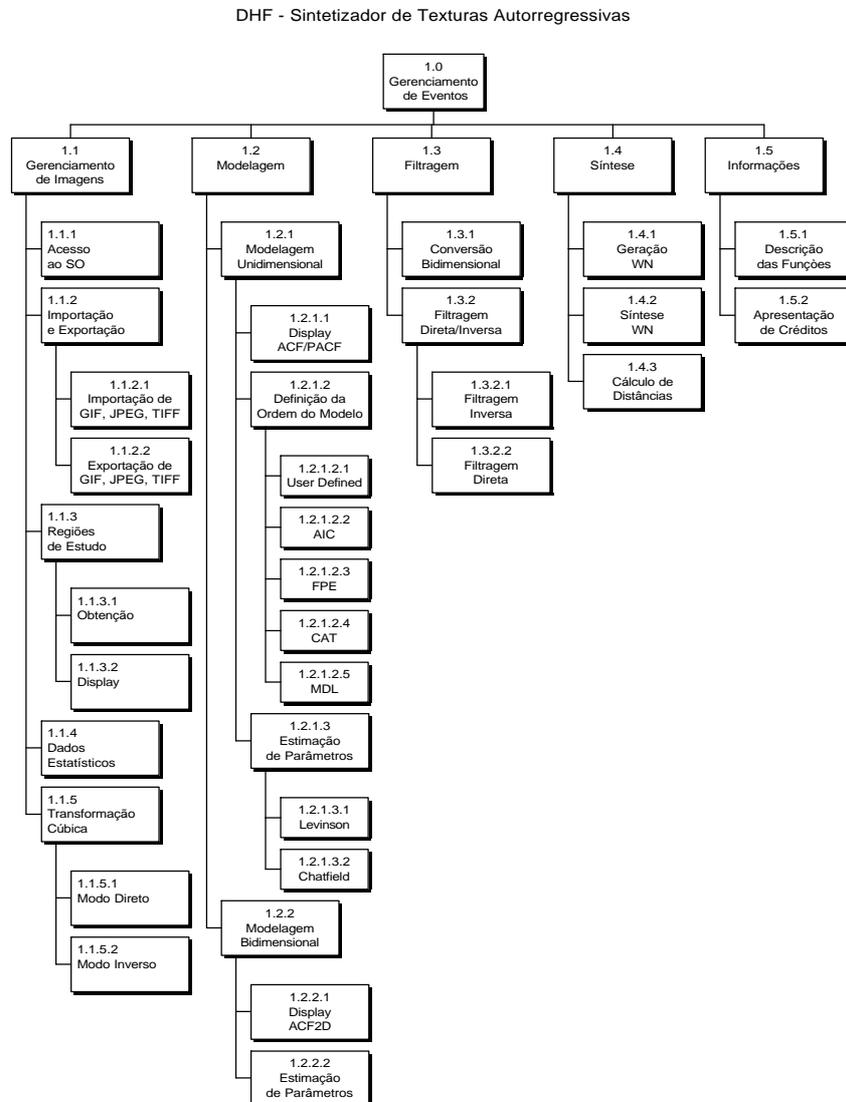


Fig. A.1- DHF do Sintetizador de Texturas Autorregressivas

TABELA A.1- DESCRIÇÃO DAS FUNÇÕES IMPLEMENTADAS NO SOFTWARE SINTETIZADOR DE TEXTURAS AUTORREGRESSIVAS

FUNÇÃO	DESCRIÇÃO
1.0	Gerenciamento e controle de execução dos diversos eventos
1.1	Gerenciamento das atividades relativas ao tratamento das imagens
1.1.1	Atividades relacionadas ao sistema operacional: abrir imagens, mostrá-las e sair do programa
1.1.2	Atividades de importação e exportação para/de formato ENVI (nativo)
1.1.2.1	Importação de imagens GIF, JPEG ou TIFF para formato ENVI
1.1.2.2	Exportação de formato ENVI para imagens GIF, JPEG ou TIFF
1.1.3	Definição e manipulação das regiões de estudo
1.1.3.1	Obtenção gráfica das regiões de estudo a serem utilizadas
1.1.3.2	Display das regiões de estudo existentes, bem como dos momentos de segunda ordem das mesmas
1.1.4	Display de dados estatísticos das imagens: histograma, média e variância
1.1.5	Manipulação das funções de gaussianização para uso nas imagens SAR
1.1.5.1	Transformação das imagens pela curva raiz cúbica
1.1.5.2	Recuperação de imagens transformadas pela curva raiz cúbica
1.2	Atividades diversas relacionadas à modelagem autorregressiva
1.2.1	Tarefas ligadas à modelagem autorregressiva unidimensional
1.2.1.1	Display das funções de autocorrelação e autocorrelação parcial para um determinado atraso (<i>lag</i>)
1.2.1.2	Definição customizada da ordem do modelo
1.2.1.2.1	Definição da ordem pelo usuário
1.2.1.2.2	Uso da função de minimização AIC para a definição da ordem do modelo
1.2.1.2.3	Uso da função de minimização FPE para a definição da ordem do modelo
1.2.1.2.4	Uso da função de minimização CAT para a definição da ordem do modelo
1.2.1.2.5	Uso da função de minimização MDL para a definição da ordem do modelo
1.2.1.3	Estimação de parâmetros autorregressivos
1.2.1.3.1	Utilização do algoritmo de Levinson-Durbin para a estimação de parâmetros
1.2.1.3.2	Utilização do método de Chatfield para a estimação de parâmetros (função nativa de estimação de parâmetros do IDL)
1.2.2	Tarefas ligadas à modelagem autorregressiva bidimensional
1.2.2.1	Display das funções de autocorrelação bidimensional e autocorrelação bidimensional concatenada
1.2.2.2	Estimação de parâmetros utilizando a função de autocorrelação bidimensional concatenada
1.3	Funções ligadas ao processo de manipulação dos filtros bidimensionais e de filtragem
1.3.1	Mapeamento do filtro unidimensional em bidimensional
1.3.2	Atividades de filtragem direta/inversa
1.3.2.1	Filtragem inversa para obtenção do resíduo
1.3.2.2	Filtragem direta para regeneração da imagem original
1.4	Funções ligadas ao processo de síntese de texturas
1.4.1	Geração do ruído branco gaussiano de mesma variância que o resíduo
1.4.2	Síntese de textura utilizando o ruído branco gerado e a filtragem direta
1.4.3	Cálculo das distâncias para a verificação do ajuste dos modelos
1.5	Funções de apoio ao usuário, meramente informativas
1.5.1	Descrição do processo de modelagem e síntese autorregressiva
1.5.2	Informações a respeito dos responsáveis pelo programa desenvolvido

Diagrama de Interação entre Processos

O Diagrama de Interação entre Processos para o Sintetizador de Texturas Autorregressivas é apresentado na Figura A.2. Os processos e interações mostrados em cor diferente representam funcionalidades não implementadas.

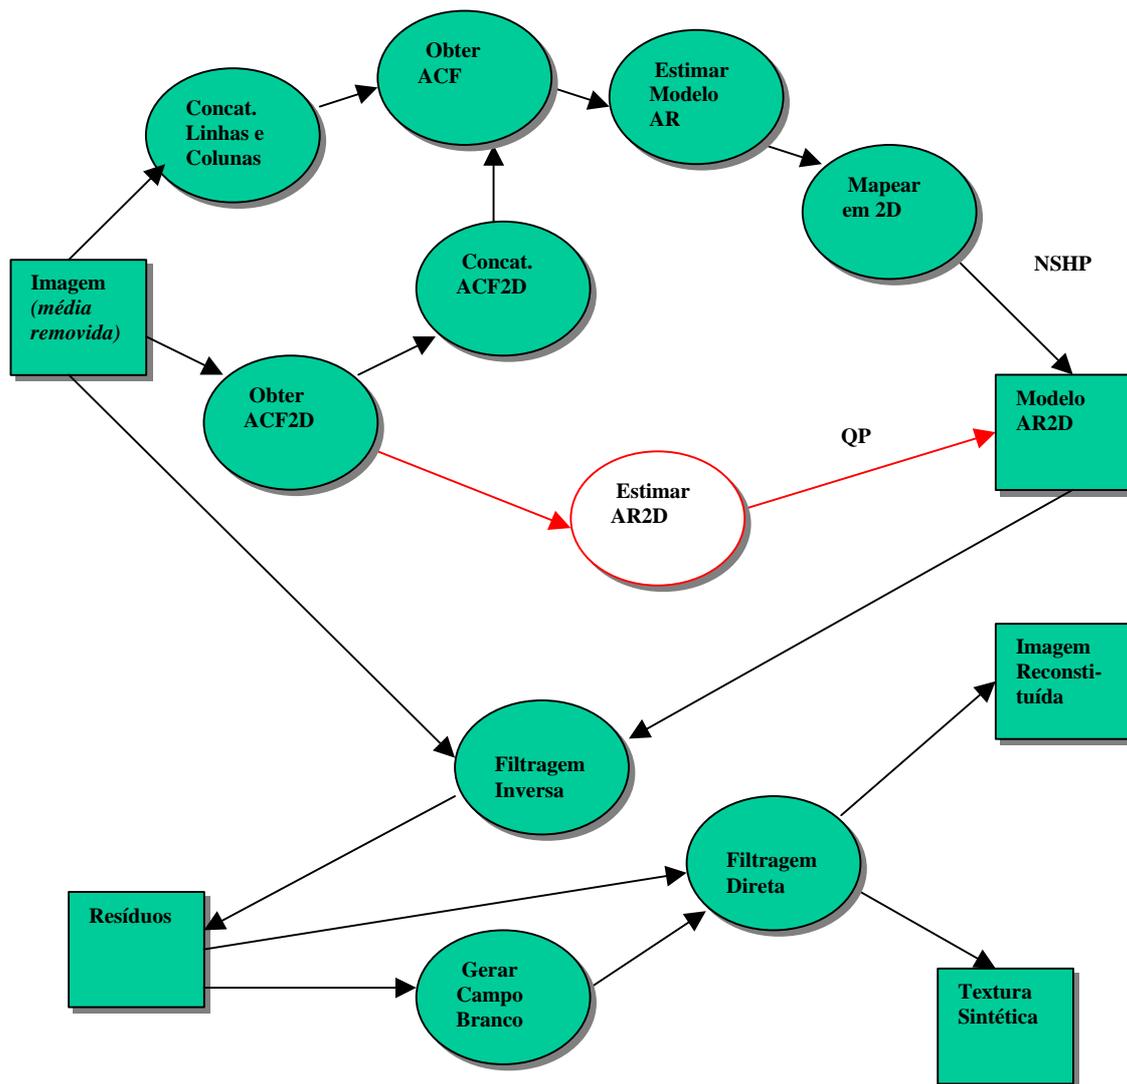


Fig. A.2 - Diagrama de Interação entre Processos

Layout da Implementação das Funções Mais Significativas

A seguir, algumas das interfaces gráficas (GUI) implementadas são apresentadas, bem como os elementos que levaram a definição de seu *layout*. Embora o software desenvolvido em IDL tem por característica ser multiplataforma, operando em qualquer ambiente que possua interpretador IDL disponível, as interfaces apresentarão pequenas diferenças, dependendo do padrão gráfico do sistema operacional, Windows ou MOTIF. As interfaces aqui apresentadas foram obtidas em padrão Windows, e possuem as características da API e bibliotecas gráficas deste sistema.

A interface controladora de eventos apresenta-se conforme um menu do tipo flutuante comum em interfaces UNIX, similar ao utilizado por softwares como ENVI e FrameMaker.

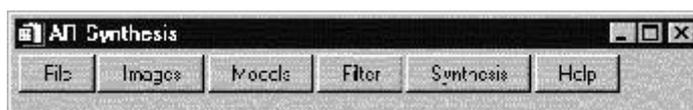


Fig. A.3 - Controlador de Eventos.

As interfaces que implementam janelas para a visualização de resultados gráficos, bem como dados relativos aos produtos são similares às interfaces do software ENVI, o qual também é implementado em IDL.

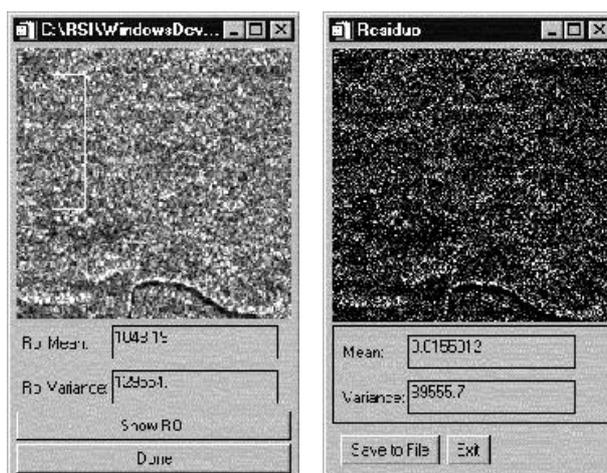


Fig. A.4 - Interfaces com imagens e dados (continua).

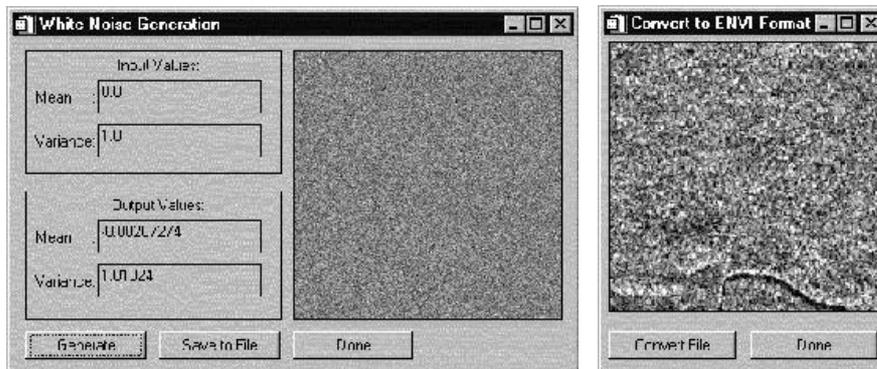


Fig. A.4 - Conclusão.

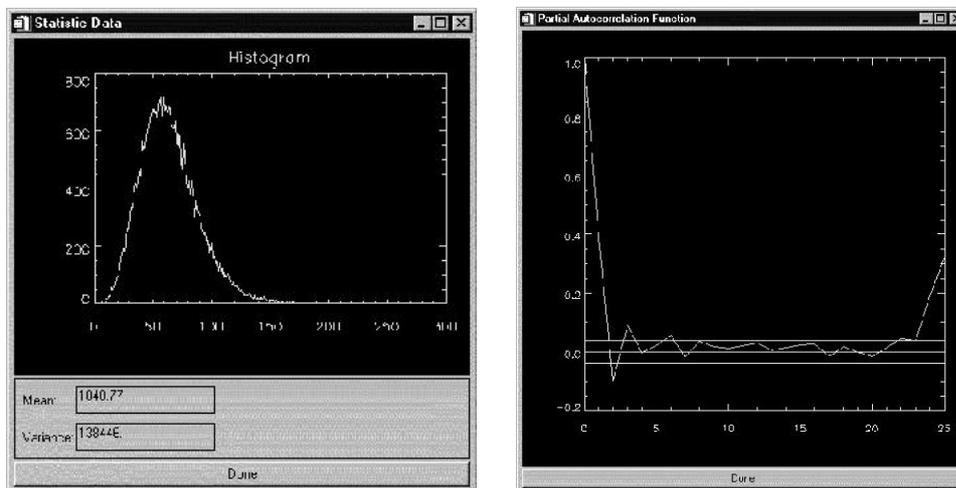


Fig. A.5 - Interfaces com dados gráficos e textuais.

Algumas interfaces incorporaram o padrão de janelas de comandos, comuns em sistemas UNIX.

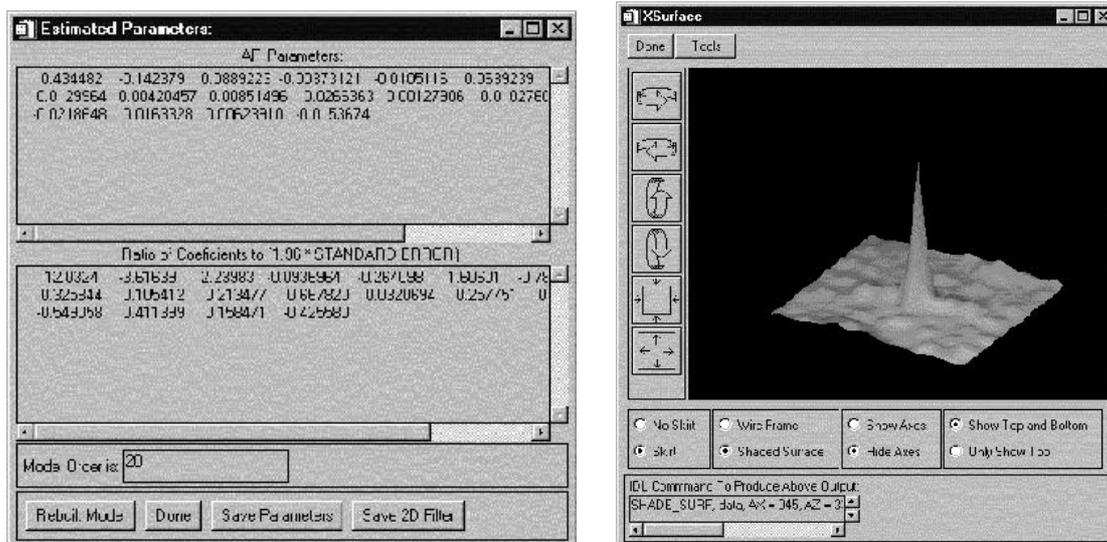


Fig. A.6 - Interfaces tipo janela de comandos.

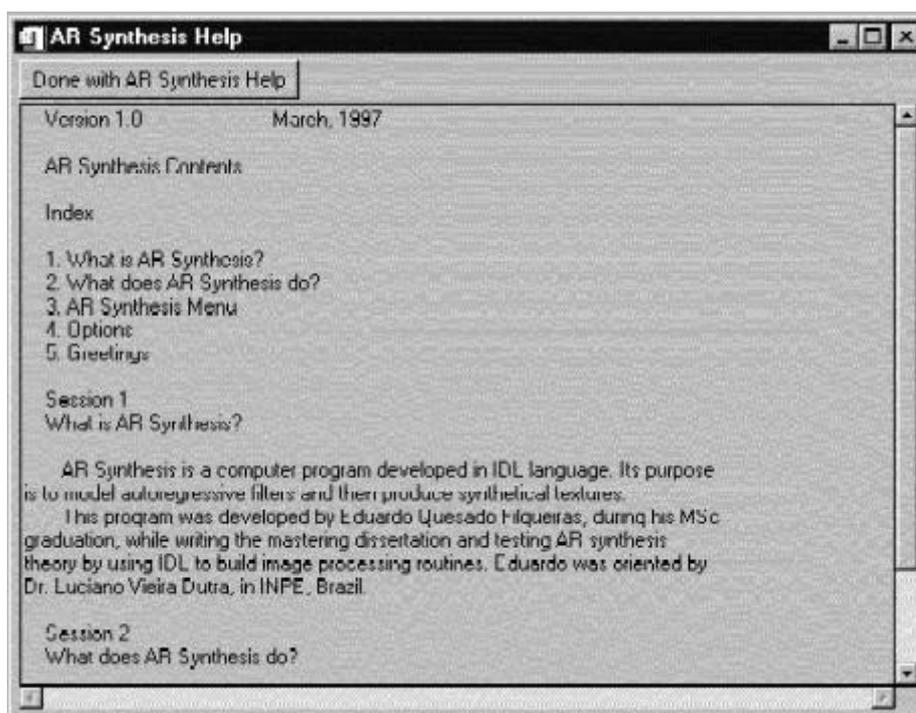


Fig. A.7 - Interfaces com texto em janela de comandos.

Interfaces do tipo “termômetro” foram utilizadas para permitir a visualização de progresso de operações que demandavam mais tempo de CPU, evitando os desagradáveis períodos sem resposta do sistema e sem estimativa de finalização da tarefa.

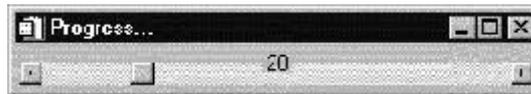


Fig. A.8 – Interface tipo termômetro.

Janelas que se utilizam dos padrões de caixas de diálogo ligadas a API do sistema operacional de forma a apresentar mensagens de alerta ou de informações aos usuários também foram utilizadas.



Fig. A.9 – Interface tipo caixa de diálogo.

Finalmente, interfaces do tipo *grid tabular* foram implementadas, semelhantes a interfaces proporcionadas por VBX ou OCX, bem como interfaces customizadas para a resolução de tarefas específicas, como o cálculo das distâncias euclidianas.

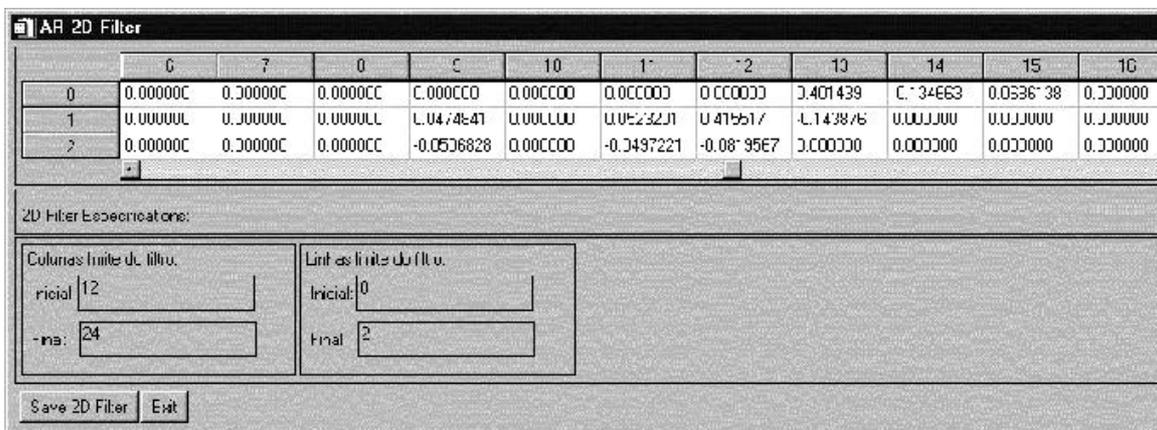


Fig. A.10 – Interface tipo *datagrid*.



Fig. A.11 - Interface específica para cálculo de distâncias euclidianas.

A idéia principal foi proporcionar um ambiente agradável e intuitivo que utilizasse dos recursos gráficos dos sistemas operacionais em que o software multiplataforma foi implementado, proporcionando conforto e suave aprendizado tanto aos usuários de UNIX quanto de Windows 95/NT habituados a utilizar ENVI e outros softwares de processamento de imagens.

APÊNDICE B

CARACTERÍSTICAS DO SENSOR ÓTICO DO SATÉLITE JERS-1

O satélite JERS-1 (Japanese Earth Resources Satellite) é um satélite de observação da Terra voltado para a cobertura global de proteção ambiental, monitoramento costeiro, proteção contra desastres, cobertura agrícola, desflorestamento e outras atividades focadas na observação ao redor do planeta e exploração de recursos.

Foi lançado em uma órbita solar-síncrona sub-recorrente a uma altitude de 568 Km, com um período de recorrência de 44 dias, pelo veículo lançador H-1 em 11 de fevereiro de 1992 pela NASDA (from National Space Development Agency of Japan) do Centro Espacial Tanegashima.

JERS-1 é capaz de coletar dados com radar de abertura sintética (Synthetic Aperture Radar - SAR) e sensor ótico (Optical Sensor - OPS) de alta performance.

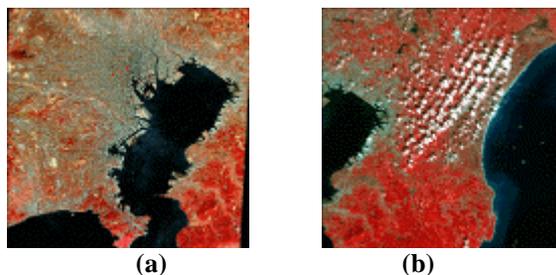
O radar de abertura sintética (SAR) é um sensor ativo que transmite microondas e observa características da superfície da Terra sem ser influenciado pelas condições meteorológicas ou períodos do dia/noite.

O sensor ótico (OPS) é um sensor passivo capaz de observar em sete bandas espectrais, do espectro visível à banda infravermelha de ondas curtas, podendo realizar observações estereoscópicas em banda próxima ao infravermelho, o que é altamente útil para a identificação de minerais. O sensor ótico (OPS) do satélite JERS-1 provê melhor resolução no solo do que o sensor do satélite MOS-1 (Japan's Marine Observation Satellite-1). Utiliza-se de câmeras digitais CCD¹ (Charged Coupled Device) para a aquisição de imagens de sensoriamento remoto de alta resolução em bandas espectrais visíveis e próximas ao infravermelho. A Figura B.1 apresenta imagens óticas JERS-1 de Tokyo e Chiba (Japão).

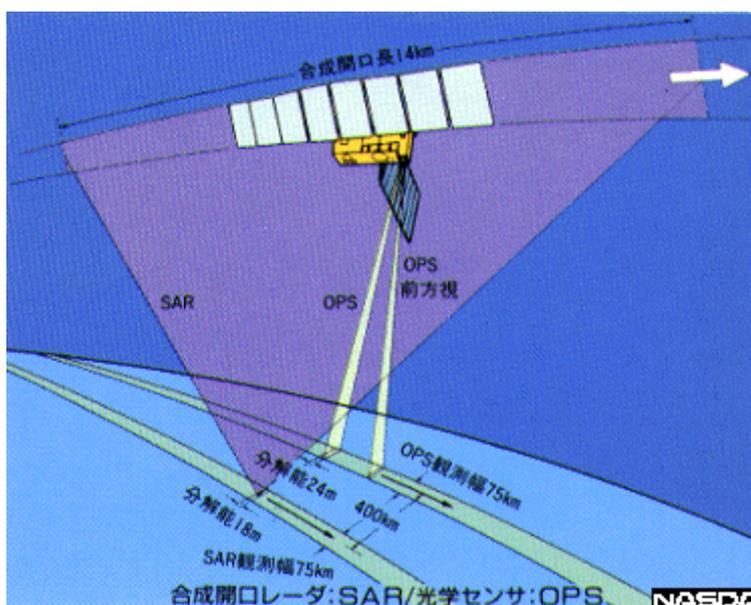
¹ Os sensores CCD das câmeras do satélite transformam a luz obtida pela objetiva em sinais digitais.

Especificações Principais do Sensor Ótico (Figura B.2):

Largura da visada no solo (swath width)	75Km
Resolução	18m x 24m
Número de Bandas de Observação:	- Visíveis próximas ao infravermelho: 3 - Infravermelho de ondas curtas: 4 - Estereoscópica: 1



**Fig. B.1 – Imagens do sensor ótico do satélite JERS-1:
(a) Tokyo (Japão); (b) Chiba (Japão).
FONTE: NASDA.**



**Fig. B.2 – Especificações do satélite JERS-1.
FONTE: NASDA.**