

INPE-5457-TDI/499

**USO DA TEORIA DE ESTIMAÇÃO BAYESIANA NA FUSÃO
DE DADOS DE SATÉLITES**

Ana Lúcia Bezerra Candeias

**INPE
São José dos Campos
1992**

SECRETARIA DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

INPE-5457-TDI/499

USO DA TEORIA DE ESTIMAÇÃO BAYESIANA NA FUSÃO
DE DADOS DE SATÉLITES

Ana Lúcia Bezerra Candeias

Dissertação de Mestrado em Sensoriamento Remoto, orientada
pelos Drs. Nelson Delfino D'Avila Mascarenhas e Gerald
Jean Francis Banon, aprovada em fevereiro de 1992

INPE
São José dos Campos
1992

621.376.5

CANDEIAS, A.L.B.

Uso da teoria de estimação bayesiana na fusão de dados de satélites. / A.L.B. Candéias. -- São José dos Campos: INPE, 1992. 133p. -- (INPE-5457-TDI/499)

1. Imagem sintética. 2. Interpolação estatística. 3. Estimação bayesiana. 4. Processamento de imagem. I. Título

Aprovada pela Banca Examinadora
em cumprimento a requisito exigido
para a obtenção de Título de Mestre
em Sensoriamento Remoto

Dr. Raimundo Almeida Filho



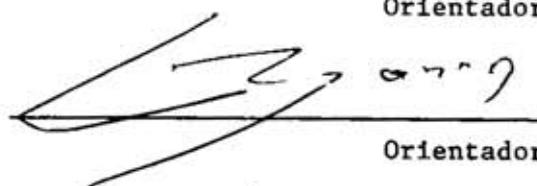
Presidente

Dr. Nelson Delfino d'Ávila Mascarenhas



Orientador

Dr. Gerald Jean Francis Banon



Orientador

Dr. Fernando Toshinori Sakane



Membro da Banca
- Convidado -

Candidata: Ana Lúcia Bezerra Candeias

São José dos Campos, 14 de fevereiro de 1992

"É difícil dizer o que é impossível,
pois a fantasia de ontem é a esperança de
hoje e a realidade do amanhã."

Dedico este trabalho aos meus pais.

AGRADECIMENTOS

Gostaria de agradecer a todas as pessoas que, direta ou indiretamente, e ajudaram neste trabalho de tese. A seguir eu expresso alguns agradecimentos especiais.

Ao Instituto Nacional de Pesquisas Espaciais (INPE) pela oportunidade de realizar o curso de mestrado em Sensoriamento Remoto e pelo apoio à pesquisa.

Aos professores Viera Dias (INPE), Marluce Veiga (UFPE) e Zacharias E. Candeias, ambos da Universidade Federal de Pernambuco (UFPE), que me encorajaram para fazer este curso de mestrado.

Aos Drs, Nelson Delfino D'Avila Mascarenhas e Gerald Francis Banon pela orientação deste trabalho, e principalmente, pela atenção, inestimável ajuda e valiosos esclarecimentos.

Aos pesquisadores e funcionários do INPE e do Departamento de Processamento de Imagens (DPI), em especial a Júlio D'Alge, Silvia II e Virginia.

Aos amigos e bolsistas do INPE, em especial Ana Paula Dutra Aguiar e Diana Sarita Hamburger, pelo companherismo e pela atenção que sempre me dispensaram.

Ao Departamento de Energia Nuclear (UFPE), que me liberou para realizar este curso de mestrado.

Ao Departamento de Cartografia (UFPE) por ter cedido seus equipamentos para alguns testes.

A Edilberto Bezerra de Sousa, meu braço forte, com quem compartilhei todos os momentos difíceis e

alegres deste trabalho.

Ao computador PC-EGO da sala de microcomputadores do DPI, que ficou comigo todos os dias, sábados, domingos e feriados, realizando os resultados desta tese.

E, finalmente, a minha querida família, principalmente aos meus pais, que me ajudaram a ser hoje o que sou e pelo apoio que me deram em toda minha caminhada.

Muito obrigada a todos; sem vocês este trabalho não teria se realizado.

RESUMO

Fusão de dados pictóricos é a denominação de um conjunto de técnicas para gerar imagens sintéticas a partir da combinação de imagens primárias, procurando aproveitar as melhores características de cada imagem primária. Nesta dissertação, é desenvolvido um modelo bayesiano de fusão de dados pictóricos utilizando como base o trabalho de Brum (1989). Como exemplo, tal modelo é aplicado à fusão de imagens do satélite SPOT. É feita uma comparação da técnica proposta com outras apresentadas na literatura. O método bayesiano tem como vantagem, além de sua formalização estatística, a possibilidade de adaptar o processo de síntese às características locais das imagens

BAYESIAN MODEL FOR PICTORIAL DATA FUSION OF SATELLITE IMAGE

ABSTRACT

Pictorial data fusion is the denomination of a set of techniques for generating synthetic images from the combination of primary images, by attempting to preserve the best characteristics from each primary image. In this dissertation, a Bayesian model for pictorial data fusion is proposed, based on the work of Brum (1989). As an example, such model is applied to the image data fusion of SPOT satellite images. A comparison between the proposed technique with others that were presented in the literature is made. The Bayesian model has the advantage of offering the potential for adaptation to the local characteristics of the images in the synthesis process, besides its formal statistical formulation.

SUMÁRIO

| | <u>Pág.</u> |
|---|-------------|
| LISTA DE FIGURAS..... | xix |
| LISTA DE TABELAS..... | xxi |
| | |
| <u>CAPÍTULO 1 - INTRODUÇÃO</u> | 1 |
| | |
| 1.1 - Metodologia usada na fusão de dados..... | 2 |
| 1.2 - Organização da tese e metodologia..... | 3 |
| 1.3 - Fundamentação teórica..... | 4 |
| 1.3.1 - Processamento digital de imagens..... | 4 |
| 1.3.2 - Modelo estocástico da imagem..... | 12 |
| 1.3.3 - Resolução..... | 15 |
| 1.3.4 - Sensor HRV-SPOT..... | 16 |
| 1.3.5 - Estimador de Bayes..... | 18 |
| 1.3.5.1 - Princípio da ortogonalidade..... | 20 |
| 1.3.5.2 - Estimador linear não-homogêneo..... | 24 |
| | |
| <u>CAPÍTULO 2 - TRABALHOS EM FUSÃO DE DADOS DE SENSORES...</u> | 27 |
| | |
| 2.1 - Fusão pelo método de Cliche et. al. (1985)..... | 30 |
| 2.2 - Fusão pelo método IHS..... | 33 |
| 2.3 - Transformação IHS - Dutra | 35 |
| 2.4 - Transformação IHS - Carper | 36 |
| 2.5 - Interpolação geométrica e fusão de dados..... | 37 |
| 2.5.1 - Fusão pelo método de Brum | 37 |
| 2.5.2 - Modelagem..... | 38 |
| 2.5.3 - Geração dos canais estimados..... | 39 |
| 2.5.4 - Determinação das constantes α_i e b_{jk} | 44 |
| 2.5.5 - Interpolação geométrica..... | 46 |
| 2.5.6 - Montagem das equações..... | 49 |
| 2.5.7 - Análise de resultados..... | 52 |

| | |
|--|-----|
| <u>CAPÍTULO 3 - TEORIA BAYESIANA DE ESTIMAÇÃO E FUSÃO DE</u> | |
| <u>DADOS.....</u> | 55 |
| 3.1 - Interpolação estatística espacial..... | 55 |
| 3.2 - Cálculo da matriz de covariância C..... | 61 |
| 3.3 - Estimador total (imagem sintética)..... | 63 |
| 3.4 - Estudo dos casos limites..... | 66 |
| 3.4.1 - Caso 1 - Interpolação estatística espacial da imagem..... | 67 |
| 3.4.2 - Caso 2 - Imagem sintética..... | 67 |
| | |
| <u>CAPÍTULO 4 - COMPORTAMENTO DO MODELO DE ESTIMAÇÃO BAYE-</u> | |
| <u>SIANA.....</u> | 71 |
| 4.1 - Validação do modelo usando estimação bayesiana... | 71 |
| 4.1.1 - Comparação entre a matriz de covariância medida e a calculada..... | 71 |
| 4.1.2 - Análise da variação dos parâmetros ρ_H , ρ_V e V .. | 74 |
| 4.1.2.1 - Caso 1 - Interpolação estatística espacial .. | 74 |
| 4.1.2.2 - Caso 2 - Imagem sintética | 74 |
| 4.1.3 - Comportamento do modelo para regiões com bordas verticais e regiões sem borda..... | 78 |
| 4.2 - Comparação do desempenho do interpolador espaci- al e de outros interpoladores..... | 80 |
| 4.3 - Comparação do desempenho das imagens sintéticas geradas pelo método de Bayes com as propostas na literatura..... | 87 |
| | |
| <u>CAPÍTULO 5 - ANÁLISE DE RESULTADOS E CONCLUSÕES.....</u> | 97 |
| | |
| REFERÊNCIAS BIBLIOGRÁFICAS | 99 |
| APÊNDICE A - PRODUTO DE KRONECKER..... | 105 |
| | |
| A.1 - Definição | 107 |
| A.2 - Propriedade da inversa..... | 113 |

| | |
|--|-----|
| APÊNDICE B - SISTEMAS BEM CONDICIONADOS E MALCONDICIONADOS | 107 |
| APÊNDICE C - MATRIZ INVERSA GENERALIZADA | 113 |
| APÊNDICE D - EXPRESSÃO PARA A INVERSA DA MATRIZ DE COEFICIENTES DE CORRELAÇÃO SUPONDO UM PROCESSO MARKOVIANO | 115 |
| APÊNDICE E - DETECÇÃO DE BORDAS | 117 |
| APÊNDICE F - LITERATURA RECOMENDADA | 119 |
| APÊNDICE G - FLUXOGRAMAS..... | 123 |
| APÊNDICE H - FIGURAS..... | 129 |

LISTA DE FIGURAS

| | <u>Pág.</u> |
|--|-------------|
| 1.1 - Processamento digital de imagens..... | 5 |
| 1.2 - Produto E x D..... | 6 |
| 1.3 - Modelo de imageador..... | 8 |
| 1.4 - Representação de um "pixel"..... | 9 |
| 1.5 - Palheta de cores do cubo RGB..... | 11 |
| 1.6 - Interpretação geométrica da ortogonalidade..... | 22 |
| 2.1 - Interpolação pelo método de Cliche..... | 31 |
| 2.2 - Fusão de dados usando transformação IHS..... | 35 |
| 2.3 - Curvas de responsividade espectral dos canais P, S ₁ , S ₂ e S ₃ do sensor HRV, satélite SPOT..... | 40 |
| 2.4 - Combinação linear dos canais HRV - SPOT..... | 43 |
| 2.5 - Processo de reamostragem..... | 47 |
| 2.6 - Reconstrução da imagem..... | 49 |
| 3.1 - Representação de um bloco com três linhas e três colunas..... | 58 |
| 4.1 - Número de condição..... | 77 |
| 4.2 - Curva de nível do número de condição..... | 77 |
| 4.3 - Imagem simulada | 78 |
| 4.4 - Comportamento de uma área constante. Interpolação espacial..... | 79 |
| 4.5 - Comportamento das curvas de nível para uma área constante. | 79 |
| 4.6 - Análise de borda vertical..... | 80 |
| 4.7 - Interpolação espacial. | 82 |
| 4.8 - "Zoom" de interpolação espacial. | 83 |
| 4.9 - Histograma de interpolação espacial - banda 1 ... | 84 |
| 4.10 - Histograma de interpolação espacial - banda 2... .. | 85 |
| 4.11 - Histograma de interpolação espacial - banda 3 .. | 86 |
| 4.12 - Imagem sintética (Cliche , Brum, Est. bayesiana) | 89 |
| 4.13 - Imagem sintética (Dutra , Sat., Carper)..... | 90 |

| | |
|--|-----|
| 4.15 - Histograma da imagem sintética - banda 2. | 94 |
| 4.16 - Histograma da imagem sintética - banda 3. | 95 |
| 4.17 - Histograma da imagem original pancromática. | 95 |
| B.1 - Superfície residual em um k-elipsóide para o problema com $n=2$ | 109 |
| B.2 - Superfície residual em um k-elipsóide para um problema com $n=2$ e $p=1$ | 112 |
| C.1 - Geometria das soluções de um sistema subdeterminado..... | 113 |
| E.1 - Representação esquemática do operador gradiente.. | 120 |
| G.1 - Fluxograma de fusão de imagens usando modelo de Cliche..... | 123 |
| G.2 - Fluxograma de fusão de imagens usando modelo de Dutra..... | 124 |
| G.3 - Fluxograma de fusão de imagens usando modelo de Carper..... | 125 |
| G.4 - Fluxograma da fusão de dados pelo método desenvolvido em Brum (1989)..... | 126 |
| G.5 - Fluxograma de fusão de dados usando estatística Bayesiana | 127 |
| H.1 - Bandas originais HRV - SPOT..... | 129 |
| H.2 - Imagem sintética. a) Cliche; b) Brum; c) Bayes; d) Dutra; e) IHS com tabela para canal S; f) Carper..... | 130 |
| H.3 - Zoom da Figura H.2 - Banda 2. a) Cliche; b) Brum; c) Bayes..... | 131 |
| H.4 - Zoom da Figura H.2 - d) Dutra; e) IHS com sat.;f) Carper..... | 132 |
| H.5 - Sistema malcondicionado. Zoom da banda 2. $\rho_H = \rho_V = 0.999$ e matriz V nula..... | 133 |

LISTA DE TABELAS

| | <u>Pág.</u> |
|--|-------------|
| 1.1 - Arestas do cubo | 10 |
| 2.1 - Canais estimados e canais HRV - SPOT | 39 |
| 2.2 - Valores das constantes α_i e b_{kj} | 46 |
| 4.1 - Matriz de covariância calculada e matriz de covariância medida pelo SITIM..... | 72 |
| 4.2 - Cálculo das estatísticas do interpolador espacial | 74 |
| 4.3 - Cálculo das estatísticas do intrerpolador espacial | 87 |
| 4.3 - Cálculo das estatísticas da imagem sintética..... | 91 |

CAPÍTULO 1

INTRODUÇÃO

Com a crescente disponibilidade de sensores para imageamento, a fusão de dados de multisensores vem se tornando uma componente importante no processamento de imagens, representando uma boa fonte de informação para um GIS (Geographical Information System).

Neste trabalho, conceitua-se a fusão de dados como a técnica de geração de uma imagem sintética a partir da combinação de características predominantes das imagens primárias. Com isto, há uma redução no volume de dados e melhor aproveitamento em sua análise.

É interessante ressaltar que, na literatura, denota-se também integração de dados para fusão de dados.

Em termos gerais, os sensores utilizados para imageamento dividem-se em duas classes: os que apresentam boa resolução espectral (TM, MSS-Landsat e os canais multiespectrais do sensor SPOT) e os que apresentam boa resolução espacial (SPOT pancromático e as fotografias aéreas). Com o desenvolvimento de técnicas de fusão de dados, é possível obter uma imagem sintética que contenha alta resolução espacial e espectral.

Para o sensoriamento remoto, a fusão de dados torna-se um recurso importante quando se deseja um estudo mais refinado de uma dada área ou tema. Alguns exemplos, como planejamento e gerenciamento de áreas urbanas, inventário florestal, regeneração da vegetação natural e cadastramento de áreas agrícolas, necessitam de uma boa resolução espacial e espectral. Estes casos podem

ser estudados a partir de uma imagem sintética com alta resolução espacial e espectral obtida por fusão de dados.

O objetivo deste trabalho é propor um modelo de uma imagem sintética com alta resolução espacial e espectral a partir de uma abordagem estatística bayesiana, usando como base o método apresentado em Brum (1989). Avalia-se seu desempenho e compara-se o método proposto com alguns métodos descritos na literatura.

O sensor utilizado é o HRV-SPOT. Faz-se a síntese de uma imagem que tenha a resolução espectral das bandas multiespectrais e a resolução espacial da banda pancromática.

A área teste é a do aeroporto de Guarulhos - SP (Brasil), com órbita ponto WRS 716 - 397, e a data de passagem é 02/08/1989 (Figura H.1).

1.1 - METODOLOGIA USADA NA FUSÃO DE DADOS

Em geral, a metodologia aplicada na fusão pode ser dividida em três etapas. A primeira compatibiliza espacialmente as imagens por meio da interpolação espacial. A segunda etapa obtém o registro geométrico das imagens. Finalmente, na terceira etapa se desenvolve a fusão propriamente dita (Candeias, 1991).

As interpolações espaciais mais utilizadas na fusão de dados são a interpolação do vizinho mais próximo, a interpolação bilinear e a interpolação por convolução cúbica. Alguns outros métodos propostos são apresentados por Brum (1989) e Mascarenhas et al. (1991), os quais estão descritos nos Capítulos 2 e 3 deste trabalho.

A fusão de dados é geralmente desenvolvida na literatura a partir de operações aritméticas (Cliche et al., 1985; Chavez 1986), Transformação IHS (Hayden et al., 1982; Carper et al. 1990), e Principais Componentes (Chavez, 1988; Chavez 1991). Para todos os casos anteriormente citados, deseja-se que a imagem sintética preserve a resolução espacial e a resolução espectral das imagens primárias.

Neste trabalho, propõe-se criar uma imagem sintética com alta resolução espacial e espectral, supondo que a interpolação seja dada a partir de uma abordagem estatística bayesiana que usa como base o método apresentado em Brum (1989). Como resultado, têm-se um interpolador espacial e um estimador total. O interpolador espacial servirá como conhecimento a priori para o estimador total.

1.2 - ORGANIZAÇÃO DA TESE E METODOLOGIA

Algumas definições básicas importantes para o perfeito entendimento do texto encontram-se na Seção 1.2. São discutidos alguns métodos apresentados na literatura no Capítulo 2, sendo dada uma importância maior ao método desenvolvido em Brum (1989). O Capítulo 3 propõe o método que usa estatística bayesiana. O Capítulo 4 trata dos resultados obtidos e de algumas comparações com outros métodos. As considerações finais são apresentadas no Capítulo 5.

Apresenta-se a seguir a metodologia desenvolvida neste trabalho:

- a) Estudo da bibliografia sobre fusão de dados.
- b) Desenvolvimento do modelo para síntese, que usa

estatística bayesiana, para gerar os seguintes estimadores:

- interpolador espacial;
 - estimador total (imagem sintética).
- c) Avaliação dos resultados e comparação com alguns modelos estudados na literatura.
- d) Resultados e conclusões.

Na sobreposição das imagens pancromática e multiespectrais avaliaram-se apenas as diferenças de deslocamento vertical e horizontal existentes entre as imagens. Utilizaram-se pontos de controle como referência de estimação de desvios existentes entre as imagens pancromática e multiespectral.

1.3 - FUNDAMENTAÇÃO TEÓRICA

Alguns conhecimentos teóricos serão introduzidos aqui para o perfeito entendimento de termos e definições usados neste trabalho. Os conceitos apresentados nas Seções 1.3.1 e 1.3.2 estão baseados em Banon (1990).

1.3.1 - PROCESSAMENTO DIGITAL DE IMAGENS

A partir de uma cena f , estuda-se como se obtém uma imagem colorida ou uma cena reconstruída e como o sistema visual humano observa este resultado. A Figura 1.1 descreve um esquema deste processo.

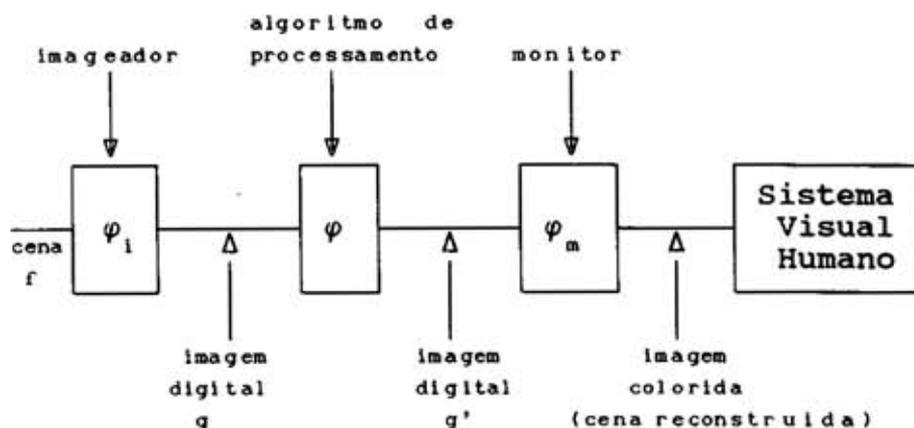


Fig. 1.1 - Processamento digital de imagens

1) Definição de cena plana

Supõe-se por simplificação que a visada do satélite seja obtida a nadir. As componentes do domínio da cena f são:

- E : o conjunto das coordenadas dos pontos do plano

$$x = (x_1, x_2) \in E \subset \mathbb{R}^2 \quad (\text{m}^2). \quad (1.1)$$

- D : o conjunto das coordenadas geodésicas dos pontos na semi-esfera unitária.

$$\theta = (\theta_1, \theta_2) \in D = [0, 2\pi] \times [0, \pi/2]. \quad (\text{Sr}). \quad (1.2)$$

- S : o conjunto dos valores reais positivos que representam o comprimento de onda $\lambda \in S \subset \mathbb{R}^+$ (μm). Sabe-se que λ é dado por $\lambda = c/f$, onde c é a velocidade da luz e f é a frequência.

Seja φ a função de $E \times D \times S$ (produto cartesiano) em \mathbb{R}^+ , onde $\varphi(x, \theta, \lambda)$ representa a potência (w) da radiação que sai de x na direção θ e de comprimento de onda λ . A função:

$$f: E \times D \times S \rightarrow \mathbb{R}^+, \quad (1.3)$$

dada por:

$$f(x, \theta, \lambda) = \left. \frac{d^3\varphi}{(dx d\theta d\lambda)} \right|_{x, \theta, \lambda} \quad 1/\cos\theta \text{ (W/m}^2\text{Sr}\mu\text{m)}, \quad (1.4)$$

representa a radiância espectral da cena e é chamada simplesmente de cena.

Observa-se que esta definição de cena depende da iluminação. Caso se desejasse uma definição independente de iluminação, seria obtida através de noção de reflectância.

A Figura 1.2 é uma representação esquemática do produto $E \times D$.

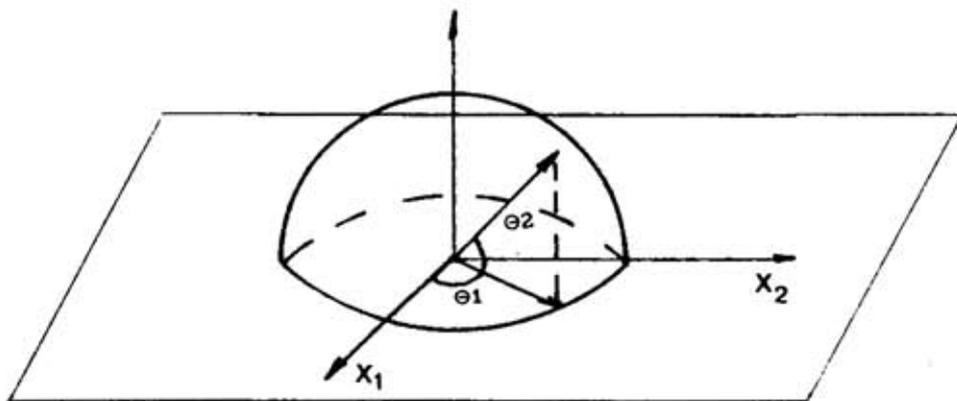


Fig. 1.2 - Produto $E \times D$.

2) Imagem digital

Supõe-se que E seja um retângulo de Z^2 que forma uma superfície. Então, uma imagem digital g é uma função de E em K , onde K é um intervalo $[0,k]$ de Z (conjunto dos números inteiros relativos).

3) Elemento de imagem ("pixel")

Define-se como "pixel" aleatório aquele no qual $g(x)$ é uma variável aleatória. Neste caso, a imagem g é um campo aleatório constituído por "pixels" identicamente distribuídos. No Capítulo 3, supõe-se que a imagem seja dada por um campo aleatório e que, ao falar de "pixel", faz-se referência a "pixel" aleatório .

4) Modelo de imageador

Um imageador ou um sensor φ_1 é um sistema de aquisição que, a partir de uma cena f , produz uma imagem digital g (Figura 1.3).



Fig. 1.3 - Modelo de imageador.

$$f : E \times D \times S \rightarrow \mathbb{R}^+ \quad , \quad g : E' \rightarrow K'.$$

O modelo do imageador φ é dado por uma função, e a imagem digital produzida por φ a partir de f é dada por:

$$g(x') = \varphi(f)(x') \quad \text{para } x' \in E', \quad (1.5)$$

onde E' é o conjunto dos centros de detectores e \mathbb{R}^+ é o conjunto de comprimentos de onda.

O imageador não é exatamente linear, pois o contradomínio K de g não é um espaço vetorial. Porém, por simplificação, admite-se que seja linear e que a cena f seja lambertiana, isto é:

$$f(x, \theta, \lambda) = f(x, \lambda); \quad (1.6)$$

portanto, não há dependência de θ .

5) Imagem colorida

Considera-se E um conjunto de pontos que formam uma superfície, e K um conjunto de cores que formam uma palheta de cores.

Define-se uma imagem colorida g como um conjunto de "pixels" elementos de imagem, onde cada "pixel" p é caracterizado por uma posição p em E e por uma única cor $y(p)$ em K .

$$\begin{aligned} g : E &\rightarrow K. \\ p \in E &\rightarrow g(p) \in K. \end{aligned} \quad (1.7)$$

Na Figura 1.4 tem-se a representação esquemática de um "pixel" da imagem colorida.

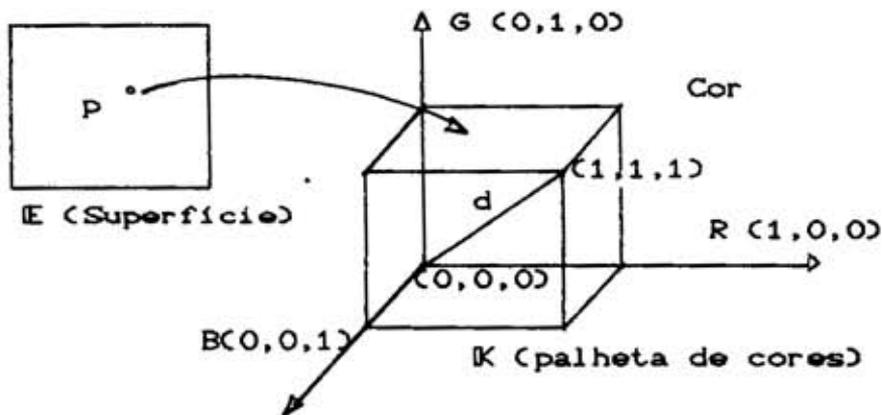


Fig. 1.4 - Representação de um "pixel".

Uma imagem colorida é, portanto, função de E em K .

6) Noção de cores

O sistema visual humano (SVH) comporta 3 tipos de cones (na retina). Cada cone tem uma sensibilidade espectral S_i , onde $i=1,2,3$. Seja $\varphi(\lambda)$ o valor da potência espectral da fonte de luz no comprimento de onda λ . Tem-se

que a potência absorvida pelo cone do tipo i é dada por:

$$\alpha_i = \int \varphi(\lambda) S_i(\lambda) d\lambda, \quad (1.8)$$

onde $i=1,2,3$.

A sensação de cores produzida pelo sistema visual humano está em relação biunívoca com a tripla $(\alpha_1, \alpha_2, \alpha_3)$.

Considerando que os $\alpha_i \in [0,1]$, eles indicam a proporção das cores primárias, vermelho (R), verde (G), e azul (B); a tripla $(\alpha_1, \alpha_2, \alpha_3)$ é tal que:

$$(\alpha_1, \alpha_2, \alpha_3) \in [0,1]^3, \quad (1.9)$$

onde $[0,1]^3 =$ cubo unitário RGB.

Supondo por hipótese que a tripla $(\alpha_1, \alpha_2, \alpha_3)$ corresponde ao branco de intensidade máxima, as arestas do cubo que não contêm $(0,0,0)$ e $(1,1,1)$ representam as cores de saturação máxima e de intensidade máxima. A Tabela 1.1 mostra a posição de algumas cores.

TABELA 1.1 - ARESTAS DO CUBO

| Representação | | | Cor |
|---------------|---|---|----------|
| R | G | B | |
| 0 | 0 | 0 | Preto |
| 0 | 0 | 1 | Azul |
| 0 | 1 | 0 | Verde |
| 0 | 1 | 1 | Ciano |
| 1 | 0 | 0 | Vermelho |
| 1 | 0 | 1 | Magenta |
| 1 | 1 | 0 | Amarelo |
| 1 | 1 | 1 | Branco |

Na Figura 1.5, mostra-se o cubo. A diagonal d representa os níveis de cinza. Para este caso os α_i são iguais.

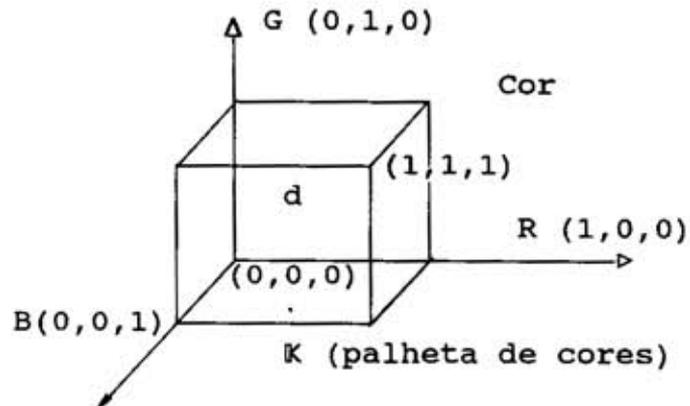


Fig. 1.5 - Palheta de cores do cubo RGB.

7) Imagem multiespectral

Define-se uma imagem multiespectral g com p bandas como a p -upla de p imagens digitais $g=(g_1, \dots, g_p)$.

8) Filtragem

No processo de filtragem espacial tem-se uma transformação dos valores dos "pixels". O novo valor do "pixel" na posição x depende tanto do valor original do "pixel" na posição x como dos valores dos "pixels" vizinhos. Em geral, "pixels" mais próximos têm uma contribuição maior que "pixels" afastados (Mascarenhas e Velasco, 1984; Moik, 1980).

A operação de filtragem linear e invariante em translação de g por um filtro de resposta impulsiva F é definida pela convolução de g por F . A operação é

representada por:

$$gf = g * F, \quad (1.10)$$

onde g é a imagem original, F é a resposta impulsiva do filtro, gf é a imagem filtrada e $*$ representa convolução.

Se o filtro F atenua as componentes de alta frequência, este filtro é chamado de filtro passa-baixa. Neste caso há suavização dos contornos, borramento da imagem e diminuição de resolução espacial.

Se o filtro F atenua as componentes de baixa frequência, este filtro é chamado filtro passa-alta. Neste caso há realce de bordas, o que dá a impressão de maior nitidez na imagem.

9) Reamostragem

Na área de processamento de imagens, a técnica de estimação dos valores de amostras de uma imagem em pontos de uma grade desejada, a partir de amostras na grade original, é conhecida por reamostragem ou interpolação.

1.3.2 - MODELO ESTOCÁSTICO DA IMAGEM

Seja $g : E \rightarrow K$ uma imagem digital, onde $|E|$ é finita e $K = \{0, 1, 2, \dots, 255\}$.

1) Histograma

O histograma $Hg(k)$ é dado pela razão entre o número de "pixels" com radiometria k e o número total de "pixels", onde $k \in K$. $Hg(k)$ é uma ferramenta básica utilizada para realce e análise de imagens, a qual fornece a distribuição dos níveis de cinza da imagem. É definida

por:

$$Hg : K \rightarrow \mathbb{R}^+, \text{ tal que:} \quad (1.11)$$

$$Hg(k) = 1/|E| \sum_{x \in E} 1_{\{k\}}(g(x)), \quad (1.12)$$

onde $1_{\{k\}}$ é a função indicadora,

$$1_A(k) = \begin{cases} 1 & \text{se } k \in A, \\ 0 & \text{se não.} \end{cases}$$

2) Média

A média de uma imagem g representa a impressão geral do brilho médio da imagem, que é definida por :

$$\mu_g = \bar{g} = \sum_{k \in K} k Hg(k). \quad (1.13)$$

Atribui-se $k = 255$ ao nível de cinza do branco e $k = 0$ ao nível de cinza do preto. Se $\mu_g < \mu_{g'}$, então a imagem g tem menor brilho que g' , ou seja, é mais escura que a imagem g' .

3) Variância da imagem

A variância indica o contraste da imagem g e mostra o espalhamento dos valores dos "pixels" da imagem em torno da média.

$$\text{Var}(g) = \sigma_g^2 = \sum_{k \in K} (k - \mu_g)^2 H_g(k). \quad (1.14)$$

Se $\sigma_g < \sigma_{g'}$, então a imagem g possui menor contraste que g' .

4) Covariância

A covariância entre as imagens g_1 e g_2 é obtida por:

$$\text{Cov}(g_1, g_2) = \sum_{(k_1, k_2) \in K^2} (k_1 - \mu_{g_1})(k_2 - \mu_{g_2}) H_{g_1, g_2}(k_1, k_2), \quad (1.15)$$

onde:

$$H_{g_1, g_2}(k_1, k_2) = 1/|E| \sum_{x \in E} 1_{\{k_1, k_2\}}((g_1(x), g_2(x))).$$

Se $\text{Cov}(g_1, g_2) = 0$, então diz-se que g_1 e g_2 são imagens não-correlacionadas.

5) Matriz de covariância

A matriz de covariância de uma imagem multiespectral $g(g_1, \dots, g_p)$, onde $g_i: E \rightarrow \mathbb{R}$ $i = 1, \dots, p$,

é denotada como Σ_g e dada por:

$$\Sigma_g = \begin{bmatrix} \text{Var}(g_1) & \dots & \text{Cov}(g_1, g_p) \\ \vdots & \ddots & \vdots \\ \text{Cov}(g_p, g_1) & & \text{Var}(g_p) \end{bmatrix} \quad (1.16)$$

ou:

$$\Sigma_g = [\text{Cov}(g_i, g_j)]_{p \times p} .$$

1.3.3 - RESOLUÇÃO

Há três espécies de resolução, a saber: resolução espacial, resolução espectral e resolução radiométrica.

1) Resolução espacial

A resolução espacial é aquela em que se tomam propriedades geométricas do sistema imageador no terreno (Slater, 1980; Mather, 1987). Em Andrade (1990) define-se resolução espacial como o número de "pixels" que representam uma dada área na cena. Imagens de alta resolução são as que possuem muitos "pixels" para representar uma dada área na cena; imagens de baixa resolução são as que possuem poucos "pixels" para representar esta mesma área. Portanto, a resolução espacial de uma imagem digital é dada pelo número de "pixels" por unidade de área.

2) Resolução espectral

A resolução espectral é dada pela largura das bandas de frequência dos diversos canais do sistema sensor.

Bandas estreitas contêm dados mais precisos das radiações dos alvos, ou seja, melhor resolução espectral. Existe uma limitação para altas resoluções espectrais, que é dada por uma redução da razão sinal/ruído devido à baixa quantidade de energia refletida pelo alvo e captada pelo sensor (lei de Plank).

3) Resolução radiométrica

A resolução radiométrica refere-se ao número de níveis digitais usados para expressar os dados coletados pelo sensor. De um modo geral, pode-se afirmar que o detalhe na informação está diretamente relacionado com o número de níveis de cinza para representá-lo (Mather, 1987).

1.3.4 - SENSOR HRV - SPOT

O satélite SPOT (Satellite Pour l'Observation de la Terre) é um sistema de sensoriamento remoto que foi desenvolvido pelo CNES (Centre National d'Études Spatiales), na França, com a colaboração da Bélgica e da Suécia. Ele contém dois sensores, HRV1 e HRV2 (High Resolution Visible), que funcionam de forma independente. Seus modos de operação são: o pancromático, com uma única banda (0,51 - 0,73 μ m) e uma resolução espacial de 10m; e o multiespectral, com resolução espacial de 20m e 3 bandas espectrais (XS1: banda do espectro do verde 0,50 - 0,59 μ m, XS2: banda do espectro do vermelho 0,61 - 0,68 μ m, XS3: banda do espectro do infravermelho 0,79 - 0,89 μ m).

As vantagens deste satélite são : o poder de resolução espacial e visada fora do nadir, que varia numa faixa de mais ou menos 27°.

O sensor HRV - SPOT não utiliza uma varredura de espelhos como o Landsat MSS e o TM. Sua varredura é dada por um "array" de detectores (6.000 no caso pancromático e 3000 no caso multiespectral). Este tipo de varredura, denominado "pushbroom scanner", tem a vantagem de não apresentar problemas mecânicos na varredura do espelho, mas ocorrem problemas de calibração e alinhamento de detectores.

Os dados não podem ser utilizados diretamente da forma como são recebidos. Dependendo do estudo a ser feito, são necessárias correções radiométricas e geométricas. São apresentadas a seguir os níveis de processamento (Cerbelaud, 1990; CNES, 1989).

- Nível 1A

Para este nível são feitas apenas correções radiométricas.

- Nível 1B

Inclui correções radiométricas e geométricas.

- Nível 2

Nível de precisão. É utilizado quando se necessita de maior precisão cartográfica ou para integração ("merging") de dados com outras fontes diferentes.

- Nível S

Este nível registra imagens de um dado local em passagens diferentes.

Neste trabalho utilizam-se as imagens SPOT com nível 1B (maiores detalhes em CNES, 1989).

O registro das bandas multiespectrais com aquisição simultânea é garantido (CNES, 1989). Porém, o mesmo não ocorre entre bandas multiespectrais e banda pancromática, mesmo que tenham sido obtidas simultaneamente (Begni et al., 1985). Isto ocorre porque os "arrays" de detectores são distintos; portanto, a disposição geométrica destas bandas não é garantida.

Para estudos onde se trabalha simultaneamente com o modo multiespectral e pancromático, é necessário fazer uma sobreposição dos "pixels" relativos a uma ponto de referência na cena.

1.3.5 - ESTIMADOR DE BAYES

Supõe-se que, em um dado experimento, seja possível observar a variável aleatória (v.a) Z. Deseja-se estimar uma v.a. X a partir da observação da v. a. Z de forma ótima. Denota-se \hat{X} o estimador de X.

Na estimativa de X, comete-se um erro de estimação, que é dado por:

$$\varepsilon = X - \hat{X}. \quad (1.17)$$

Associa-se uma função custo $C(X, \hat{X})$ a todos os pares (X, \hat{X}) . Supondo que $C(X, \hat{X})$ dependa apenas do erro de estimação, tem-se que a função custo será dada por $C(\varepsilon)$. Por definição, o risco de Bayes é representado pela esperança do custo (Sage e Melsa, 1971; Melsa e Cohn,

1978), ou seja:

$$R = E[C(\mathcal{E})], \quad (1.18)$$

$$R = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} C(\mathcal{E}) P_{X,Z}(\partial X, \partial Z).$$

A probabilidade condicional $P_{Z/X}$ verifica que:

$$P_{X,Z} = P_{Z/X} P_X, \quad (1.19)$$

onde P_X é a probabilidade a priori de X .

Definição 1.2.1 \hat{X} é um estimador de Bayes de X , dado Z , relativamente a uma função de custo C , se e somente se:

$$\begin{aligned} \hat{X} &\in U^Z, \\ E[C(X, \hat{X})] &\leq E[C(X, U)]. \quad \forall U \in U, \end{aligned}$$

onde U^Z é o conjunto de todas as funções de Z (Banon, 1983).

Supõe-se que a função custo seja dada pelo quadrado da norma de \mathcal{E} .

$$C(\mathcal{E}) = \mathcal{E}^2, \quad \text{onde } \mathcal{E} \in \mathbb{R}. \quad (1.20)$$

Substitui-se a Equação 1.20 na Equação 1.18. A estimação de X será ótima se o risco de Bayes for mínimo. Para obter o risco mínimo, diferencia-se o risco de Bayes e tem-se que o estimador será dado por:

$$\hat{X} = E(X/Z). \quad (1.21)$$

Definição 1.2.2 $E(X/Z)$ é a esperança condicional de X dado Z , se e somente se $E(X/Z)$ é solução de:

$$E(X/Z) \in U^Z$$

$$E[XU] = E(E(X/Z)U) \quad \forall U \in U^Z$$

Portanto, \hat{X} será obtido pela média condicional de X , dada uma observação Z . Alguns autores denotam \hat{X} como estimador de mínima variância, já que o risco é minimizado a partir da variância condicional.

1.3.5.1 - PRINCÍPIO DA ORTOGONALIDADE

A estimativa ótima de uma v.a. X , a partir do custo quadrático, nem sempre é fácil de ser calculada, pois se deve conhecer a de probabilidade a posteriori $P_{X/Z}$. Considera-se aqui o caso particular da estimação linear. Para este caso, é necessário apenas o conhecimento dos dois primeiros momentos de X , dado Z , para obter o estimador \hat{X} .

Pelo princípio da ortogonalidade, tem-se que o risco será mínimo se o erro ε (Equação 1.17) for perpendicular ao subespaço onde \hat{X} está contido (Figura 1.6). A seguir detalha-se este princípio.

Supõe-se que a v.a. \hat{X} pertença a um espaço H^Z , onde H^Z é o conjunto de todas as variáveis aleatórias linearmente dependentes de Z com probabilidade um (Banon, 1983). Supõe-se também que:

$$E(X - \hat{X})^2 \leq E(X - U)^2 \quad \forall U \in H^Z. \quad (1.22)$$

Portanto, o risco deve ser mínimo para o estimador \hat{X} . Além disto, $H^Z \subset U^Z$.

Seja:

$$H = \{ \alpha X + \beta Z; (\alpha, \beta) \in \mathbb{R}^2 \}. \quad (1.23)$$

O conjunto H forma um espaço vetorial. Uma variável aleatória $U \in H$ será vista como um vetor de H .

O estimador \hat{X} será portanto um vetor de H^2 mais próximo de X . Então, tem-se que:

$$|| X - \hat{X} ||^2 \leq || X - U ||^2 \quad \forall U \in H^2, \quad (1.24)$$

onde $|| \cdot || = \mathbf{E}(\cdot^2)$

O erro ε será mínimo quando este for perpendicular ao subespaço H^2 .

Generalizando, supõe-se que Z seja um vetor de dimensão $n \times 1$. \hat{X} é uma combinação linear das n variáveis aleatórias Z^1, \dots, Z^n conhecidas, ou seja:

$$\hat{X} = a_1 Z^1 + \dots + a_n Z^n \quad (1.25)$$

Deseja-se obter as n constantes a_1, \dots, a_n para que o risco de Bayes seja mínimo. Isto ocorre quando o erro for perpendicular ao vetor Z . Supõe-se que X e \hat{X} são unidimensionais. Tem-se então pelo teorema da projeção (Papoulis, 1984):

$$\mathbf{E}[(X - \hat{X})Z^T] = 0. \quad (1.26)$$

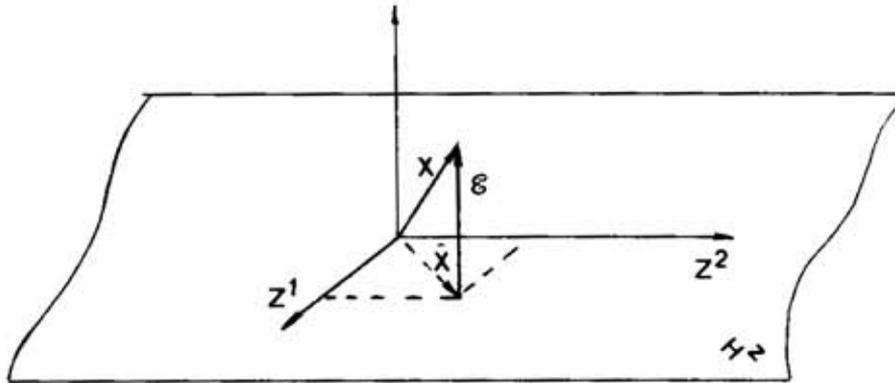


Fig. 1.6 - Interpretação geométrica da ortogonalidade
 FONTE: Papoulis (1984), p. 409.

O teorema da projeção indica que o risco de Bayes será mínimo se as constantes a_i (onde $i=1, \dots, n$) forem calculadas a partir da Equação 1.26. Duas provas desta Equação são apresentadas por Papoulis (1984).

A partir da Equação 1.26 desenvolvem-se as equações de Yule-Walker, que são dadas por:

$$\sum_{j=1}^n R_{ij} a_j = R_{oi}, \quad (1.27)$$

onde $R_{ij} = E[Z^i Z^j]$ e $R_{oi} = E[XZ^i]$, e $i = 1, \dots, n$ e $j = 1, \dots, n$

É fácil fazer com que o risco mínimo quadrático seja dado por (Papoulis, 1984):

$$R_{oo} - (a_1 R_{o1} + \dots + a_n R_{on}) = 0. \quad (1.28)$$

$$R_{oo} = E[X^2].$$

De forma vetorial as Equações 1.25 e 1.27 escrevem-se:

$$\hat{X} = AZ \text{ e } RA = R_0 \quad (1.29)$$

onde:

$$Z^T : [z^1, \dots, z^n],$$

$$A^T : [a_1, \dots, a_n],$$

$$R = [R_{ij}]_{\substack{i=1, \dots, n \\ j=1, \dots, n}}$$

$$R_0 = [R_{0i}]_{i=1, \dots, n}$$

Finalmente, resolvendo o sistema, encontrar-se-á vetor das constantes A, que é dado por:

$$A = R_0 R^{-1}, \quad (1.30)$$

$$A = E[XZ^T][E(ZZ^T)]^{-1}$$

No Capítulo 3, supõe-se que X e \hat{X} sejam vetores de v. a. de dimensão (n x 1) e Z um vetor de v. a. de dimensão (m x 1). Além disto, o estimador é obtido por uma equação linear não-homogênea a partir do vetor de v.a. Z. Então, para este caso, são determinados uma matriz A de dimensão n x m e um vetor B de dimensão n x 1.

1.3.5.2 - ESTIMADOR LINEAR NÃO-HOMOGÊNIO

Denota-se \hat{X} como estimador linear não homogêneo do vetor aleatório X ($m \times 1$), que é dado por:

$$\hat{X} = AZ + B, \quad (1.31)$$

onde A é uma matriz ($m \times n$) de constantes, Z é um vetor ($n \times 1$) dos valores observados e B é um vetor ($m \times 1$) de "offsets".

O caso linear homogêneo é um caso particular quando o vetor B é nulo.

Comete-se um erro de estimação do vetor aleatório X , que será denotado por ε .

$$\varepsilon = X - \hat{X}. \quad (1.32)$$

Associa-se uma função de custo na estimativa de X e supõe-se que esta função dependa apenas do erro de estimação ε . Neste caso, supõe-se que a função custo seja dada pelo quadrado da norma de ε . Então:

$$C(\varepsilon) = \varepsilon^T \varepsilon, \quad (1.33)$$

onde ε^T é o vetor transposto de ε .

A estimação de X será ótima se o risco de Bayes for mínimo. Este risco é dado pela esperança do custo da estimativa de X (Sage e Melsa, 1971; Melsa e Cohn, 1978).

$$R = E[C(\varepsilon)]. \quad (1.34)$$

Deseja-se encontrar a matriz A e o vetor B na Equação 1.31, para que o risco de Bayes seja mínimo. Portanto, supondo que o estimador é linear e diferenciando o risco em relação a cada elemento da matriz A, tem-se que a estimativa ótima será dada pelo princípio da ortogonalidade (Papoulis, 1984), apresentado na Equação 1.35.

$$E[\varepsilon Z^T] = 0. \quad (1.35)$$

Observa-se que na Equação 1.35 o erro de estimação é não correlacionado com os dados observados e a projeção de ε em relação a Z é zero.

Aplicando a esperança matemática na Equação 1.31, tem-se que:

$$E[\hat{X}] = AE[Z] + B. \quad (1.36)$$

Supondo que o estimador é não tendencioso, tem-se que:

$$B = E[X] - AE[Z]. \quad (1.37)$$

As matrizes de covariância de Z (Σ_{ZZ}) e de X em relação a Z (Σ_{XZ}) são dadas por:

$$\Sigma_{ZZ} = E[ZZ^T] - E[Z]E[Z^T]. \quad (1.38)$$

$$\Sigma_{XZ} = E[XZ^T] - E[X]E[Z^T].$$

Substituindo a Equação 1.37 na Equação 1.35 e conhecendo as matrizes de covariância na Equação 1.38,

tem-se que a matriz A será dada por:

$$A = \Sigma_{XZ} \Sigma_{ZZ}^{-1}, \quad (1. \quad)$$

onde Σ_{ZZ}^{-1} é inversa de Σ_{ZZ} .

O vetor B será então igual a:

$$B = E[X] - (\Sigma_{XZ} \Sigma_{ZZ}^{-1}) E[Z]. \quad (1.40)$$

Portanto, o estimador \hat{X} será dado por:

$$\hat{X} = E[X] + \Sigma_{XZ} \Sigma_{ZZ}^{-1} (Z - E[Z]). \quad (1.41)$$

CAPÍTULO 2

FUSÃO DE DADOS DE SENSORES

Este capítulo propõe uma revisão bibliográfica sobre o uso da fusão de dados em sensoriamento remoto. Dar-se-á maior ênfase aos métodos de Cliche et al. (1985), Dutra et al. (1988), Brum (1989) e Carper et al. (1990). O modelo desenvolvido em Brum (1989) será examinado com maior detalhe, pois fornece a base para o modelo desenvolvido no Capítulo 3.

2.1 - TRABALHOS EM FUSÃO DE DADOS DE SENSORES

O uso de fusão de dados no sensoriamento remoto tem por objetivo melhorar a análise visual e a interpretação das imagens de satélite, sendo possível utilizar simultaneamente informações complementares de cada sensor.

A utilização simultânea de informações de diferentes sensores poderá implicar em problemas ligados à resolução espacial e à resolução espectral. Portanto, na combinação destes dados, é necessário o desenvolvimento de técnicas para compatibilizá-los. Em geral, a metodologia aplicada exige o registro geométrico dos dados e, em seguida, a fusão de informação.

Os métodos em fusão desenvolvidos na literatura são descritos por: operações aritméticas (Cliche et al., 1985; Chavez 1986), transformação IHS (Hayden et al., 1982; Dutra et al., 1988; Carper et al., 1990), e principais componentes (Chavez, 1988; Chavez, 1991). Na literatura, existem outros métodos de interpolação, tais como os descritos em Brum (1989) e em

Candeias (1990).

Alguns trabalhos em fusão de dados são citados a seguir por ordem cronológica. Neles, o que se deseja é obter uma imagem sintética que preserve as características predominantes das imagens primárias.

Daily et al. (1978) fundiram imagens de RADAR e MSS-LANDSAT para interpretação geológica da litologia do terreno. As características de reflectância da superfície são dadas pelo sensor do LANDSAT; e informações de rugosidade da superfície, tamanho das partículas e constante dielétrica da camada superficial do terreno são dadas pelo RADAR.

Um produto semelhante à fotografia aérea em falsa cor foi obtida por Cliche (1985), a partir da simulação dos canais pancromático e multiespectrais do SPOT. Na simulação foi utilizado um SCANNER multiespectral de 11 canais DAEDALUS DS-1260. Um detalhamento maior encontra-se na Seção 2.2.

Chavez (1986) fundiu imagens TM-LANDSAT com fotografias aéreas digitalizadas na escala de 1:24.000. Segundo Chavez (1986), este método já era utilizado na literatura, com dados onde a resolução espacial variava de um fator de 2 a 3 (fusão de sensores, MSS e SIR-A; Simulação TM e SPOT, Simulação do SPOT com dados de 20 e 10 metros). Em seu trabalho, a diferença espacial obtida pelos sensores é grande (28 versus 4 m). Para evitar efeitos de blocos na imagem, utilizou-se filtro passa baixa. Foram observados bons resultados.

Prince (1987) desenvolveu uma técnica para combinar duas resoluções de dados digitais do HRV-SPOT

para obter o TM-LANDSAT com resolução de 15m . Com isto, seu produto tem a vantagem multiespectral do TM, bem como uma resolução espacial melhor. O objetivo deste trabalho é equivalente ao de Cliche et al. (1985), exceto que esta abordagem utiliza as propriedades estatísticas dos dados. Baseia-se na redundância existente entre a resolução multiespectral dos canais 1 e 2 com o pancromático.

Chavez (1991) faz uma revisão de alguns métodos, dentre os quais se tem a fusão de dados usando principais componentes. Inicialmente, selecionam-se algumas bandas do sensor TM para gerar as principais componentes. Em seguida, substitui-se a primeira principal componente pela banda do sensor que possui uma alta resolução espacial. Utiliza-se neste caso a banda pancromática do sensor HRV-SPOT. Finalmente, efetua-se uma rotação para o sistema RGB e obtém-se a imagem sintética.

A fusão de dados utilizando a transformação IHS é bastante utilizada na literatura. Menciona-se aqui o trabalho de Hayden (1982), no qual muitos trabalhos estão baseados. Citam-se como exemplos os trabalhos desenvolvidos em Dutra et al. (1988) e Carper et al. (1990), que estão resumidos nas Seções 2.4 e 2.5.

O trabalho desenvolvido por Brum (1989) usou os canais multiespectrais e pancromático do sensor HRV-SPOT para gerar 3 novas bandas sintéticas com resolução espacial de aproximadamente 10m e resolução espectral equivalente às bandas multiespectrais originais. Seu trabalho baseia-se em um modelo linear entre bandas, observando a superposição das faixas espectrais das bandas pancromática e multiespectrais. Além disto, utiliza interpolação geométrica, como bandas intermediárias para gerar a imagem sintética. A Seção 2.5 descreve melhor este modelo.

Considerando também a combinação linear de bandas do sensor HRV-SPOT, Mascarenhas et al. (1990) propuseram a simulação da banda pancromática a partir das bandas multiespectrais. O objetivo é diminuir a taxa de dados do canal de comunicação entre satélite e a Terra. Os métodos utilizados são: mínimos quadrados sem restrição de igualdade e mínimos quadrados com restrição de igualdade.

Também como referência, pode-se citar a publicação da conferência 3099 da NASA, 1991, intitulada "Multisource Data Integration in Remote Sensing", que apresenta vários trabalhos voltados para a fusão de dados.

A seguir são detalhados alguns métodos de fusão de dados.

2.1 - FUSÃO PELO MÉTODO DE CLICHE

Em seu trabalho, Cliche et al. (1985) simularam os canais multiespectrais e pancromático por meio de um "scanner" multiespectral de onze canais DAEDALUS DS-1260, com altitude de 4875 m.

Obteve-se um produto similar à fotografia aérea em falsa cor com as vantagens da resolução espacial do canal pancromático (P) (10 x 10m) e as vantagens da resolução espectral dos canais multiespectrais (S_i) (20 x 20m).

Três algoritmos de fusão foram propostos na simulação para produzir composições coloridas, porém o que apresentou melhor resultado visual (ver item 3) é o que possui menor correlação entre o pancromático e o infravermelho. Na simulação usaram-se "pixels" originais do canal pancromático P, e para os canais multiespectrais S_i

(onde $i = 1, 2, 3$) utilizou-se a duplicação de "pixel" em termos de coordenadas X e Y.

Os três algoritmos apresentados em Cliche et al. (1985) são:

1) Raiz quadrada do produto $P \times S_i$:

$$P_{sq_i} = A_a * (P * S_i)^{1/2} + B_a, \quad (2.1)$$

onde A_a é o ganho e B_a é o "offset". A imagem P_{sq_i} é a imagem resultante da fusão, $i=1, 2, 3$.

2) Produto $P \times S_i$, compensado pelo ganho e "offset"

$$P_{p_i} = A_b * (P * S_i) + B_b, \quad (2.2)$$

onde A_b é o ganho e B_b é o "offset". A imagem gerada é denominada P_{p_i} , $i = 1, 2, 3$.

3) Algoritmo que obteve melhor resultado:

• Fusão dos canais do visível:

$$P_i = A_1 * (P * S_i)^{1/2} + B_1, \quad (2.3)$$

onde $i=1, 2$

• Fusão do canal infravermelho:

$$P_3 = A_3 * (0.75S_3 + 0.25P) + B_3, \quad (2.4)$$

onde P_1 representa o canal sintético verde, P_2 o canal sintético vermelho e P_3 o canal sintético infravermelho. S_i são as bandas multiespectrais e P o canal pancromático. A_i são dados de ganho e B_i , dados de "offset", $i=1,2,3$.

Para todos os casos, cada "pixel" dos canais P e S_i é função da reflectância dos elementos da cena; portanto, $P * S_i$ ainda mantém esta proporcionalidade. A raiz quadrada nos casos "1" e "3" é utilizada para manter a faixa de 0-255 (Cliche et al., 1985).

No modelo "3" (ver Figura 2.1), observa-se que, na simulação da banda do infravermelho, há um peso maior para o canal S_3 quando comparado com o canal P , o que se justifica por ser o canal pancromático menos correlacionado com o infravermelho do que com os canais visíveis. A Figura 2.3 mostra a responsividade espectral do sensor HRV-SPOT.

Cliche et al. (1985) concluíram que há possibilidade de melhorar a resolução espacial para 10m, usando a fusão de dados dos canais do sensor HRV-SPOT multiespectrais e pancromático, o que resulta em um produto bastante semelhante à fotografia aérea em falsa cor.

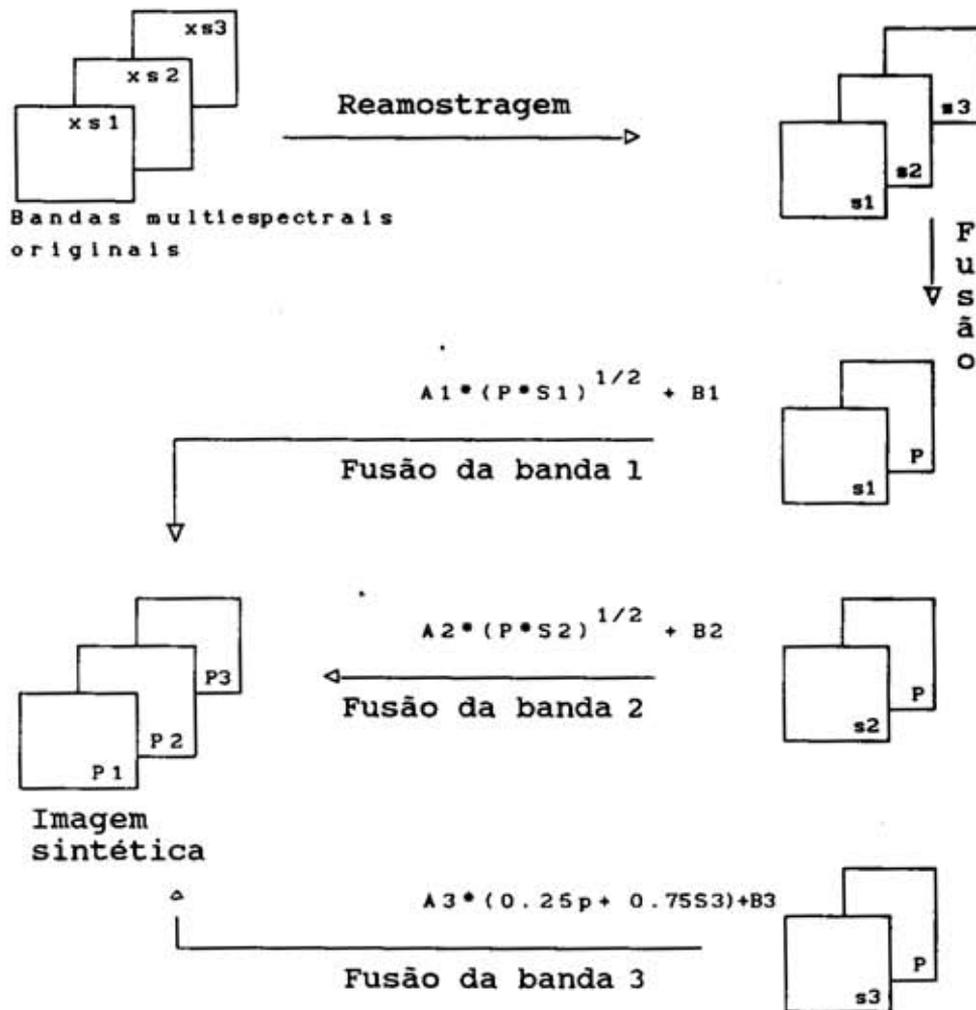


Fig. 2.1 - Interpolação pelo método de Cliche.

2.2 - FUSÃO PELO MÉTODO IHS

As composições coloridas de imagens multiespectrais usadas em processamento de imagens são apresentadas em monitores de vídeo, onde a representação básica destas cores se dá através das cores fundamentais RGB (vermelho, verde e azul). A percepção visual trabalha

com combinações independentes destas cores fundamentais, que são intensidade (I), ou brilho, matiz (H) e saturação (S). É possível trabalhar com os valores de IHS separadamente e obter melhor controle das composições (Dutra, 1987).

O olho humano contém bastonetes, responsáveis pela sensação de brilho, e os cones, responsáveis pela sensação de cor. Quando se substitui o canal I pelo canal pancromático P, altera-se brilho da imagem com resolução espacial melhor que a do sensor TM ou HRV-SPOT multiespectral. Sabe-se pela literatura que o olho humano tem maior sensibilidade para intensidade por conter mais bastonetes que cones. Portanto, substituindo o canal I pelo canal P, interpolando apenas os canais H e S e fazendo a transformação inversa, obter-se-á um produto com alta resolução espacial e espectral.

Em termos de vantagem, o IHS atua diretamente sobre as variáveis importantes ao olho humano. Os canais IHS são manipulados independentemente. Em termos de desvantagem, é necessário transformar IHS para RGB para para visualização em vídeo.

Vários algoritmos são citados na literatura para a transformação IHS, tais como os de: Smith (1978); ACM (1979); Siegal e Gillespie (1980); Haydn et al. (1982). Estes são diferenciados pela velocidade computacional bem como pelo método utilizado no cálculo da componente de intensidade I. Encontram-se também em Mather (1987) citações de vários trabalhos desenvolvidos usando IHS. Além disto, a transformação IHS pode ser encontrada em Schowengerdt (1983) e Moik (1980).

Os trabalhos apresentados nas Seções 2.3 e 2.4 baseiam-se em Haydn et al. (1982).

2.3 - MÉTODO DE TRANSFORMAÇÃO IHS DE DUTRA

No trabalho desenvolvido por Dutra et al. (1988), uma solução é dada para fusão de dados de sensores com resoluções espaciais e espectrais distintas. Esta fusão baseia-se na transformação do espaço das cores. Foram utilizados os sensores TM pelas suas características de multibanda e pela vantagem do poder de resolução espacial do sensor SPOT pancromático. O resultado é uma imagem colorida com resolução de 10m. Obtiveram-se bons resultados quando desenvolvida esta técnica para solo urbano.

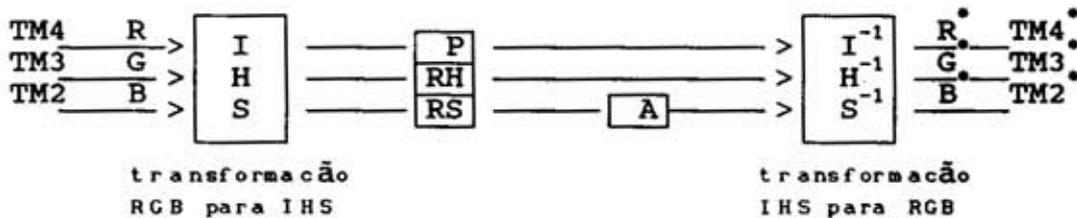


Fig. 2.2 - Fusão de dados usando transformação IHS.

Na Figura 2.2, o canal pancromático é representado por "P"; o canal "H" reamostrado, por "RH"; o canal "S" reamostrado, por "RS"; e a adição de saturação, por "A". Neste algoritmo utilizam-se os canais TM2, TM3 e TM4 do sensor TM por serem mais próximos espectralmente dos canais S1, S2 e S3 do HRV-SPOT.

Em Brum (1989), este método foi utilizado como comparação de seu método. Utilizaram-se neste caso os canais S1, S2 e S3 do sensor HRV-SPOT, em vez do canal TM2, TM3 e TM4 do sensor TM .

2.4 - MÉTODO DE TRANSFORMAÇÃO IHS DE CARPER

No método apresentado em Carper et al. (1990), nota-se que o canal pancromático não deve ser aplicado diretamente na componente I; deve-se utilizar um peso médio dos dados pancromáticos e infravermelho próximo.

$$WTA = ((2 * P) + RMS3) / 3, \quad (2.5)$$

onde WTA é a banda resultante; P é o canal pancromático; e RMS3 é o canal infravermelho reamostrado.

A justificativa da fórmula é que o canal pancromático é bastante correlacionado com as bandas do visível, e o canal referente ao infravermelho também influencia na intensidade global. Com isto, Carper et al. (1990) introduzem pesos para melhorar o IHS. Além disto, avaliam o seu resultado por meio de correlações dos dados obtidos pelo método de Cliche et al. (1985) e Welch et al. (1987).

Uma conclusão a que se chegou neste trabalho é que a substituição direta do canal pancromático na componente I não é ótima para mapear vegetação, mas é bastante útil para ocupação urbana. Além disto, o trabalho de Carper et al. (1990) sugere uma indicação na avaliação das bandas originais com as bandas geradas pelo modelo.

É interessante observar que a Equação 2.5 toma uma média ponderada para cada "pixel". Portanto, é de esperar que haja uma suavização na imagem gerada. Isto é observado no Capítulo 4.

2.5 - INTERPOLAÇÃO GEOMÉTRICA E FUSÃO DE DADOS

É examinado nesta seção um modelo de fusão de dados proposto por Banon e desenvolvido em Brum (1989).

2.5.1 - MÉTODO DE FUSÃO DE BRUM

Este método baseia-se na simulação de 3 bandas com resolução de 10m, a partir dos canais multiespectrais (20m) e pancromático (10m) do sensor HRV-SPOT.

A idéia geral consiste em escrever equações lineares que descrevam a dependência entre as variáveis observadas (valores dos "pixels" pancromático e multiespectrais originais) e as variáveis desconhecidas (valores dos "pixels" da imagem sintética de fusão).

O modelamento depende da superposição das faixas espectrais das bandas, o que é satisfeito para o sensor HRV-SPOT.

Como o sistema gerado por meio das combinações lineares entre bandas é do tipo subdeterminado, obtêm-se outras relações para tornar o sistema sobredeterminado. Utiliza-se reamostragem do vizinho mais próximo seguida de filtragens direcionais. Obtêm-se novas equações que irão tornar o sistema sobredeterminado. Os "pixels" dos canais sintéticos são descritos então a partir da Equação: $X = (A^T M A)^{-1} A^T M Y$, desenvolvida na Seção 2.5.6 .

Para teste de desempenho do método, Brum (1989) utilizou métodos de Cliche (1985) e IHS (Dutra, 1988).

2.5.2 - MODELAGEM

Considere-se $f(\lambda)$ a radiância espectral da cena; $g_i(\lambda)$, $i=1,2,3$ as responsividades espectrais das bandas multiespectrais do sensor HRV-SPOT; e $g_p(\lambda)$ a característica espectral da banda pancromática.

Os valores observados para cada "pixel" das bandas multiespectrais podem ser dados por:

$$s_i = \int f(\lambda) g_i(\lambda) d\lambda, \quad (2.6)$$

onde $i = 1, 2, 3$.

E para a banda pancromática:

$$p = \int f(\lambda) g_p(\lambda) d\lambda. \quad (2.7)$$

Como se pode observar na Figura 2.3, há superposição das faixas espectrais das bandas pancromática e multiespectrais.

O problema é encontrar um sistema linear de equações no qual a solução seja um bom estimador da resolução espacial de 10m e a resolução espectral seja equivalente aos canais multiespectrais do HRV-SPOT.

No trabalho de Brum (1989), não foram levados em consideração a dispersão da responsividade espectral entre os detetores, as variações da transmitância do divisor de feixe e o ruído intrínseco ao detetor. Haverá perda de precisão radiométrica nos resultados, porém isto não afetará a implementação e teste do método.

2.5.3 - GERAÇÃO DOS CANAIS ESTIMADOS

Definem-se E_i , $i = 1, 2, 3$ como os três canais estimados (10m). São definidas também 3 faixas correspondentes aos novos canais, como mostra a Tabela 2.1. Nota-se que, nesta Tabela, a faixa de E_i contém a faixa do canal multiespectral S_i .

TABELA 2.1 - CANAIS ESTIMADOS E CANAIS HRV-SPOT

| Canal estimado | Faixa (nm) | Canal HRV-SPOT (Original) | Faixa(nm) |
|----------------|------------|------------------------------|-----------|
| E1 | 480 - 600 | S1 | 495 - 585 |
| E2 | 600 - 740 | S2 | 615 - 680 |
| E3 | 740 - 920 | S3 | 775 - 880 |
| - | - | P | 500 - 730 |

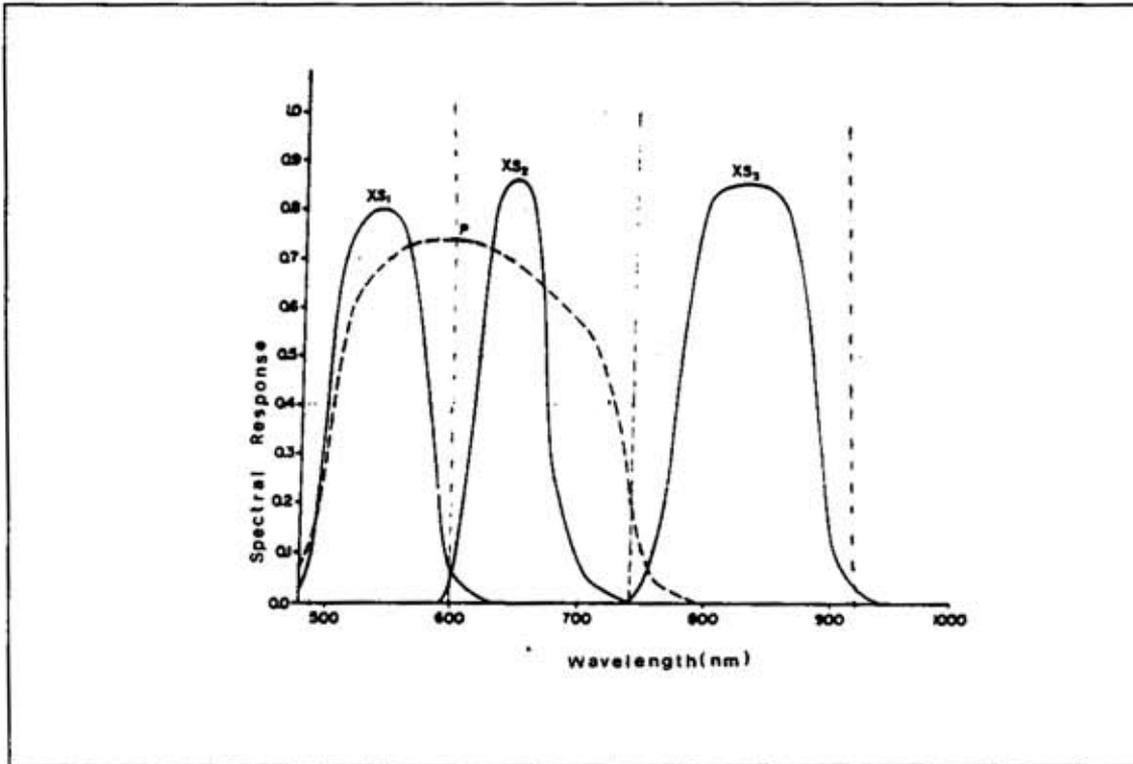


Fig. 2.3 - Curvas de responsividade espectral dos canais P, S1, S2 e S3 do sensor HRV, satélite SPOT.
FONTE: Brum (1989), p. 42.

O sistema linear estabelecido em Brum (1989) escreve-se:

$$Y_{7 \times 1} = H_{7 \times 12} X_{12 \times 1} \quad (2.8)$$

ou:

$$\begin{pmatrix} p_1 \\ p_2 \\ p_3 \\ p_4 \\ S_1 \\ S_2 \\ S_3 \end{pmatrix} = \begin{pmatrix} \alpha_1 & 0 & 0 & 0 & \alpha_2 & 0 & 0 & 0 & \alpha_3 & 0 & 0 & 0 \\ 0 & \alpha_1 & 0 & 0 & 0 & \alpha_2 & 0 & 0 & 0 & \alpha_3 & 0 & 0 \\ 0 & 0 & \alpha_1 & 0 & 0 & 0 & \alpha_2 & 0 & 0 & 0 & \alpha_3 & 0 \\ 0 & 0 & 0 & \alpha_1 & 0 & 0 & 0 & \alpha_2 & 0 & 0 & 0 & \alpha_3 \\ \beta_{11} & \beta_{11} & \beta_{11} & \beta_{11} & \beta_{11} & \beta_{12} & \beta_{12} & \beta_{12} & \beta_{12} & \beta_{13} & \beta_{13} & \beta_{13} & \beta_{13} \\ \beta_{21} & \beta_{21} & \beta_{21} & \beta_{21} & \beta_{21} & \beta_{22} & \beta_{22} & \beta_{22} & \beta_{22} & \beta_{23} & \beta_{23} & \beta_{23} & \beta_{23} \\ \beta_{31} & \beta_{31} & \beta_{31} & \beta_{31} & \beta_{31} & \beta_{32} & \beta_{32} & \beta_{32} & \beta_{32} & \beta_{33} & \beta_{33} & \beta_{33} & \beta_{33} \end{pmatrix} \begin{pmatrix} X_{11} \\ X_{12} \\ X_{13} \\ X_{14} \\ X_{21} \\ X_{22} \\ X_{23} \\ X_{24} \\ X_{31} \\ X_{32} \\ X_{33} \\ X_{34} \end{pmatrix}$$

onde $Y(7 \times 1)$ é o vetor dos valores dos "pixels" do sensor HRV-SPOT, $H(7 \times 12)$ é a matriz de transformação linear e $X(12 \times 1)$ é o vetor dos valores dos "pixels" dos canais sintéticos (ou estimados) E1, E2, E3.

Supõe-se na Equação 2.8 que P_1, P_2, P_3 e P_4 são os valores dos "pixels" do canal pancromático; S_1, S_2 e S_3 são valores dos "pixels" dos canais multiespectrais; e X_{ij} representa o valor do "pixel" sintético ($i = 1, 2, 3$; $j = 1, \dots, 4$).

A Equação 2.8 é um sistema subdeterminado. A determinação do vetor $X_{12 \times 1}$ não pode ser feita diretamente por aquela equação. A Seção 2.5.5 mostra uma interpolação

geométrica das bandas multiespectrais do HRV-SPOT que tornará a Equação 2.8 um sistema sobredeterminado. A Seção 2.5.6 mostra como é possível obter o vetor $X_{12 \times 1}$. A seguir definem-se as variáveis da Equação 2.8.

Define-se uma relação linear entre os canais sintéticos (ou estimados) e o canal pancromático, supondo para cada P_k (valor do "pixel" do canal pancromático) uma equação que se relaciona com os "pixels" estimados. Espacialmente não há alterações, pois P_k e X_{ik} têm resoluções espaciais de 10m. Espectralmente há pesos α_i para as contribuições das bandas estimadas.

$$P_k = \sum_{i=1}^3 \alpha_i X_{ik}, \quad (2.9)$$

onde $k = 1, 2, 3, 4$.

Supõe-se que i seja o índice do canal estimado, α_i a constante que relaciona cada canal estimado com o canal pancromático, k a posição do "pixel" no canal E_i , e X_{ik} o "pixel" estimado na posição k (Figura 2.4).

Para os S_j , $j = 1, 2, 3$ (resolução espacial de $20 \times 20m$), tem-se também um sistema linear que os relaciona com os canais estimados (resolução espacial de $10 \times 10m$). Como as resoluções espaciais são diferentes, é necessário agrupar 4 "pixels" de cada canal estimado (10m). Os pesos β_{ji} indicam a contribuição de uma dada banda estimada agrupando os 4 "pixels" estimados.

$$s_j = \sum_{i=1}^3 \beta_{ji} \left(\sum_{k=1}^4 X_{ik} \right), \quad (2.10)$$

onde $j = 1, 2, 3$ e $\beta_{ji} = b_i/4$.

Sabe-se que k representa a posição do "pixel" no canal estimado E_i ; i representa o índice do canal estimado, j representa o índice do canal multiespectral original; e X_{ik} é o valor do "pixel" estimado.

A Figura 2.4 é a representação esquemática da Equação 2.8:

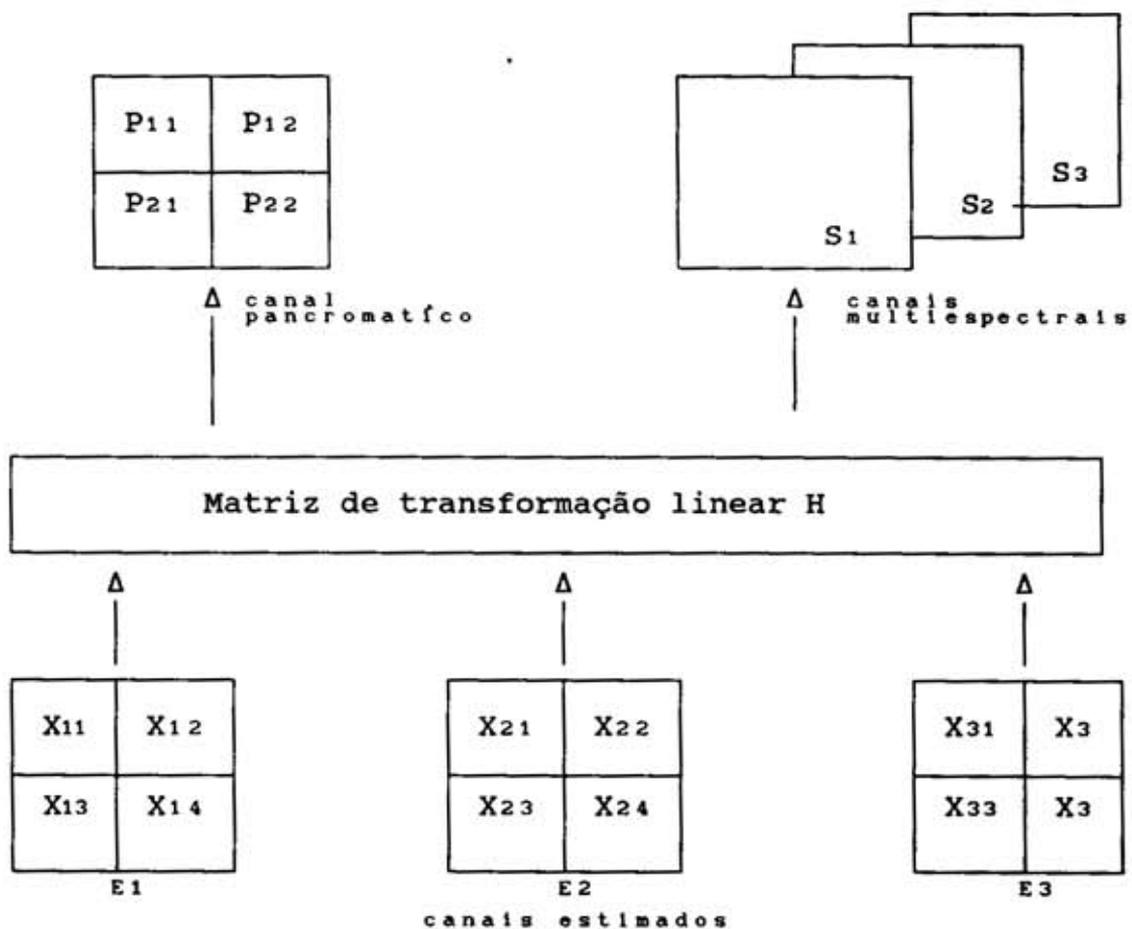


Fig. 2.4 - Combinação linear dos canais HRV - SPOT.

2.5.4 - DETERMINAÇÃO DAS CONSTANTES α_i E b_{jk}

As constantes α_i , $i=1,2,3$ representam o quanto cada canal pancromático está relacionado com o canal multiespectral estimado E_i ; portanto:

$$\alpha_i = (P \cap E_i) / P, \quad (2.11)$$

onde $i = 1, 2, 3$; P é a área abaixo da curva de responsividade espectral do canal pancromático; E_i é a área abaixo da curva de responsividade espectral do canal estimado.

Observando a Figura 2.3 e a Tabela 2.1, tem-se:

$$\sum_{i=1}^3 P \cap E_i = P. \quad (2.12)$$

Portanto, o somatório de α_i deve ser igual a 1, ou seja:

$$\sum_{i=1}^3 \alpha_i = (1/P) \left(\sum_{i=1}^3 P \cap E_i \right) = 1. \quad (2.13)$$

As constantes b_{jk} $j = 1, 2, 3$ e $k = 1, 2, 3$, representam o quanto cada canal multiespectral S_k está relacionado com um dado canal estimado E_i .

$$b_{jk} = (1/S_k) (S_k \cap E_i), \quad (2.14)$$

onde $k = 1, 2, 3$; $j = 1, 2, 3$; S_k é a área abaixo da curva de responsividade espectral de um canal multiespectral do sensor HRV-SPOT.

Observando a Figura 2.3 e a Tabela 2.1, tem-se:

$$\sum_{i=1}^3 S_k \cap E_i = S_k, \quad (2.15)$$

onde $k = 1, 2, 3$.

Portanto, o somatório de b_{kj} deve ser igual a 1, ou seja:

$$\sum_{j=1}^3 b_{kj} = (1/S_k) \left(\sum_{i=1}^3 S_k \cap E_i \right) = 1. \quad (2.16)$$

Cada b_{kj} , $k = 1, 2, 3$ e $j = 1, 2, 3$ representa o peso do canal E_k em relação ao canal multiespectral do HRV-SPOT S_k . Levando em consideração a resolução espacial diferente entre os "pixels" dos canais estimados E_k e os "pixels" dos canais S_k , o fator b_{kj} é dividido por quatro, gerando assim as constantes β_{kj} .

A Tabela 2.2 mostra os valores apresentados em Brum (1989) para α_i e b_{kj} , onde $i = 1, 2, 3$, $j = 1, 2, 3$ e $k = 1, 2, 3$. Para obter os valores de β_{kj} , divide-se b_{kj} por 4.

Percebe-se que usando as Equações 2.13 e 2.16 para a Tabela 2.2, há certa imprecisão das áreas relativas e o somatório é diferente da unidade.

TABELA 2.2 - VALORES DAS CONSTANTES α_i E b_{kj}

| Constante | Valor |
|------------|-------|
| α_1 | 0,433 |
| α_2 | 0,559 |
| α_3 | 0,017 |
| b_{11} | 0,994 |
| b_{12} | 0,018 |
| b_{13} | 0,0 |
| b_{21} | 0,0 |
| b_{22} | 0,993 |
| b_{23} | 0,0 |
| b_{31} | 0,0 |
| b_{32} | 0,0 |
| b_{33} | 0,996 |

2.5.5 - INTERPOLAÇÃO GEOMÉTRICA

Observa-se que a Equação 2.8 é um sistema subdeterminado para obter $X_{12 \times 1}$. O método sugerido em Brum (1989) é o de reamostrar os canais originais multiespectrais para gerar novas equações e transformar o sistema na Equação 2.8 num sistema sobredeterminado, sendo possível estimar os valores dos "pixels" X_{ij} .

Denota-se por Y^k o valor do "pixel" do canal multiespectral na posição k . São obtidas as distâncias de cada elemento k aos elementos ij . Tem-se que $i = 1, 2, 3$ (índice dos canais multiespectrais); $j = 1, 2, 3, 4$ (posição do pixel reamostrado); e $k = 1, \dots, 9$ (vizinhança do "pixel" reamostrado na posição j). A representação

esquemática da reamostragem encontra-se na Figura 2.5.

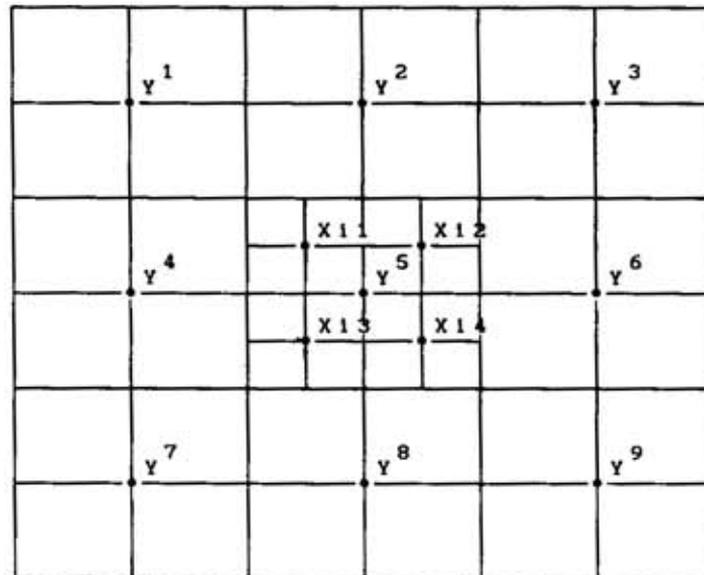


Fig. 2.5 - Processo de reamostragem

A partir das equações desenvolvidas que envolvem distâncias entre os "pixels" originais e reamostrados, são projetados quatro filtros F_j passa-baixas. Estes filtros não devem alterar a média da imagem original; portanto, cada um deles é multiplicado pelo inverso da somatória de todos os pesos (Brum, 1989).

Cada banda multiespectral será filtrada quatro vezes, cada vez com um filtro direcional. Geram-se novas equações para transformar o sistema subdeterminado em sobredeterminado. A seguir descreve-se o procedimento para geração da imagem interpolada geometricamente.

- 1) Filtragem da imagem S_i (imagens multiespectrais do HRV-SPOT) com os filtros F_j , onde $i = 1, 2, 3$ e $j = 1, \dots, 4$.

2) Geram-se a partir do procedimento 1 quatro imagens I_i , $i=1, \dots, 4$.

3) Monta-se uma nova imagem (Figura 2.7) com:

- I_1 = que define as linhas e colunas ímpares;
- I_2 = que define as linhas ímpares e colunas pares;
- I_3 = que define as linhas pares e colunas ímpares;
- I_4 = que define as linhas e colunas pares.

Os filtros são os seguintes:

$$F_1 = (1/100) \begin{vmatrix} 10 & 13 & 7 \\ 13 & 29 & 8 \\ 7 & 8 & 5 \end{vmatrix} \cdot \quad F_2 = (1/100) \begin{vmatrix} 7 & 13 & 10 \\ 8 & 29 & 13 \\ 5 & 8 & 7 \end{vmatrix} \cdot$$

$$F_3 = (1/100) \begin{vmatrix} 7 & 8 & 5 \\ 13 & 29 & 8 \\ 10 & 13 & 7 \end{vmatrix} \cdot \quad F_4 = (1/100) \begin{vmatrix} 5 & 8 & 7 \\ 8 & 29 & 13 \\ 7 & 13 & 10 \end{vmatrix} \cdot$$

Na construção dos filtros, observa-se que o valor com maior peso é o "pixel" central $(5, Y^5)$, pois este fornece mais informações na estimativa por ser o "pixel" mais próximo dos "pixels" reamostrados (j, X_{ij}) . Depois deste, a vizinhança constituída dos 4 "pixels" mais próximos dos "pixels" reamostrados (j, X_{ij}) é a que contribui mais para a estimativa do "pixel" (j, X_{ij}) (Figura 2.5).

A reconstrução da imagem pode ser observada na Figura 2.6.

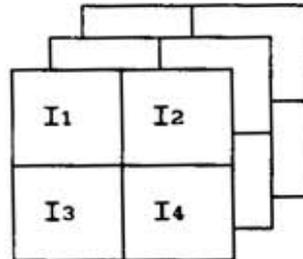


Fig. 2.6 - Reconstrução da imagem.

Com a aplicação dos filtros, geram-se 3 novas bandas interpoladas geometricamente. Com 12 novos valores Y_{ij} ($i = 1, 2, 3; j = 1, 2, 3, 4$) gerados a partir dos "pixels" dos canais multiespetrais, o sistema desenvolvido na Equação 2.8 torna-se sobredeterminado. Tem-se que i representa a banda e j representa a posição do "pixel" reamostrado, gerados a partir da vizinhança dos "pixels" (j, Y_{ij}) interpolados geometricamente.

2.5.6 - MONTAGEM DAS EQUAÇÕES

As 7 primeiras equações foram extraídas das características espectrais do sensor; as doze seguintes foram retiradas das operações de interpolação espacial envolvendo a disposição geométrica dos elementos da cena vistos na Seção 2.5.5.

Denomina-se o vetor $Y(19 \times 1)$ na Equação 2.20 como vetor dos "pixels" do sensor HRV-SPOT e dos "pixels" interpolados geometricamente obtidos pela filtragem direcional desenvolvida na Seção 2.5.5. $A(19 \times 1)$ é a matriz $H(7 \times 12)$ estendida com a matriz identidade $I(12 \times 12)$. $X(12 \times 1)$ é o vetor dos valores dos "pixels" reamostrados nas posições j para os três canais sintéticos.

Os valores dos "pixels" pancromáticos são representados por P1,P2,P3,P4. Os valores dos "pixels" dos canais multiespectrais são representadas por S1, S2 e S3. Os valores dos "pixels" dos canais multiespectrais interpolados geometricamente são representados por Yij, onde i = 1, 2, 3 (canal) e j = 1, 2, 3, 4 (posição no canal). Xij representam os canais sintéticos, onde i = 1, 2, 3 (canal) e j = 1, 2, 3, 4 (posição no canal) e Ej representa o erro no processo da reamostragem devido ao filtro passa baixas, onde j = 1, ..., 12.

$$Y_{19 \times 1} = A_{19 \times 12} X_{12 \times 1} + E_{19 \times 1}, \quad (2.20)$$

ou:

$$\begin{array}{l}
 P1 \\
 P2 \\
 P3 \\
 P4 \\
 S1 \\
 S2 \\
 S3 \\
 Y11 \\
 Y12 \\
 Y13 \\
 Y14 \\
 Y21 \\
 Y22 \\
 Y23 \\
 Y24 \\
 Y31 \\
 Y32 \\
 Y33 \\
 Y34
 \end{array}
 =
 \begin{array}{cccccccc}
 \alpha_1 & 0 & 0 & 0 & \alpha_2 & 0 & 0 & 0 \\
 0 & \alpha_1 & 0 & 0 & 0 & \alpha_2 & 0 & 0 \\
 0 & 0 & \alpha_1 & 0 & 0 & 0 & \alpha_2 & 0 \\
 0 & 0 & 0 & \alpha_1 & 0 & 0 & 0 & \alpha_2 \\
 \beta_{11} & \beta_{11} & \beta_{11} & \beta_{11} & \beta_{12} & \beta_{12} & \beta_{12} & \beta_{13} \\
 \beta_{21} & \beta_{21} & \beta_{21} & \beta_{21} & \beta_{22} & \beta_{22} & \beta_{22} & \beta_{23} \\
 \beta_{31} & \beta_{31} & \beta_{31} & \beta_{31} & \beta_{32} & \beta_{32} & \beta_{32} & \beta_{33}
 \end{array}
 \begin{array}{l}
 X11 \\
 X12 \\
 X13 \\
 X14 \\
 X21 \\
 X22 \\
 X23 \\
 X24 \\
 X31 \\
 X32 \\
 X33 \\
 X34
 \end{array}
 +
 \begin{array}{l}
 0 \\
 0 \\
 0 \\
 0 \\
 0 \\
 0 \\
 0 \\
 E1 \\
 E2 \\
 E3 \\
 E4 \\
 E5 \\
 E6 \\
 E7 \\
 E8 \\
 E9 \\
 E1 \\
 E1 \\
 E1
 \end{array}$$

O sistema dado na Equação 2.20 é sobredeterminado, sendo possível determinar sua solução de mínimos quadrados.

Multiplicando os dois lados da igualdade na Equação 2.20 por $A^T M$, obtém-se:

$$A^T M Y = A^T M X + A^T M E, \quad (2.22)$$

onde M é uma matriz quadrada de dimensão 19×19 , diagonal. Seus elementos ponderam as contribuições das características espectrais do sensor e das características geométricas.

Definem-se os elementos de M como:

$$M_i \begin{cases} m & ; \text{ para } 1 \leq i \leq 7 \\ n & ; \text{ para } 7 < i \leq 19 \end{cases}, \quad (2.23)$$

onde $m = v/7$ e $n = (1 - v)/12$.

Em Brum (1989), v assume valores de 0,7, 0,5 e 0,37. O valor de v dará o peso maior para as 7 primeiras equações quando $v > 0,37$, ou para as 12 últimas quando $v < 0,37$.

Tomando a Equação 2.22 e multiplicando-a por $(A^T M A)^{-1}$, tem-se:

$$Z = X + (A^T M A)^{-1} A^T M E, \quad (2.24)$$

onde

$$Z = (A^T M A)^{-1} A^T M Y. \quad (2.25)$$

Supondo que o erro E seja desprezível, o segundo termo da Equação 2.24 torna-se muito pequeno e as

estimações dos X_{ij} serão dadas pela matriz Z . Portanto, o estimador \hat{X} para a fusão é dado por:

$$\hat{X} = (A^T M A)^{-1} A^T M Y. \quad (2.26)$$

Em Brum (1989) foi examinado este caso particular. Supondo agora que a matriz $M = I$, onde I é a matriz identidade, têm-se:

$$\hat{X} = (A^T A)^{-1} A^T Y, \quad (2.27)$$

$$H^+ = (A^T A)^{-1} A^T, \quad (2.28)$$

$$\hat{X} = H^+ Y, \quad (2.29)$$

onde H^+ é a pseudo-inversa da matriz H , que oferece a solução de mínimos quadrados de um sistema sobredeterminado de equações, com as colunas de H linearmente independentes (Apêndice C).

2.5.7 - ANÁLISE DE RESULTADOS

No trabalho de Brum (1989), foram geradas 3 bandas estimadas com resolução espacial próxima de 10m e resolução espectral semelhante à resolução dos canais multiespectrais do HRV-SPOT.

Conclui-se que, para $v > 0,5$, o sistema a ser resolvido será mais próximo do sistema subdeterminado e a solução tende a ser a de mínima norma. Portanto, o valor dado a v é de grande importância, para que o sistema tenha soluções adequadas. Os melhores resultados são observados quando $v = 0,7$. Em Brum (1989) há uma comparação com os valores de v iguais a 0,5, 0,7 e 0,37 ($m = n$).

Com $v = 0,7$, os métodos de IHS (Dutra, 1988) e de Brum (1989) apresentaram resultados semelhantes, tendo este último método obtido uma resolução espectral melhor (Brum, 1989). Notou-se ainda que a imagem gerada pelo método de Cliche (1985) apresentou-se mais borrada quando comparada com a imagem dada em Brum (1989), com $v = 0,7$.

CAPÍTULO 3TEORIA BAYESIANA DE ESTIMAÇÃO E FUSÃO DE DADOS

Neste capítulo é examinado um método de interpolação para fusão de dados de satélites proposto por Mascarenhas, utilizando técnicas estatísticas bayesianas. Tanto os "pixels" na grade original como aqueles situados na grade interpolada são considerados variáveis aleatórias. A estimação linear dos "pixels" interpolados é feita pelo critério de mínimo erro médio quadrático através da solução do sistema de equações normais, que envolve as correlações espaciais e espectrais. É admitida a hipótese de separabilidade da estrutura de correlação nas direções horizontal, vertical e espectral. Além disso, supõe-se um modelo markoviano para as correlações espaciais. São desenvolvidos dois estimadores denominados respectivamente estimador espacial (interpolação estatística espacial) e estimador total (espacial e espectral). Para o estimador total supõe-se que haja conhecimento a priori de uma média e de uma matriz de covariância. Denomina-se imagem sintética a imagem gerada pelo estimador total.

3 - INTERPOLAÇÃO ESTATÍSTICA ESPACIAL

Supõe-se uma relação linear não-homogênea que transforme as imagens multiespectrais primárias g , geradas pelo sensor HRV-SPOT, em imagens interpoladas espacialmente g' . A definição destas imagens é dada por:

$$\begin{aligned} g: E &\rightarrow K^3, \\ g': E' &\rightarrow K^3, \end{aligned}$$

$$\begin{aligned} \text{onde } K &= \{0, 1, \dots, 255\}, \\ E &= \{0, 1, \dots, n-1\}^2, \\ E' &= \{1, \dots, 2(n-1)\}^2, \end{aligned}$$

E representa o conjunto de pontos de uma superfície; E' representa o conjunto de pontos na grade mais fina; e K representa os valores radiométricos contidos nas três bandas multiespectrais do sensor HRV- SPOT.

Define-se "pixel" (p_{1c}) de uma banda qualquer g_i da imagem g como um par constituído de uma posição $y = (l, c)$ e um nível de cinza $g_i(y)$ (Banon, 1989). Portanto:

$$p_{1c} = (y, g_i(y)). \quad (3.1)$$

Portanto $y = (l, c)$, e o valor assumido por $g_i(y)$ pertence a K , onde l representa linha e c representa coluna.

O estimador de "pixels" multiespectrais interpolados é do tipo linear não-homogêneo. Portanto, sua representação é obtida por:

$$\hat{X}_{12 \times 1} = A_{12 \times 27} Y_{27 \times 1} + B_{12 \times 1}. \quad (3.2)$$

Deseja-se calcular A e B de tal forma que o risco seja mínimo. Para o cálculo de $\hat{X}_{12 \times 1}$ será utilizada a Equação 1.41. Tem-se então :

$$\hat{X}_{12 \times 1} = E[X]_{12 \times 1} + (\Sigma_{XY})_{12 \times 27} (\Sigma_{YY}^{-1})_{27 \times 27} (Y_{27 \times 1} - E[Y]_{27 \times 1}). \quad (3.3)$$

A seguir são apresentadas algumas definições e, posteriormente, o cálculo de cada elemento da Equação 3.3.

Define-se bloco $_k^i(\cdot)$ a partir de um ponto y da banda g_i como uma matriz de "pixels" com k linhas e k colunas, onde $i=1, 2, 3$.

Supondo p_{1c} um "pixel" em linha 1 e coluna c, define-se $\text{bloco}_k^1(p_{1c}^*)$ relativo à banda g_i^* por:

$$\text{bloco}_k^1(p_{1c}^*) = \begin{bmatrix} p_{1,c}^* & p_{1,c+1}^* & \cdots & p_{1,c+n}^* \\ p_{1+1,c}^* & p_{1+1,c+1}^* & \cdots & p_{1+1,c+n}^* \\ \vdots & \vdots & \vdots & \vdots \\ p_{1+n,c}^* & p_{1+n,c+1}^* & \cdots & p_{1+n,c+n}^* \end{bmatrix}_{K \times K}, \quad (3.4)$$

onde $i = 1, 2, 3$ e;
 $n = 1$ para $k = 1$;
 $n = k - 1$ para $k > 1$.

Define-se a função $\phi(\cdot)$ como a ordenação lexicográfica por coluna do $\text{bloco}_k^1(\cdot)$. Portanto:

$$\phi^T(\text{bloco}_k^1(p_{1c})) = [p_{1,c}; p_{1,c+1}; \cdots; p_{1+n,c+n}], \quad (3.5)$$

onde $\phi^T(\cdot)$ é a transposta de $\phi(\cdot)$.

O vetor $Y_{27 \times 1}$ é composto por subvetores Y_j 9×1 , onde $j = 1, 2, 3$. Cada Y_j representa um $\text{bloco}_3^j(\cdot)$. Então :

$$Y_{1 \times 27}^T = [\phi^T(\text{bloco}_3^1(p_{1c})); \phi^T(\text{bloco}_3^2(p_{1c})); \phi^T(\text{bloco}_3^3(p_{1c}))]. \quad (3.6)$$

Como $k = 3$, tem-se um bloco com três linhas e três colunas (ver Figura 3.1).

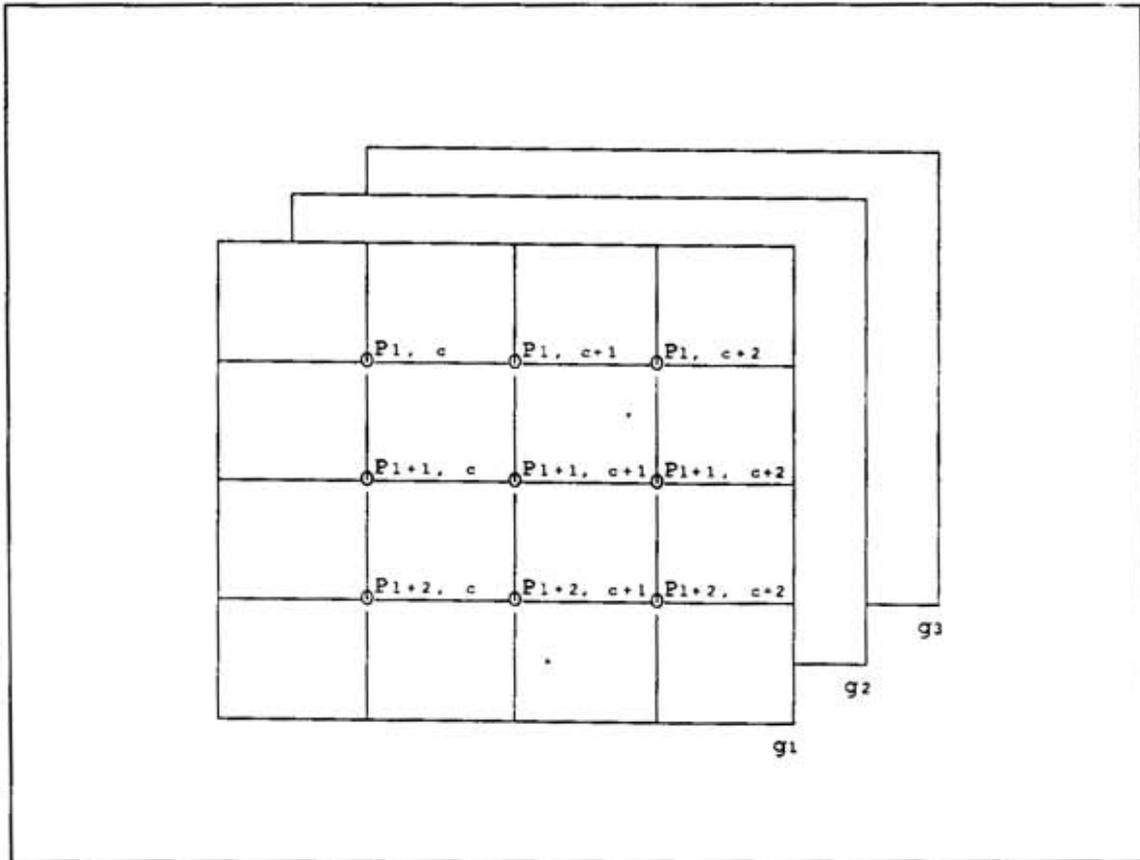


Fig. 3.1 - Representação de um bloco com três linhas e três colunas.

O vetor de "pixels" interpolados $\hat{X}_{12 \times 1}$ é composto por subvetores $X_{14 \times 1}$, onde $i = 1, 2, 3$. Cada $X_{14 \times 1}$ é representado por um bloco $\text{bloco}_2^i(\cdot)$. O valor de cada "pixel" é gerado a partir do bloco $\text{bloco}_3^1(\cdot)$ da banda primária. A representação é vista a seguir:

$$\hat{X}_{1 \times 12}^T = [\phi^T(\text{bloco}_2^1(p_{1c})); \phi^T(\text{bloco}_2^2(p_{1c})); \phi^T(\text{bloco}_2^3(p_{1c}))]. \quad (3.7)$$

Para gerar a imagem interpolada g' , deve-se iniciar o deslocamento do bloco $\text{bloco}_3^1(p_{1c})$ a partir do início de g e, em seguida, percorrer todas as colunas e todas as

linhas até a linha final menos 2. Observa-se que as primeiras linha e coluna e as últimas linha e coluna não serão interpoladas. Então a imagem interpolada será menor que o dobro de linhas e colunas da imagem original.

Supõe-se que $E[Y]_{27 \times 1}$ seja formado por subvetores $E[Y_i]_{9 \times 1}$, onde $i = 1, 2, 3$ e seus valores sejam respectivamente iguais à média μ_i da banda g_i .

Por hipótese, considera-se que a média μ_i de g_i não deve ser alterada após a interpolação. Portanto, tem-se que $E[X]_{12 \times 1}$ será formada por subvetores $E[X_i]_{4 \times 1}$, com valores iguais a μ_i , onde $i = 1, 2, 3$.

Para obter as matrizes de covariância Σ_{XY} e Σ_{YY} , supõe-se que na estimativa dos "pixels" interpolados sejam levados em consideração a separabilidade das direções horizontal, vertical e espectral, e um processo markoviano para correlações espaciais (Mascarenhas e Prado, 1980).

Seja ρ_{ij} o coeficiente de correlação entre Y_i e Y_j , isto é,

$$\rho_{ij} = \sigma_{ij}^2 / \sqrt{\sigma_{ii}^2 \sigma_{jj}^2}, \quad (3.8)$$

onde σ_{ij}^2 é a covariância entre Y_i e Y_j , e σ_{ii}^2 é a variância de Y_i .

Denota-se por ρ_H o coeficiente de correlação horizontal e por ρ_V o coeficiente de correlação vertical.

Supõe-se que a matriz de covariância entre X e Y seja dada por:

$$\Sigma_{XY} = (R_H)_{XY} \otimes (R_V)_{XY} \otimes (\Sigma)_E. \quad (3.9)$$

e que a matriz de covariância de Y seja dada por:

$$\Sigma_{YY} = (R_H)_{YY} \otimes (R_V)_{YY} \otimes (\Sigma)_E, \quad (3.10)$$

onde R_H representa a matriz de coeficientes de correlação horizontal, R_V representa a matriz de coeficientes de correlação vertical e $(\Sigma)_E$ representa a matriz de covariância espectral.

O símbolo \otimes representa o produto de Kronecker (Graybill, 1969). Sua definição e a propriedade da inversa encontram-se no Apêndice A.

O produto de Kronecker não é comutativo, isto é, $A \otimes B$ é diferente de $B \otimes A$. Portanto, dependendo do arranjo deste produto, poder-se-iamos obter resultados diferentes. Entretanto, a ordenação lexicográfica adotada inicialmente por linhas, em seguida por colunas e por último, por bandas, torna obrigatória a sequência H, V e E adotada nas Equações 3.9 e 3.10.

Define-se $(R)_{YY}$ por (ver Apêndice D):

$$(R)_{YY} = \begin{bmatrix} 1 & \rho & \rho^2 \\ \rho & 1 & \rho \\ \rho^2 & \rho & 1 \end{bmatrix}. \quad (3.11)$$

Supõe-se então que $(R_H)_{YY}$ e $(R_V)_{YY}$ são dados por $(R)_{YY}$, com $\rho = \rho_H$ e ρ_V , respectivamente.

Seja $(R)_{XY}$ a matriz dada por:

$$(R)_{XY} = \begin{bmatrix} \rho^{3/4} & \rho^{1/4} & \rho^{5/4} \\ \rho^{5/4} & \rho^{1/4} & \rho^{3/4} \end{bmatrix}. \quad (3.12)$$

Supõe-se então que $(R_H)_{XY}$ e $(R_V)_{XY}$ são dados por $(R)_{XY}$, com $\rho = \rho_H$ e ρ_V , respectivamente.

A especificação das potências de ρ na matriz $(R)_{XY}$ dada pela Equação 3.12 depende das distâncias entre os "pixels" interpoladores X e os "pixels" interpolados (Y) nas direções horizontal ou vertical, adotando o modelo markoviano.

A matriz de covariância espectral, que é igual à matriz de covariância entre bandas, é dada por:

$$(\Sigma)_E = \begin{bmatrix} \sigma_{11}^2 & \sigma_{12}^2 & \sigma_{13}^2 \\ \sigma_{21}^2 & \sigma_{22}^2 & \sigma_{23}^2 \\ \sigma_{31}^2 & \sigma_{32}^2 & \sigma_{33}^2 \end{bmatrix}. \quad (3.13)$$

Portanto, conhecem-se todos os elementos da Equação 3.3.

3.1 - CÁLCULO DA MATRIZ DE COVARIÂNCIA C

A matriz C é denotada como matriz de covariância do estimador espacial. Esta matriz é positiva e definida, sendo dada por:

$$C_{12 \times 12} = E[(\hat{X}_{12 \times 1} - E[\hat{X}]_{12 \times 1})(\hat{X} - E[\hat{X}]_{12 \times 1})^T], \quad (3.14)$$

onde $\hat{X}_{12 \times 1}$ é o estimador espacial e $E[\hat{X}]_{12 \times 1}$ é a média do interpolador.

Supõe-se que \hat{X} seja obtido por um sistema linear não-homogêneo visto na Equação 3.3.

Substituindo a Equação 3.2 na Equação 3.14, tem-se que C é dado por:

$$C = A \Sigma_{YY}^{-1} A^T. \quad (3.15)$$

A matriz A é obtida na Equação 1.39; portanto:

$$C = \Sigma_{XY} \Sigma_{YY}^{-1} \Sigma_{XY}^T. \quad (3.16)$$

A matriz C é formada por submatrizes $C_{ij4 \times 4}$, onde $i = 1, 2, 3$ e $j = 1, 2, 3$.

$$C_{12 \times 12} = \begin{bmatrix} C_{11 \ 4 \times 4} & C_{12 \ 4 \times 4} & C_{13 \ 4 \times 4} \\ C_{21 \ 4 \times 4} & C_{22 \ 4 \times 4} & C_{23 \ 4 \times 4} \\ C_{31 \ 4 \times 4} & C_{32 \ 4 \times 4} & C_{33 \ 4 \times 4} \end{bmatrix}. \quad (3.17)$$

A matriz C não avalia as bandas apenas de forma espectral; também utiliza em seu cálculo informações espaciais. Entende-se por informação espacial as correlações horizontais e verticais existentes entre "pixels" dentro de uma mesma banda g_i' , ou entre bandas diferentes g_i' e g_j' .

Quando $i=j$, $C_{ij4 \times 4}$ representa a variância em uma dada banda g_i' , calculada a partir da informação espacial contida nos 4 "pixels" interpolados nessa banda.

Quando $i \neq j$, $C_{ij4 \times 4}$ representa a covariância entre bandas diferentes, calculada a partir da informação espectral e espacial dos 4 "pixels" interpolados em cada banda.

3.2 - ESTIMADOR TOTAL (IMAGEM SINTÉTICA)

Supõe-se uma relação linear não-homogênea que transforme: imagens primárias g , compostas por bandas multiespectrais g_i ($i = 1, 2, 3$), e pancromática g_p , geradas pelo sensor HRV-SPOT, em imagens estimadas espacialmente e espectralmente g'' . A definição destas imagens é dada por:

$$g = (g_1, g_2, g_3, g_p),$$

$$g_i: E \rightarrow K \text{ e,}$$

$$g_p: E^p \rightarrow K,$$

$$g'': E' \rightarrow K^3,$$

onde $i = 1, 2, 3,$

$$K = \{0, 1, \dots, 255\},$$

$$E = \{0, 1, \dots, n-1\}^2,$$

$$E^p = \{0, 1, \dots, 2n-1\}^2,$$

$$E' = \{1, \dots, 2(n-1)\}^2.$$

E representa o conjunto de pontos de uma imagem multiespectral; E^p representa o conjunto de pontos de uma imagem pancromática; E' representa o conjunto de pontos de uma imagem interpolada espacialmente e espectralmente; e K representa os valores radiométricos das imagens.

O estimador total \hat{F} é do tipo linear não-homogêneo; sua representação é dada por:

$$\hat{F}_{12 \times 1} = W_{12 \times 7} Z_{7 \times 1} + K_{12 \times 1}; \quad (3.18)$$

onde $W_{12 \times 7}$ representa o filtro de Wiener; $Z_{7 \times 1}$ representa o vetor de "pixels" observados da imagem g e g_p ; e $K_{12 \times 1}$ representa o vetor de "offsets".

Para o estimador na Equação 3.18, deseja-se encontrar um filtro $W_{12 \times 7}$ e um vetor $K_{12 \times 1}$, tal que minimizem o risco de Bayes.

Supõe-se que $Z_{7 \times 1}$ seja do tipo linear não-homogêneo (Brum, 1989). Sua representação, como foi observado na Seção 2.5.3, é dada por:

$$Z_{7 \times 1} = H_{7 \times 12} X_{12 \times 1} + N_{7 \times 1}, \quad (3.19)$$

onde $H_{7 \times 12}$ é a matriz de pesos da imagem g para formar g ; $X_{12 \times 1}$ é o vetor de "pixels" interpolados; e $N_{7 \times 1}$ é o vetor de perturbações.

Aplicando a esperança matemática na Equação 3.18 e supondo que o estimador seja não-tendencioso, tem-se que:

$$K = E[F] - WE[Z]. \quad (3.20)$$

Usando a esperança matemática na Equação 3.19 e supondo que $E[N] = 0$, tem-se que a Equação 3.20 torna-se:

$$K = E[F] - WHE[X]. \quad (3.21)$$

Como $E[Z] = \bar{Z}$ é disponível e $E[X]$ não é disponível, utiliza-se a Equação 3.20 para substituí-lo na Equação 3.18. Tem-se então:

$$\hat{F}_{12 \times 1} = E[F]_{12 \times 1} + W_{12 \times 7} (Z_{7 \times 1} - E[Z]_{7 \times 1}). \quad (3.22)$$

Como \hat{F} é do tipo linear, tem-se que sua estimativa ótima será dada pelo princípio da ortogonalidade

(Papoulis, 1984). Tem-se que :

$$E(\varepsilon Z^T) = 0, \quad (3.23)$$

onde $\varepsilon = (F - \hat{F})$ e Z dado pela Equação 3.19.

Supõe-se que as matrizes de covariância de $N_{7 \times 1}$ e $X_{12 \times 1}$ são conhecidas a priori e definidas respectivamente por $V_{7 \times 7} = E[NN^T]$ e $C = E[(\hat{X} - E[\hat{X}])(\hat{X} - E[\hat{X}])^T]$. Estas matrizes são positivas e definidas. As médias de N e F são também conhecidas e respectivamente iguais a $E[N] = 0$ e $E[\hat{X}] = E[\hat{F}]$. Por simplicidade, X e N são não correlacionados, ou seja, $E[XN^T] = E[NX^T] = 0$.

Substituindo as Equações 3.19 e 3.22 na Equação 3.23, tem-se que o filtro de Wiener W será determinado por:

$$W = CH^T(HCH^T + V)^{-1} \quad (3.24)$$

O estimador será então obtido a partir da substituição da Equação 3.24 na Equação 3.22:

$$\hat{F} = \bar{F} + CH^T(HCH^T + V)^{-1}(Z - \bar{Z}). \quad (3.25)$$

O estimador espacial \hat{X} na Equação 3.3 e a matriz de covariância C na Equação 3.16 servirão respectivamente de conhecimento a priori da média \bar{F} e matriz de covariância C na equação 3.25.

Os vetores $\hat{F}_{12 \times 1}$ e $\bar{F}_{12 \times 1}$ da Equação 3.25 têm a mesma representação que a apresentada na Equação 3.7.

O vetor $Z_{7 \times 1}$ é definido por quatro "pixels" que pertencem à banda pancromática, obtidos a partir do bloco $2^P(P_{1C})$, e por três "pixels" das bandas multiespectrais obtidos a partir de bloco $1^1(P_{1C})$. Sua representação é dada por:

$$Z_{1 \times 7}^T = [\phi^T(\text{bloco}_2^P(p_{1C})); \phi^T(\text{bloco}_1^1(p_{kj})); \phi^T(\text{bloco}_1^2(p_{kj})); \phi^T(\text{bloco}_1^3(p_{kj}))]. \quad (3.26)$$

O vetor $Z_{7 \times 1}$ tem a mesma representação do vetor $Z_{7 \times 1}$ (Equação 3.26).

As bandas multiespectrais e pancromática devem estar sobrepostas, ou seja $l = k$ e $c = j$, no início do cálculo da imagem sintética. Portanto, estas bandas devem cobrir a mesma área no terreno.

A matriz H é a mesma obtida em Brum (1989) para o caso subdeterminado (Seção 2.5.3).

3.3 - ESTUDO DOS CASOS LIMITES

Nesta seção estudam-se os casos limites da interpolação estatística espacial da imagem e da estimação da imagem sintética. As variáveis que influenciam esta análise são os coeficientes de correlação horizontal (ρ_H) e vertical (ρ_V); para o caso da imagem sintética, além dessas variáveis, existe também a matriz de covariância da perturbação $V_{7 \times 7}$.

Supõe-se que ρ_H e ρ_V existam no intervalo -1 a 1 e que a matriz V seja diagonal e definida por $V = \sigma^2 I$, onde σ^2 assume qualquer valor real positivo e I corresponde à matriz de identidade.

3.3.1 - CASO 1 - INTERPOLAÇÃO ESTATÍSTICA ESPACIAL

A Equação 3.3 representa a interpolação estatística espacial. Quando ρ_H e ρ_V tendem a zero, tem-se que :

$$\hat{X} = \lim_{\substack{\rho_H \rightarrow 0 \\ \rho_V \rightarrow 0}} E[X] + A(Y - E[Y]) = E[X], \quad (3.27)$$

onde A é dada pela Equação 1.39; para este caso, os elementos da matriz A tendem a zero. Conclui-se, portanto, que os valores interpolados em cada banda multiespectral tendem à média de cada uma dessas bandas.

3.3.2 - CASO 2 - IMAGEM SINTÉTICA

Para a imagem sintética, tem-se que o estimador é dado pela Equação 3.25. Percebe-se pela Equação 3.25 que, quando ρ_H e ρ_V tendem a zero, o estimador tende à estimativa espacial que, no caso, será a média de cada banda multiespectral (Equação 3.28). Portanto :

$$\hat{F} = \lim_{\substack{\rho_H \rightarrow 0 \\ \rho_V \rightarrow 0}} \bar{F} + CH^T(HCH^T + V)^{-1}(Z - \bar{Z}) = \bar{F} = E[X], \quad (3.28)$$

onde \bar{F} , que se reduz a $E[X]$, é igual ao estimador espacial \hat{X} . Isso se deve ao fato de que, quando ρ_H e ρ_V tendem a zero, os elementos da matriz de covariância "a priori" C tendem a zero e o forte peso do conhecimento a priori força o estimador da imagem sintética para $E[X]$ dada pela Equação 3.27.

Supondo ρ_v e ρ_H quaisquer dentro do intervalo -1 a 1, e $\sigma^2 \rightarrow \infty$, tem-se que:

$$\hat{F} = \lim_{\substack{\sigma \rightarrow \infty \\ \forall \rho_H \text{ e } \rho_v}} \bar{F} + CH^T(HCH^T + V)^{-1}(Z - \bar{Z}) = \bar{F} = E[\hat{X}]. \quad (3.29)$$

Neste caso, embora C seja qualquer, com $\sigma^2 \rightarrow \infty$, a matriz V é dominante. Então:

$$(HCH^T + V)^{-1} \cong (V)^{-1} \rightarrow 0. \quad (3.30)$$

A matriz inversa de V tende zero mesmo com C qualquer. A melhor estimativa será a estimativa espacial (Equação 3.3). Nesse caso pode-se imaginar que as observações Z são tão ruidosas que a estimativa baseia-se apenas no conhecimento a priori dado pela interpolação espacial das bandas multiespectrais.

Finalmente, supõe-se que $\sigma^2 \rightarrow 0$, para uma matriz qualquer C :

$$\hat{F} = \lim_{\substack{\sigma \rightarrow 0 \\ \forall \rho_H \text{ e } \rho_v}} \bar{F} + CH^T(HCH^T + V)^{-1}(Z - \bar{Z}). \quad (3.31)$$

Nessas condições, obtém-se:

$$\hat{F} = \bar{F} + CH^T(HCH^T)^{-1}(Z - \bar{Z}). \quad (3.32)$$

Definindo a fatorização de Cholesky da matriz de covariância "a priori" C por:

$$C = LL^T \quad (3.33)$$

e supondo:

$$F' = L^{-1}F, \quad \text{ou seja,} \quad F = LF', \quad (3.34)$$

chega-se a:

$$\hat{F} = \bar{F} + LL^T H^T (HLL^T H^T)^{-1} (Z - \bar{Z}). \quad (3.35)$$

Observa-se que $L^{-1}F$ efetua o processo de ortonormalização de Gram-Schmidt no vetor F . Pela definição $E = HL$, obtém-se:

$$\hat{F} = \bar{F} + LE^T (EE^T)^{-1} (Z - \bar{Z}). \quad (3.36)$$

A matriz $E^T (EE^T)^{-1} = E^T$ é a matriz pseudo-inversa de E e pode ser vista como solução de mínimos quadrados para o sistema subdeterminado.

$$Z = EF' = HLF' = HF. \quad (3.37)$$

Tal sistema poderá ser malcondicionado, no sentido de que a solução de mínima norma dada por :

$$\hat{F}' = E^T (EE^T)^{-1} Z = E^T Z \quad (3.38)$$

podará sofrer grandes perturbações devido a pequenas perturbações em Z . O estudo do malcondicionamento desse problema será apresentado na Seção 4.1.2.2.

CAPÍTULO 4

COMPORTAMENTO DO MODELO DE ESTIMAÇÃO BAYESIANA

Este capítulo mostra o comportamento do modelo de estimação bayesiana desenvolvido no Capítulo 3 e compara seu desempenho com os métodos descritos no Capítulo 2.

4.1 - VALIDAÇÃO DO MODELO USANDO ESTIMAÇÃO BAYESIANA

Nesta seção avalia-se o modelo usando estimação bayesiana. Analisa-se a matriz de covariância calculada da imagem (Equação 3.16) e o comportamento do modelo (Equação 3.25) para os casos limites, variando os parâmetros de ρ_H , ρ_V e V . Além disto, observa-se a definição de bordas das imagens geradas pelo modelo.

4.1.1 - COMPARAÇÃO ENTRE A MATRIZ DE COVARIÂNCIA MEDIDA E A CALCULADA

Para avaliar a matriz de covariância calculada (Equação 3.16), utilizou-se a matriz de covariância medida obtida no ambiente SITIM, que calcula parâmetros estatísticos. Estas matrizes são geradas a partir da imagem interpolada (Equação 3.3). Espera-se a priori que os resultados sejam bastante próximos.

As Tabelas 4.1 e 4.2 mostram estes resultados. Nota-se porém que a dimensão da matriz calculada é 12x12, enquanto para a matriz medida é 3x3. Portanto, não é possível uma comparação direta entre os valores das matrizes. Para a matriz de covariância calculada, utilizaram-se contribuições espaciais e espetrais, enquanto para a matriz de covariância medida

utilizaram-se apenas informações espectrais.

Cada valor da matriz medida relaciona-se com uma submatriz 4x4 da matriz calculada. Comparando agora estes valores, observa-se que são relativamente próximos. Sabe-se ainda que tanto para a matriz medida como para matriz calculada, $C_{ij} = C_{ji}$.

TABELA 4.1 - MATRIZ CALCULADA

| Banda 1 | | | | |
|----------|----------|----------|----------|----------|
| Banda 1 | "pixel"1 | "pixel"2 | "pixel"3 | "pixel"4 |
| "pixel"1 | 413.6971 | 411.1288 | 411.1288 | 408.5764 |
| "pixel"2 | 411.1288 | 413.6971 | 408.5764 | 411.1288 |
| "pixel"3 | 411.1288 | 408.5764 | 413.6971 | 411.1288 |
| "pixel"4 | 408.5764 | 411.1288 | 411.1288 | 413.6971 |

| Banda 2 | | | | |
|----------|----------|----------|----------|----------|
| Banda 1 | "pixel"1 | "pixel"2 | "pixel"3 | "pixel"4 |
| "pixel"1 | 473.7169 | 470.7760 | 470.7760 | 467.8534 |
| "pixel"2 | 470.7760 | 473.7169 | 467.8534 | 470.7760 |
| "pixel"3 | 470.7760 | 467.8534 | 473.7169 | 470.7760 |
| "pixel"4 | 467.8534 | 470.7760 | 470.7760 | 473.7169 |

(continua)

Tabela 4.1 - Conclusão

| Banda 3 | | | | |
|----------|----------|----------|----------|----------|
| Banda 1 | "pixel"1 | "pixel"2 | "pixel"3 | "pixel"4 |
| "pixel"1 | 172.0268 | 170.9588 | 170.9588 | 169.8975 |
| "pixel"2 | 170.9588 | 172.0268 | 169.8975 | 170.9588 |
| "pixel"3 | 170.9588 | 169.8975 | 172.0268 | 170.9588 |
| "pixel"4 | 169.8975 | 170.9588 | 170.9588 | 172.0268 |

| Banda 2 | | | | |
|----------|----------|----------|----------|----------|
| Banda 2 | "pixel"1 | "pixel"2 | "pixel"3 | "pixel"4 |
| "pixel"1 | 667.4852 | 663.3414 | 663.3414 | 659.2232 |
| "pixel"2 | 663.3414 | 667.4852 | 659.2232 | 663.3414 |
| "pixel"3 | 663.3414 | 659.2232 | 667.4852 | 663.3414 |
| "pixel"4 | 659.2232 | 663.3414 | 663.3414 | 667.4852 |

| Banda 3 | | | | |
|----------|----------|----------|----------|----------|
| Banda 2 | "pixel"1 | "pixel"2 | "pixel"3 | "pixel"4 |
| "pixel"1 | 255.3461 | 253.7609 | 253.7609 | 252.1855 |
| "pixel"2 | 253.7609 | 255.3461 | 252.1855 | 253.7609 |
| "pixel"3 | 253.7609 | 252.1855 | 255.3461 | 253.7609 |
| "pixel"4 | 252.1855 | 253.7609 | 253.7609 | 255.3461 |

| Banda 3 | | | | |
|----------|----------|----------|----------|----------|
| Banda 3 | "pixel"1 | "pixel"2 | "pixel"3 | "pixel"4 |
| "pixel"1 | 263.5845 | 261.9481 | 261.9481 | 260.3219 |
| "pixel"2 | 261.9481 | 263.5845 | 260.3219 | 261.9481 |
| "pixel"3 | 261.9481 | 260.3219 | 263.5845 | 261.9481 |
| "pixel"4 | 260.3219 | 261.9481 | 261.9481 | 263.5845 |

TABELA 4.2 - MATRIZ MEDIDA PELO SITIM

| | Banda 1 | Banda 2 | Banda 3 |
|---------|---------|---------|---------|
| Banda 1 | 396.83 | 463.91 | 157.39 |
| Banda 2 | 463.91 | 641.76 | 240.80 |
| Banda 3 | 157.39 | 240.80 | 240.47 |

4.1.2 - ANÁLISE DA VARIAÇÃO DOS PARÂMETROS ρ_H , ρ_V E V

Na Seção 3.4 mostraram-se analiticamente os casos limites do estimador. Nesta seção deseja-se avaliar numericamente estes limites e observar o comportamento da imagem sintética (Apêndice H).

4.1.2.1 - CASO 1 - INTERPOLAÇÃO ESTATÍSTICA ESPACIAL

Observando a Equação 3.27, percebe-se experimentalmente que, para valores com $\rho_H = \rho_V$ iguais a 0,01, a imagem interpolada espacialmente apresenta uma tendência ao valor da média de cada banda multiespectral.

4.1.2.2 - CASO 2 - IMAGEM SINTÉTICA

Supõe-se que a matriz V seja dada por $V = \sigma^2 I$ e que os coeficientes de correlação horizontal ρ_H e vertical ρ_V sejam iguais.

Deseja-se mensurar o que é um valor grande ou pequeno em termos da matriz V , ρ_H , ρ_V e avaliar como se comporta numericamente a Equação 3.25.

Considere-se o valor σ^2 definido em R^+ . Um valor será grande para os elementos da matriz quando σ^2 for pelo menos 100 vezes maior que o produto de matrizes HCH^T .

Com isto a diagonal de $(HCH^T + V)$ torna-se dominante e sua inversa é praticamente igual a zero. Para valores da ordem de grandeza de 10^4 e $\rho_H = \rho_V$ quaisquer, as observações anteriores ocorrem e a melhor estimativa é a média da imagem primária (Equação 3.3).

Supondo o valor $\sigma^2 = 1$, dependendo dos valores assumidos por $\rho_H = \rho_V$, têm-se resultados diferentes para a Equação 3.25. Quando estes valores estão próximos da unidade, a solução ótima é dada pela Equação 3.25. Quando $\rho_H = \rho_V$ tende a zero, tem-se que a matriz de covariância C (Equação 3.16) também tende a zero.

Supõe-se que os elementos da matriz CH^T assumam valores da ordem de 10^{-4} e que σ^2 assumam um valor baixo, tal como $\sigma^2 = .1$. A diagonal de $(HCH^T + V)$ assume valores da ordem de 10^4 maior que os outros elementos. Porém os valores da diagonal são próximos da unidade. Então, $CH^T(HCH^T + V)^{-1}$ (filtro de Wiener) tende a zero e a melhor estimativa será dada pela Equação 3.3. Para este caso os coeficientes de correlação são da ordem de 10^{-5} .

Quando a matriz V é igual a zero, o sistema é malcondicionado. Para estudar o comportamento da imagem sintética, usa-se o número de condição (Rust e Burrus, 1972). Quanto maior for o número de condição n , maior será o malcondicionamento.

$$n = \left\| \left\| (HL)^T ((HL)(HL)^T)^{-1} \right\| \right\| \left\| HL \right\|, \quad (4.1)$$

$$n = \left\| \left\| E^T (EE^T)^{-1} \right\| \right\| \left\| E \right\| = \left\| \left\| E^T \right\| \right\| \left\| E \right\|,$$

onde $C = LL^T$ (matriz de covariância) definida positiva, L é uma matriz triangular inferior e L^T é sua transposta.

$$\| B \| = \left(\sum_{i=1}^m \sum_{j=1}^n B_{ij}^2 \right)^{1/2} \quad (\text{norma da matriz}),$$

onde B é uma matriz qualquer.

No Apêndice B, apresenta-se um resumo desta teoria.

O número de condição é função dos coeficientes de correlação horizontal e vertical. Portanto, variando-os num intervalo de -1 a 1, tem-se o comportamento do número de condição nos quatro quadrantes.

Pela Figura 4.1 mostra-se a representação tridimensional do malcondicionamento. Utilizou-se o logaritmo neperiano para melhor representação dos valores do número de condição, dada sua grande variação.

Pela Figura 4.2, percebe-se que quando os coeficientes de correlação ρ_H e ρ_V aumentam em módulo, o número de condição também aumenta. Para valores menores que 0,9, o logaritmo do número de condição não supera o valor 4. Observa-se que o malcondicionamento do problema ocorre quando a matriz de covariância a priori C tende a tornar-se singular.

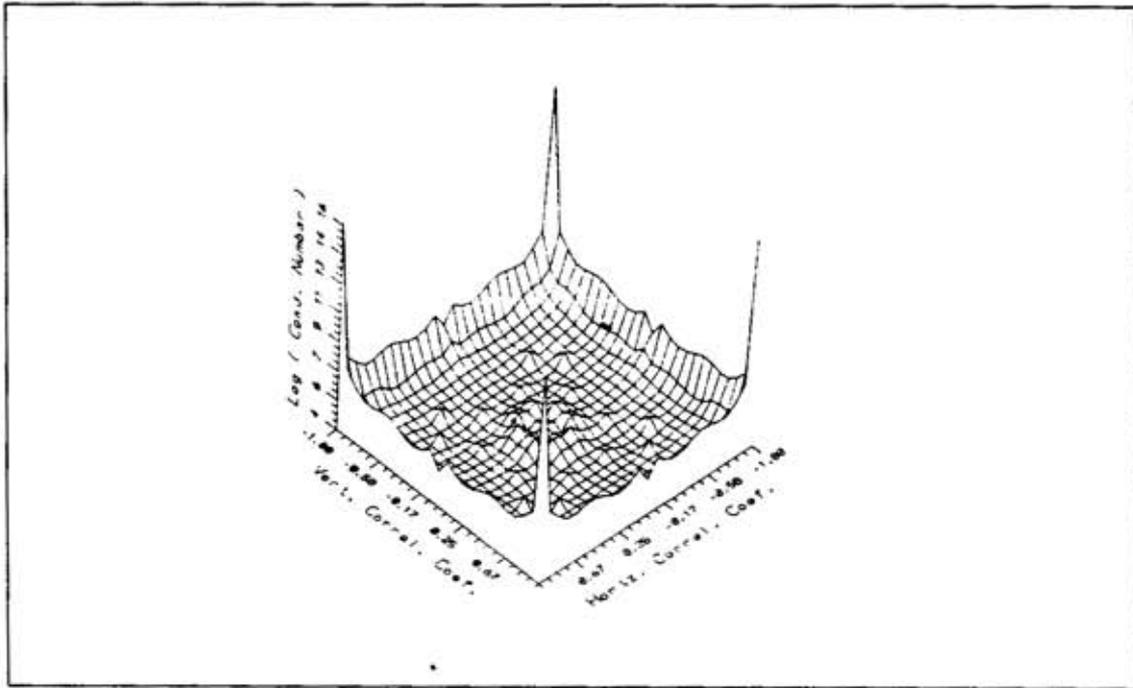


Fig. 4.1 - Número de condição.

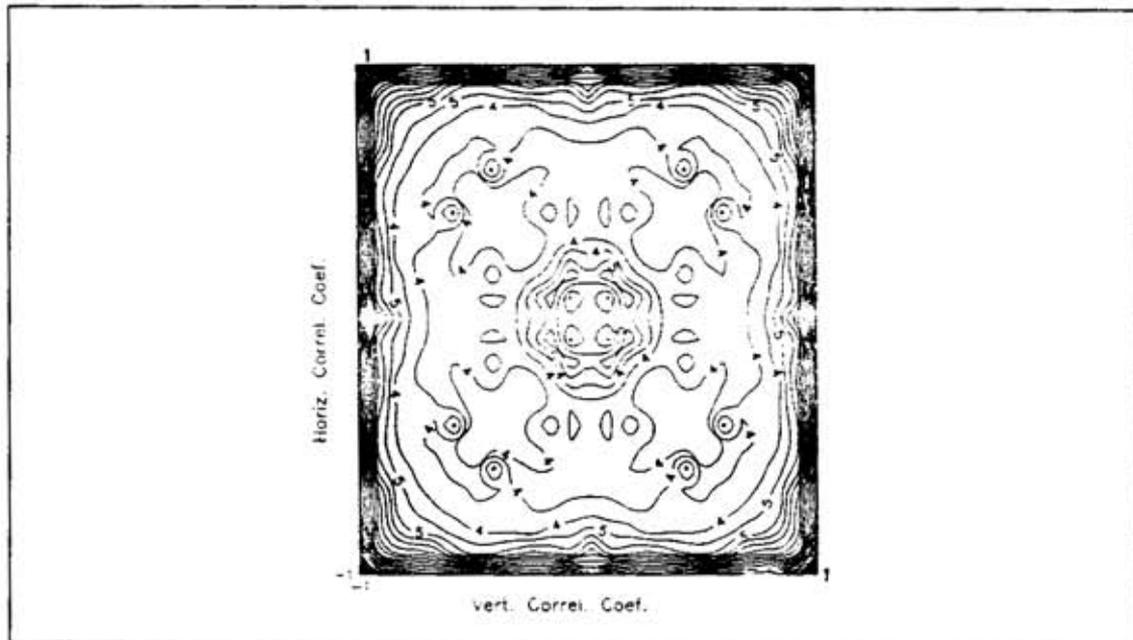


Fig. 4.2 - Curva de nível do número de condição.

4.1.3 - COMPORTAMENTO DO MODELO PARA REGIÕES COM BORDAS VERTICAIS E REGIÕES SEM BORDA

O comportamento do modelo de interpolação espacial é estudado em dois casos: área sem borda e área com borda vertical (Figura 4.3). Supõe-se que a borda horizontal seja o dual da borda vertical (maiores detalhes no Apêndice E).

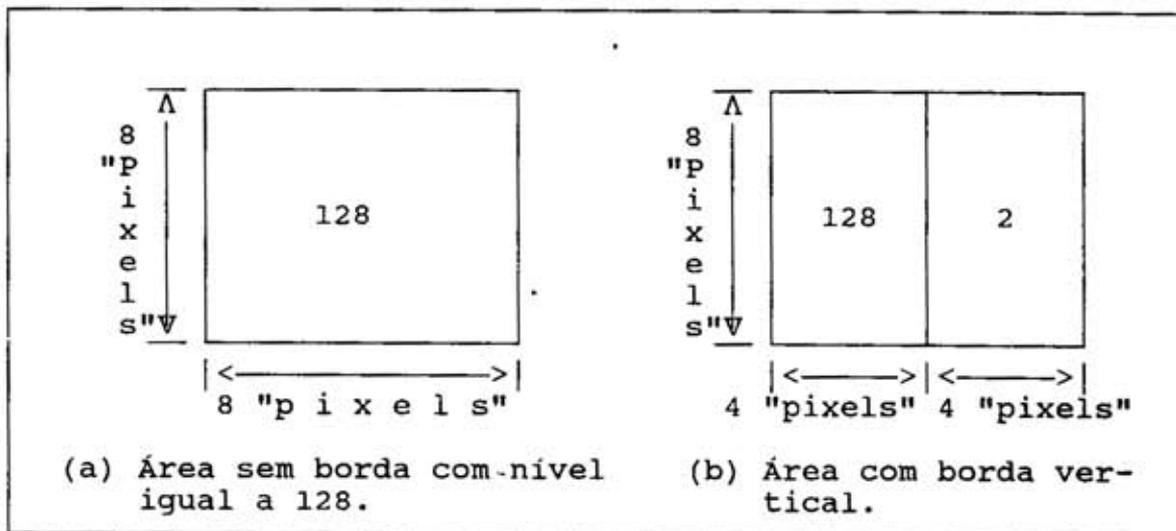


Fig.4.3 - Imagem simulada.

As Figuras 4.3 e 4.5 representam o comportamento da área constante usando o interpolador espacial. Variando ρ_H e ρ_V no intervalo de -1 a 1, observa-se que os resultados são mais próximos de 128 quando ρ_H e ρ_V têm sinais iguais e seus valores absolutos são iguais ou superiores a 0,5. Quando ρ_H e ρ_V têm sinais contrários, os valores encontrados para os "pixels" interpolados estão muito afastados do resultado esperado.

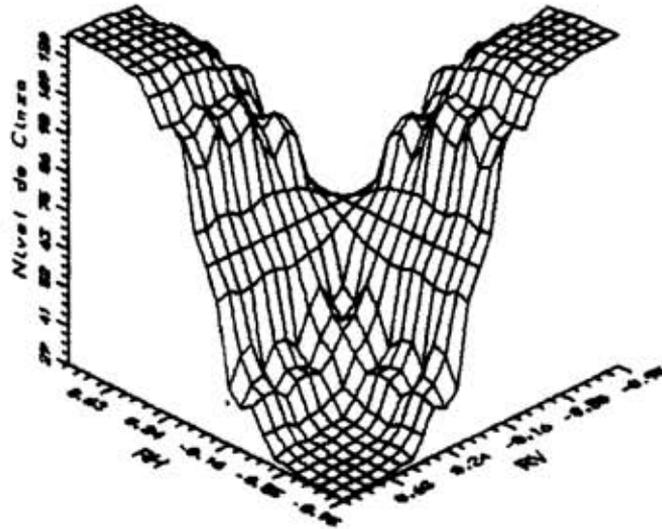


Fig. 4.4 - Comportamento de uma área constante. Interpolação espacial.

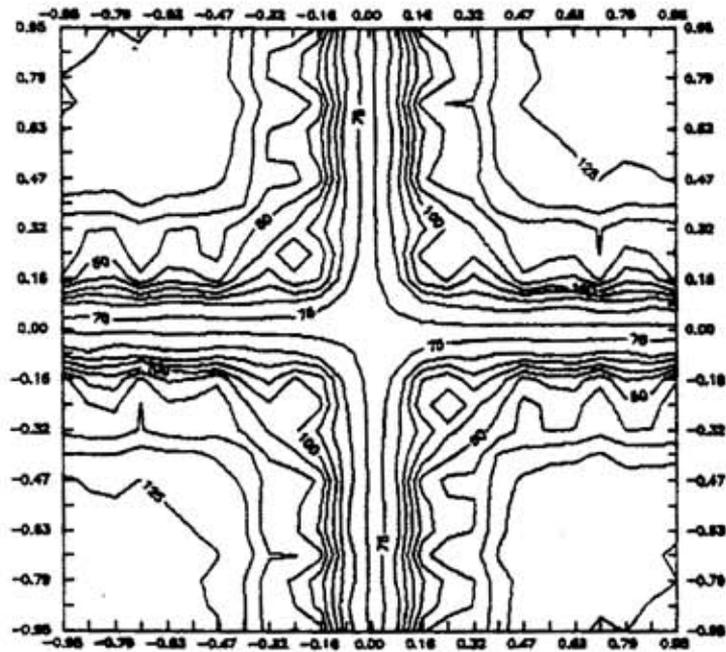


Fig. 4.5 - Comportamento das curvas de nível para uma área constante.

O caso da borda vertical é mostrado na Figura 4.6. Nota-se que há um compromisso entre definição de borda e representação do nível de cinza, isto é, valores altos de ρ_V e ρ_H (próximos de 1) tendem a preservar os tons de cinza dos dois lados da borda, mas a região de transição é alongada. Por outro lado, valores baixos de ρ_V e ρ_H (próximos de 0,2, por exemplo) tendem a diminuir o tamanho da borda (pois os valores interpolados tendem à média igual a 64), mas ao mesmo tempo é também reduzida a largura da borda.

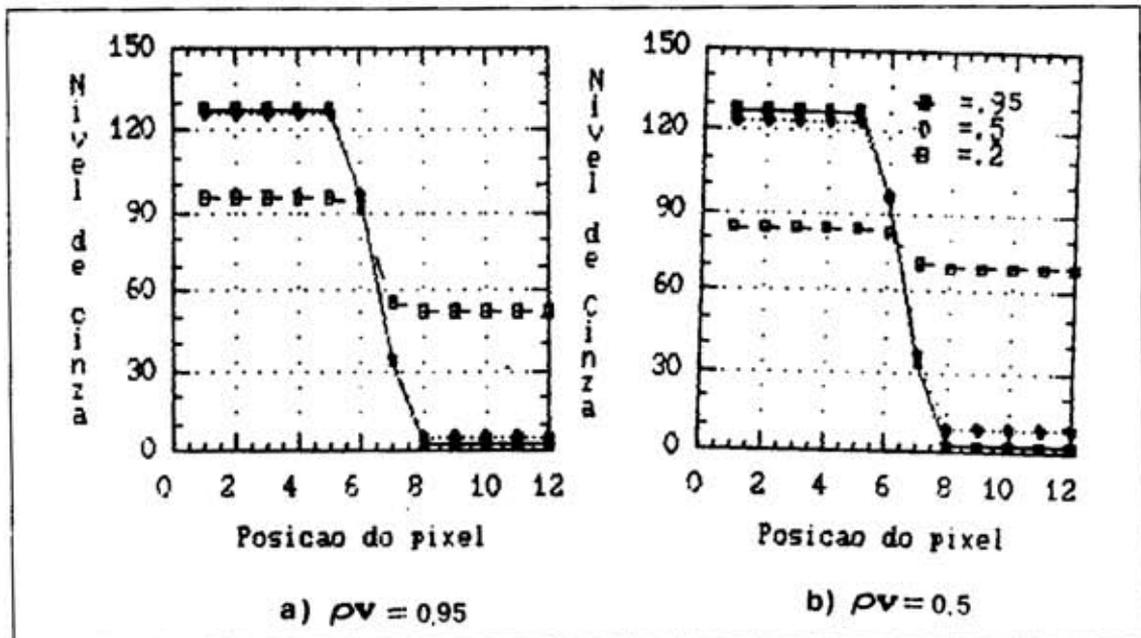


Fig. 4.6 - Análise da borda vertical.

4.2 - COMPARAÇÃO DO DESEMPENHO DO INTERPOLADOR ESPACIAL E DE OUTROS INTERPOLADORES

Analisam-se aqui o cálculo de estatísticas, os histogramas e a análise visual entre bandas originais e interpoladas, usando o método descrito na Seção 3.1 e outros métodos de interpolação espacial propostos na

literatura: vizinho mais próximo, bilinear e o método proposto em Brum (1989).

Foram utilizadas tabelas para realçar as bandas g_1 antes da aplicação dos interpoladores.

Na Figura 4.7, observa-se que, visualmente, o interpolador espacial que usa estimação bayesiana é semelhante ao interpolador bilinear e menos borrado que o interpolador geométrico usado em Brum (1989). Pela Figura 4.8, percebe-se que há efeito de blocos para o método que usa vizinho mais próximo, o que não ocorre para outros métodos.

Uma vantagem do interpolador que usa vizinho mais próximo é não introduzir novos valores de "pixel" na interpolação, ao passo que isto não ocorre com os outros interpoladores estudados.

Para o interpolador bilinear, há um preenchimento maior dos níveis de cinza, porém nota-se que há algumas alterações no contorno do histograma da imagem primária. Para o caso do estimador espacial bayesiano (Capítulo 3) e do interpolador espacial geométrico (Brum, 1989), tem-se boa semelhança com o contorno do histograma da imagem original (Figuras 4.9, 4.10 e 4.11).



Fig. 4.7 - Interpolação espacial.



Fig. 4.8 - "Zoom" da interpolação espacial.

Observa-se, na Tabela 4.2, que a média é praticamente igual para todos interpoladores espaciais e que a variância das imagens interpoladas espacialmente é sempre menor que a variância da imagem primária. Deve-se observar, como já foi mencionado anteriormente, que, no caso do interpolador de Bayes, quando ρ_V e ρ_H tende a zero, a variância de imagem interpolada é nula.

Quando se utilizam filtros passa-baixa, como é o caso do modelo em Brum (1989), há uma suavização da imagem; portanto, espera-se menor variância para a imagem.

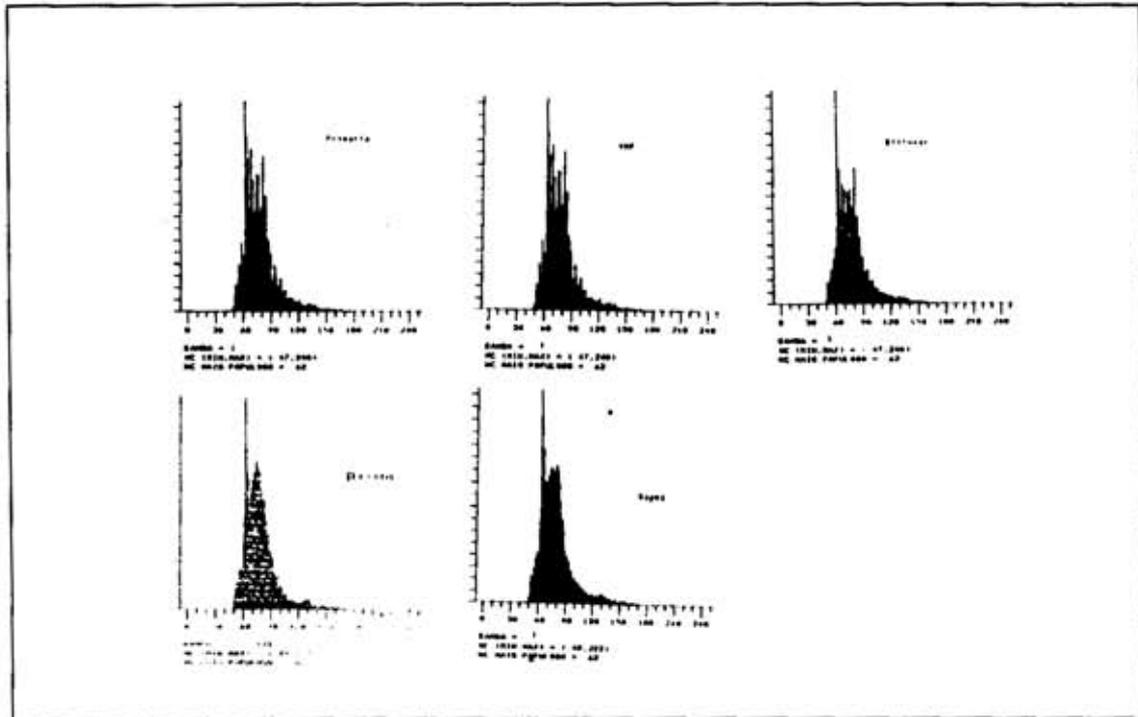


Fig. 4.9 - Histograma de interpolação espacial - banda 1.

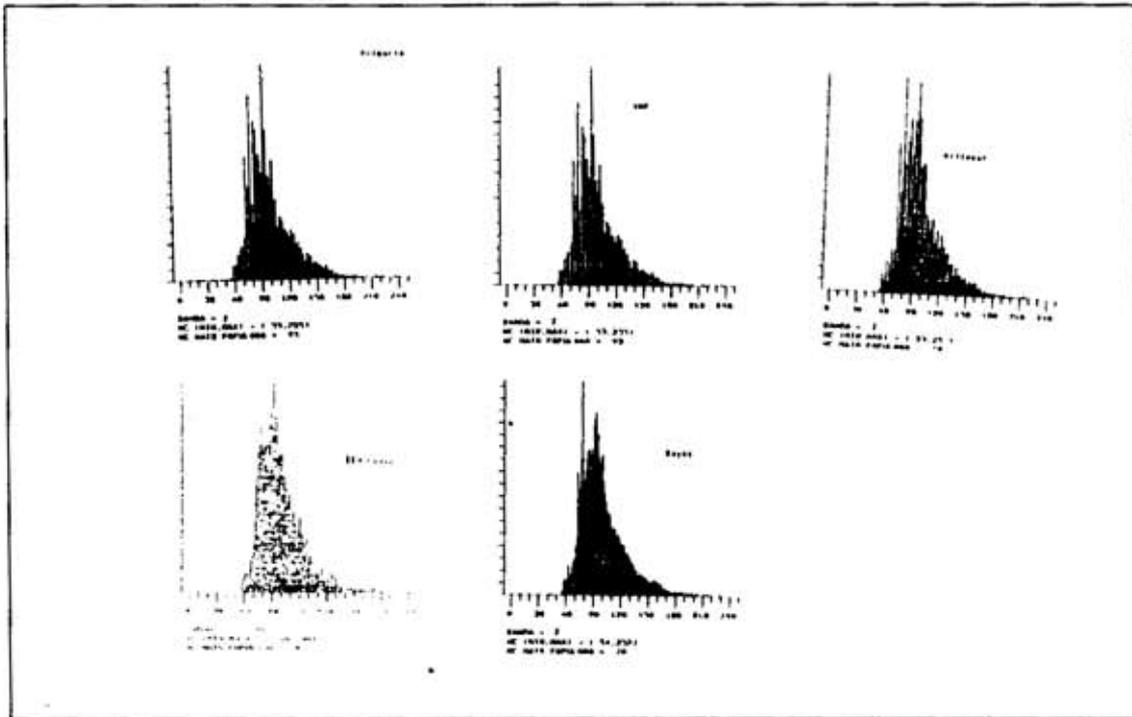


Fig. 4.10 - Histograma de interpolação espacial - banda 2.

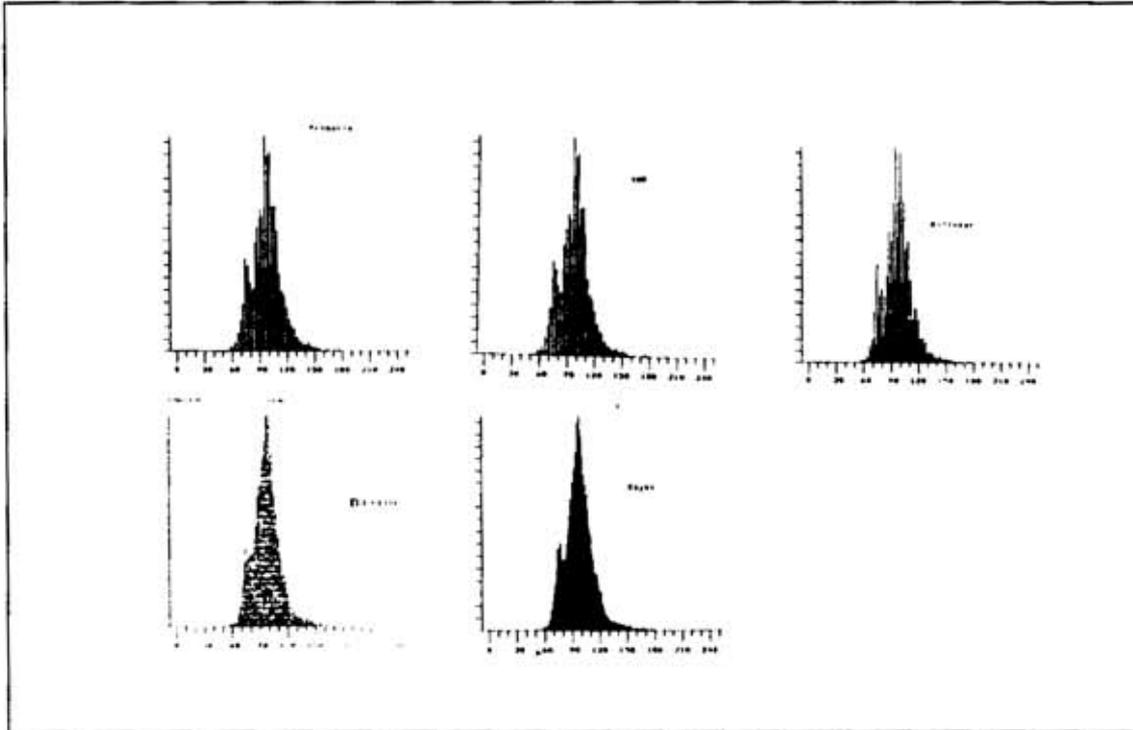


Fig. 4.11 - Histograma de interpolação espacial - banda 3.

A Tabela 4.3 mostra os valores dos cálculos estatísticos dos interpoladores espaciais estudados.

TABELA 4.3 - CÁLCULOS DAS ESTATÍSTICAS DO INTERPOLADOR ESPACIAL.

| Banda 1 | Prim. | Viz+Prox | Bilinear | Brum | Bayes $\rho_H = \rho_V = 0,95$ |
|----------|--------|----------|----------|--------|-----------------------------------|
| Média | 78,84 | 78,64 | 78,39 | 78,41 | 78,90 |
| Menor NC | 47 | 47 | 47 | 49 | 48 |
| Maior NC | 240 | 240 | 240 | 217 | 222 |
| NC + Pop | 62 | 62 | 62 | 62 | 62 |
| Var. | 438,41 | 431,86 | 402,72 | 207,48 | 396,83 |
| Banda 2 | Prim. | Viz+Prox | Bilinear | Brum | Bayes $\rho_H = \rho_V = 0,95$ |
| Média | 100,07 | 99,91 | 99,64 | 99,64 | 100,10 |
| Menor NC | 53 | 53 | 53 | 56 | 54 |
| Maior NC | 255 | 255 | 255 | 240 | 252 |
| NC + Pop | 93 | 93 | 78 | 92 | 78 |
| Var. | 701,24 | 698 | 654,67 | 587,63 | 641,76 |
| Banda 3 | Prim. | Viz+Prox | Bilinear | Brum | Bayes $\rho_H = \rho_V = 0,95$ |
| Média | 97,14 | 97,20 | 97 | 96,66 | 97,11 |
| Menor NC | 39 | 39 | 39 | 49 | 43 |
| Maior NC | 188 | 188 | 188 | 179 | 182 |
| NC + Pop | 95 | 95 | 95 | 98 | 92 |
| Var. | 276,44 | 274,92 | 250,22 | 250,22 | 240,47 |

4.3 - COMPARAÇÃO DO DESEMPENHO DAS IMAGENS SINTÉTICAS GERADAS PELO MÉTODO DE BAYES COM AS PROPOSTAS NA LITERATURA

O desempenho será analisado pelo cálculo de estatísticas, histogramas e análise visual entre as bandas sintéticas. Os modelos que são comparados com o método de Bayes são: Cliche et al. (1985), Dutra et al. (1988), Carper et al. (1990).

Compara-se visualmente (Figura 4.12) o modelo desenvolvido na Seção 3.3 (estimador de Bayes usando $\rho_H =$

$\rho_v = 0,95$ e $\sigma^2 = 1$) com os propostos por Brum (1989) e Cliche et al. (1985). Nota-se que a imagem está bem melhor definida para o estimador de Bayes.

Em Brum (1989) foi utilizado um interpolador espacial que suaviza bastante a imagem (Figura 4.7) e percebe-se que se fosse utilizado um outro interpolador que evidenciasse um pouco mais as bordas, seriam observados melhores resultados para este modelo.

Para o modelo gerado em Cliche et al. (1985), nota-se um grande borramento e mesmo variando o ganho e "offset" (ver Seção 2.2), não é possível obter resultados melhores.

Do ponto de vista espectral, os modelos desenvolvidos em Brum (1989) e na Seção 3.3 são bastantes semelhantes.

Pela análise visual, percebe-se que, levando em consideração a resolução espacial, tem-se que a melhor estimativa da imagem sintética é obtida em Dutra (1988) (comparar a Figura 4.12 com a Figura 4.13). Há, porém, um escurecimento da imagem, pois ao substituir o canal I pelo canal pancromático, a intensidade da banda do infravermelho não irá contribuir para a formação da imagem sintética. Áreas com vegetação e outros alvos que refletem muito no infravermelho serão apresentadas com tonalidades mais escuras. Estudaram-se formas para solucionar este problema. A primeira é alterar o canal S (saturação) (Figura 4.13) , modificando seu contraste, usando uma tabela. A segunda é usando aproximação feita por Carper (1990) (Figura 4.13). Nota-se que espectralmente, no método IHS, a imagem original é mais próxima da desenvolvida em Carper (1990). Espacialmente, para o método de Carper, há um borramento devido à média ponderada na geração dos "pixels" da imagem sintética.

Comparando os modelos propostos por Dutra et al. (1988) e o estimador de Bayes (Seção 3.3) (Figuras 4.12 e 4.13), nota-se que este último distingue menos as bordas na imagem. Isto ocorre porque, na sua concepção, é utilizada uma imagem interpolada espacialmente que é suavizada. Portanto, o primeiro modelo citado é melhor do ponto de vista espacial.

Uma vantagem que o modelo desenvolvido com estimador de Bayes (Seção 3.3) possui é poder variar os coeficientes de correlação ρ_H e ρ_V , oferecendo maior flexibilidade e permitindo adaptar o modelo às características locais da imagem.

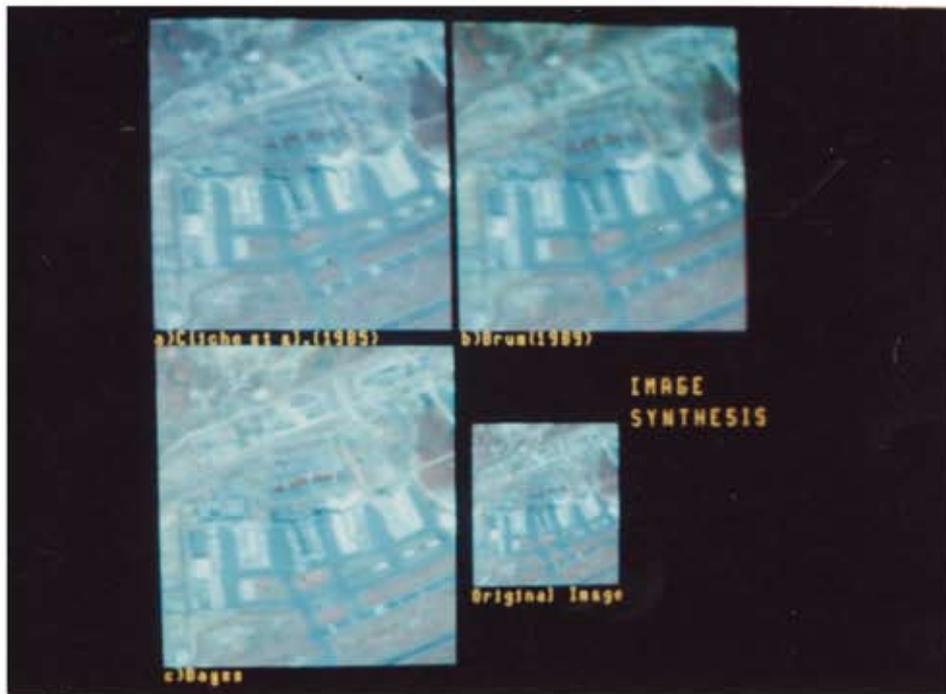


Fig. 4.12 - Imagem sintética (Cliche, Brum, bayesiana)



Fig. 4.13 - Imagem sintética (Dutra, sat., Carper).

Pela Tabela 4:3 observa-se que para todos os modelos estudados, as médias são próximas da media da imagem primária. Quanto a variância, percebe-se que há, para a maioria dos casos, um aumento na variância nas bandas sintéticas. Supõe-se que isto ocorra por serem introduzidas na composição das bandas sintéticas informações da banda pancromática.

Pela análise de histogramas (Figuras 4.14, 4.15 e 4.16), tem-se que os modelos desenvolvidos por Cliche et al. (1985), Brum (1989), Carper et al. (1990), bem como o modelo desenvolvido na Secão 3.3, apresentam um conterno da curva proxima ao histograma gerado pela imagem primária. Para a imagem gerada por IHS (Dutra et al., 1988), bem como para a imagem gerada usando uma tabela de contraste para S (saturação) do IHS, percebe-se que,

espectralmente, estes modelos apresentam uma grande diferença de seus contornos quando comparados com o histograma da imagem primária.

TABELA 4.4 - CÁLCULOS DAS ESTATÍSTICAS DA IMAGEM SINTÉTICA

| Banda 1 | Prim | Cliche | IHS | IHSat | IHSCarper |
|----------|--------|--------|---------|---------|-----------|
| Média | 78,84 | 86,59 | 81,97 | 64,66 | 81,68 |
| Menor NC | 47 | 47 | 31 | 10 | 43 |
| Maior NC | 240 | 241 | 255 | 255 | 255 |
| NC + Pop | 62 | 71 | 60 | 40 | 65 |
| Var. | 438,41 | 485,47 | 564,77 | 942,76 | 484,08 |
| Banda 2 | Prim | Cliche | IHS | IHSat | IHSCarper |
| Média | 100,07 | 97,62 | 104,79 | 115,96 | 104,10 |
| Menor NC | 53 | 50 | 37 | 20 | 51 |
| Maior NC | 255 | 253 | 255 | 255 | 255 |
| NC + Pop | 93 | 89 | 104 | 255 | 96 |
| Var. | 701,24 | 644,84 | 1313,58 | 2151,98 | 859,13 |
| Banda 3 | Prim | Cliche | IHS | IHSat | IHSCarper |
| Média | 97,14 | 97,07 | 100,02 | 105,51 | 101,21 |
| Menor NC | 39 | 45 | 36 | 6 | 38 |
| Maior NC | 188 | 202 | 255 | 255 | 243 |
| NC + Pop | 95 | 93 | 89 | 113 | 103 |
| Var. | 276,44 | 283,63 | 564,77 | 762,24 | 430,53 |

(continua)

Tabela 4.4 - Conclusão

| Banda 1 | Prim. | Brum | Bayes |
|----------|--------|--------|--------|
| Média | 78,84 | 79,54 | 80,17 |
| Menor NC | 47 | 43 | 21 |
| Maior NC | 240 | 247 | 255 |
| NC + Pop | 62 | 64 | 64 |
| Var. | 438,41 | 432,59 | 537,15 |
| Banda 2 | Prim. | Brum | Bayes |
| Média | 100,07 | 50 | 104,16 |
| Menor NC | 53 | 50 | 36 |
| Maior NC | 255 | 255 | 255 |
| NC + Pop | 93 | 94 | 98 |
| Var. | 701,24 | 745,95 | 881,55 |
| Banda 3 | Prim. | Brum | Bayes |
| Média | 97,14 | 96,73 | 97,61 |
| Menor NC | 39 | 44 | 36 |
| Maior NC | 188 | 181 | 214 |
| NC + Pop | 95 | 99 | 100 |
| Var. | 276,44 | 233,40 | 294,19 |

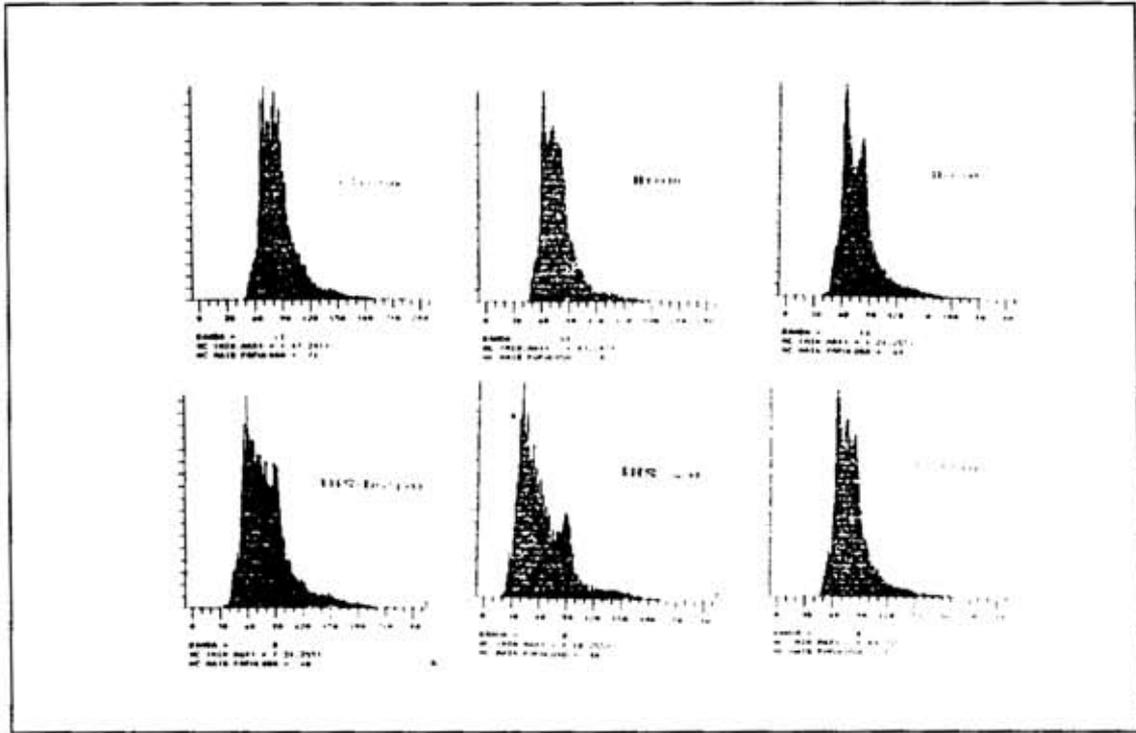


Fig. 4.14 - Histograma da imagem sintética - banda 1.

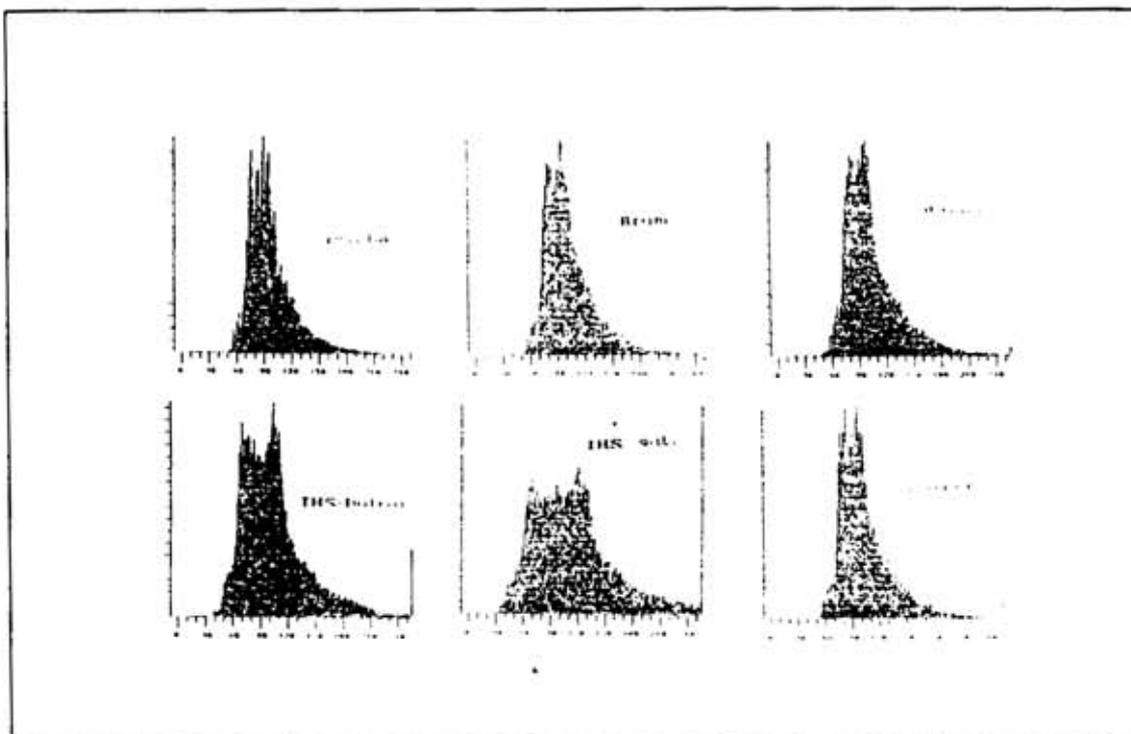


Fig 4.15 - Histograma da imagem sintética - banda 2.

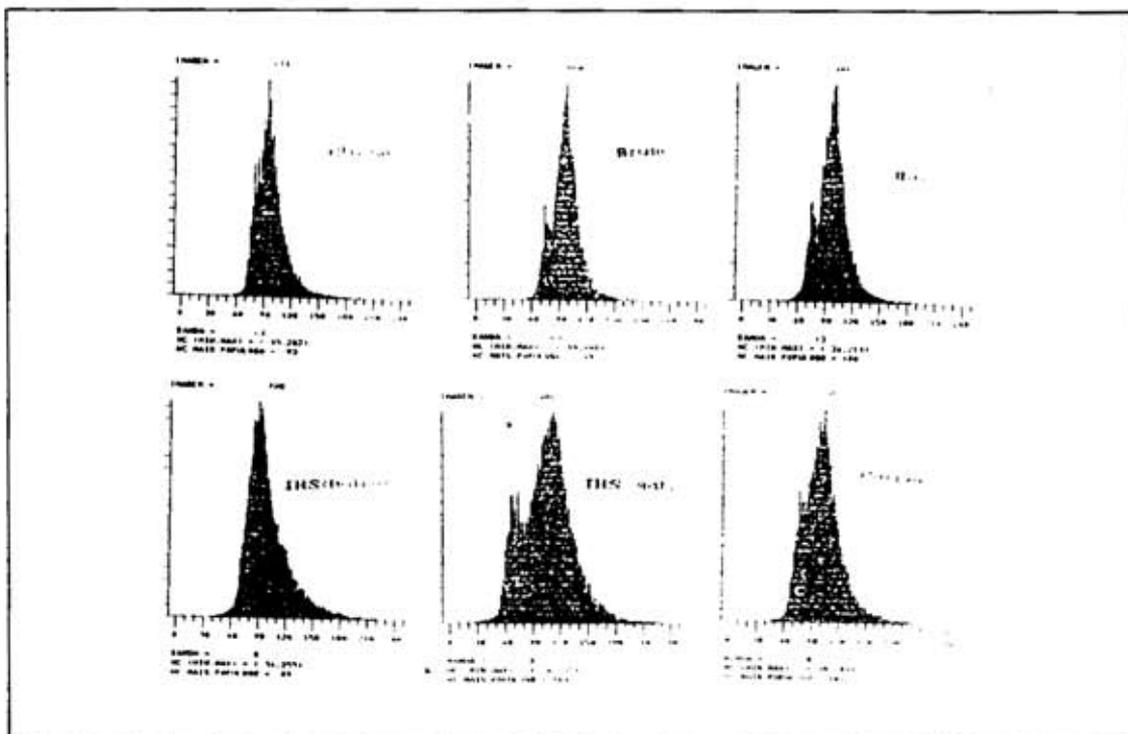


Fig. 4.16 - Histograma da imagem sintética - banda 3.

Na geração da imagem sintética utilizou-se a imagem pancromática. A seguir é mostrado seu histograma.

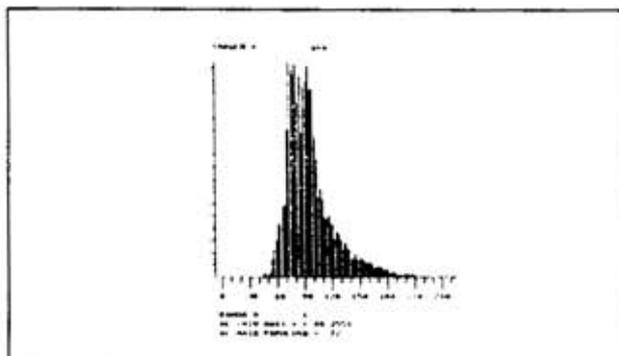


Fig. 4.17 - Histograma da banda original pancromática.

CAPÍTULO 5

ANÁLISE DE RESULTADOS E CONCLUSÕES

A geração de imagens sintéticas a partir de fusão de dados de diferentes sensores facilita a interpretação visual de uma dada área na cena. Em sensoriamento remoto este recurso é importante quando se deseja um estudo mais refinado de uma dada área ou tema.

Neste trabalho, foi apresentada uma revisão sobre fusão de dados; estudaram-se alguns trabalhos na literatura e estes foram comparados com um modelo de fusão de dados desenvolvido a partir de técnicas com abordagem bayesiana.

Dependendo da aplicação, um estimador pode ser mais eficiente que outro. Se o objetivo é análise visual, e a resolução espectral é o fator mais importante, os modelos desenvolvidos na Seção 3.3, o modelo desenvolvido em Brum (1989) e o emprego da técnica IHS (Carper et al., 1990) são os mais indicados. Se o objetivo principal é a resolução espacial, o modelo IHS (Dutra et al., 1988) é o que mais se adapta por não suavizar as bordas.

O método desenvolvido a partir da estimação bayesiana (Seção 3.3), tem a vantagem sobre os outros por permitir maior flexibilidade, adaptando o modelo às características locais da imagem, variando os coeficientes de correlação ρ_H e ρ_V .

Uma análise que poderia ser implementada no futuro seria alterar o interpolador espacial descrito no Capítulo 3 por meio de um detetor de bordas. Para áreas homogêneas, seriam utilizados coeficientes de correlação

altos (por exemplo, da ordem de 0,95). Para regiões com borda, seriam utilizados coeficientes de correlação mais baixos (por exemplo, na faixa de 0,2 a 0,5). Com isto, modelo seria adaptado às características locais da imagem e melhoraria o conhecimento a priori para o estimador de Bayes.

Também foi observado que, alterando o interpolador espacial descrito em Brum (1989) por outro interpolador que preservasse as bordas, ter-se-ia uma imagem sintética com mais informação de borda.

Conclui-se que a fusão de dados é uma importante ferramenta em processamento digital de imagens e que há uma tendência de crescimento não só visando análise visual, mas também como teste de sensores a serem projetados.

REFERÊNCIAS BIBLIOGRÁFICAS

- Andrade, V. M. B. Classificação de imagens de alta resolução usando atributos de textura. (Dissertação de Mestrado em Computação Aplicada). Instituto de Pesquisas Espaciais, São José dos Campos, fev., 1989. (INPE - 4888 - TDL/379).
- Association for Computing Machinery (ACM) States report of the graphics standards planning committee, Computer Graphics, 13(3):311-316, 1979.
- Banon, G. J. F. Estimação de variáveis aleatórias: aplicação à predição linear. Brasília, DF, IBM, 1983 (Relatório técnico CCB012).
- Banon, G. J. F. Curso de processamento digital de imagens: anotações de aula dadas no Instituto de Pesquisas Espaciais, São José dos Campos, 1990.
- Begni, G.; Boisson, B.; Perbos, J. La qualité des images issues du système SPOT et son contrôle après le lancement du satellite. Toulouse, CNES, France. 1985.
- Brum, E. R. Integração dos canais multiespectrais e pancromáticos do sensor HRV (SPOT) para obtenção de composições coloridas com resolução espacial próxima a 10m. (Dissertação de Mestrado em Sensoriamento Remoto) - Instituto de Pesquisas Espaciais, São José dos Campos, ago., 1989. (INPE - 5035 - TDL/403).
- Candeias, A. L. B. Utilização de fusão de dados de sensores para obter alta resolução espacial e espectral em imagens de satélite. In: Seminário e Workshop sobre Geoprocessamento, 1., Recife, 7 - 11, out., 1991. Recife, UFPE/DECART, 1991, p. 720-725.

- Carper, W. J.; Lillesand, T. M.; Kiefer, R. W. The use of intensity-hue-saturation transformations for merging SPOT panchromatic and multispectral image data Photogrammetric Engineering and Remote Sensing, 6(10): 459-467, Apr. 1990.
- Chavez Jr., P. S. Digital merging of LANDSAT TM and digitized NHAP data for 1:24,000 - scale image mapping. Photogrammetric Engineering and Remote Sensing, 52(10):1637-1646, Oct. 1986.
- Chavez Jr., P. S.; Sides, S. .; Anderson, J. A. Comparison of three different methods to merge multiresolution and multispectral data: LANDSAT TM and SPOT panchromatic. Photogrammetric Engineering and Remote Sensing, 57(3):295-303, Mar., 1991.
- Centre National d'Études Spatiales (CNES) SPOT user handbook. Toulouse, SPOT image, 1989. V. 2.
- Cliche, G.; Bonn, F. P. Integration of the SPOT panchromatic channel into its multispectral mode for image sharpening enhancement. Photogrammetric Engineering and Remote Sensing, 51(3):311-316, Mar. 1985.
- Corlay, G.; Henry, C.; Paul, J. B. HRV SPOT camera detection unit: optical and radiometric characteristics. In: International Symposium on Remote Sensing of Environment, 18., Paris, 1-5, 1984. Proceedings. Ann Arbor, MI, ERIM, 1984, v.1, p. 941-956.
- Daily, M. I.; Farr, T.; Elachi, C. Geologic interpretation from composite RADAR and LANDSAT imagery. Photogrammetric Engineering and Remote Sensing, 45 (8):1109-1116, Aug. 1979.

- Dutra, L. V.; Menezes, P. R. Realce de cores em imagens de sensoriamento remoto utilizando rotação da matriz no espaço IHS. Simpósio Brasileiro de Telecomunicações, Petrópolis, 1987.
- Dutra, L. V.; Foresti, C.; Menezes, P. R.; Kurkdjian, M. L. N. O. Utilização de transformação IHS para integração de imagens de diferentes resoluções: Estudo do solo urbano. In: Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens, 1., Petrópolis, 19-20, abr. 1988. Anais. Petrópolis, Sociedade Brasileira de Computação, 1988, p. 144-151.
- Graybill, F. A. Introduction to matrices with applications in statistics. Belmont, Wadsworth, 1969.
- Hayden, R. Application of the IHS color transform to the processing of multisensor data and image enhancement. In: International Symposium Lands, Cairo, Egypt. , Proceedings. , 1982, p. 599-616.
- Mascarenhas, N. D. A. Digital restoration under a regression model. The unconstrained, linear equality and inequality constrained approaches. California, Image Processing Institute, University of Southern, CA, 1974.
- Mascarenhas, N. D. A.; Banon, G. J. F.; Fonseca, L. M. G. SPOT panchromatic band simulation by linear combination of multispectral bands. In: Simpósio Brasileiro de Sensoriamento Remoto, 6; International Symposium on Primary Data Acquisition - ISPRS, 1., Manaus, 24-29, jun., 1990. Anais. São José dos Campos, INPE, 1990, v.1, P. 181-187.
- Mascarenhas, N. D. A.; Prado, L. O. C. A Bayesian approach to edge detection in images. IEEE Transactions on Automatic Control, AC-25 (1):36-43, Feb. 1980.

- Mascarenhas, N. D. A.; Velasco, F. Processamento digital de imagens. São Paulo, Instituto de Matemática e Estatística, 1984. Escola de Computação, 4., 12-20, + 1. 1984.
- Mascarenhas, N. D. A.; Banon, G. J. F.; Candeias, A. I. B. Interpolação estatística espacial das imagens multiespectrais do sensor HRV-SPOT. In: Simpósio Latino Americano de Percepção Remota - SELPER, 5., Peru, 28-01, Nov., 1991, Anais.
- Mather, P. M. Computer processing of remotely-sensed images: an introduction. New York, John Wiley., 1987. 352p.
- Melsa, J. L.; Cohn, D. L. Decision and estimation theory. New York, N. Y., McGraw-Hill, 1978. 273 p.
- Moik, J. Digital processing of remotely sensed images. Washington, D. C., U. S. Government printing office, 1980.
- NASA Multisource data integration in remote sensing. 3099,1991
- Papoulis, A. Probability, random variables and stochastic processes. New York, N. Y., Mc Graw-Hill, 1984.
- Prince, J. C. Combining panchromatic and multispectral imagery from dual resolution satellite instruments. Remote Sensing of Environment, 21(3):119-128, 1987.
- Rust, W. B.; Burrus, W. R. Mathematical programming and the numerical solution of linear equations. New York, New York, American Elsevier, 1972.
- Sage, A. P.; Melsa, L. M. Estimation theory with applications to communications and control. New York, McGraw-Hill, 1971. 529p.

- Schowengerdt, R. A. Techniques for image processing and classification in remote sensing. New York, N Y, Academic, 1983.
- Siegal, B. S.; Gillespie, A. R. Remote Sensing in Geology. New York, Wiley. 1980, 702p.
- Slater, P. N. Remote sensing: optics and optical systems. Reading, MA, Addison-Wesley, 1980, 575p.
- Smith, A. R. Color gamut transform pairs. Computer Graphics. 3(3):12-18, Aug. 1978.
- Tewarson, R. P. Solution of linear equations in remote sensing and picture reconstruction. Computing, 10(2):221-230, 1972.

APÊNDICE APRODUTO DE KRONECKERA.1 - DEFINIÇÃO

Seja A uma matriz $m_2 \times n_2$ e B uma matriz $m_1 \times n_1$, o produto de Kronecker é dado por $C = A \otimes B$, onde C é uma matriz $m_1 m_2 \times n_1 n_2$, definida por:

$$C = [C_{ij}] = A \otimes B = [A_{ij} B_{ij}], \quad (\text{A.1})$$

onde $i = 1, 2, \dots, m_1$ e $j = 1, 2, \dots, n_1$

Esta definição representa o produto direto de Kronecker à esquerda. O produto à direita seria $[B_{ij} A_{ij}]$.

A.2 - PROPRIEDADE DA INVERSA

Seja A uma matriz não-singular $m_1 \times n_1$ e B uma matriz $m_2 \times n_2$ não-singular, então: $A \otimes B$ é não-singular e a inversa é dada por:

$$(A \otimes B)^{-1} = A^{-1} \otimes B^{-1}. \quad (\text{A.2})$$

A vantagem de utilizar a inversa com produto de Kronecker é a de reduzir o esforço computacional. Outras propriedades do produto de Kronecker podem ser encontradas em Graybill (1969).

APÊNDICE BSISTEMAS BEM-CONDICIONADOS E MALCONDICIONADOS

Supõe-se que o modelo linear padrão seja definido por:

$$\hat{b} = Ax + \hat{e}, \quad (B.1)$$

onde \hat{b} é o vetor m-dimensional de observação, x é o vetor n-dimensional desconhecido, A é a matriz m x n de elementos constantes conhecidas, e \hat{e} é o vetor m-dimensional estocástico de erros observados que satisfaz : $E(\hat{e}) = 0$ e $E(\hat{e}\hat{e}^T) = S$.

A matriz S (n x m) de covariância do vetor observado \hat{b} é positiva e definida por:

$$S = \Sigma_{\hat{b}} = E[(\hat{b} - E(\hat{b}))(\hat{b} - E(\hat{b}))^T]. \quad (B.2)$$

ou, aplicando a esperança matemática na Equação B.1 e substituindo-a na Equação B.2,

$$S = \Sigma_{\hat{b}} = E[(\hat{b} - Ax)(\hat{b} - Ax)^T] \quad (B.3)$$

Para o modelo de regressão linear clássico considera-se $m \geq n$, e a matriz tem colunas linearmente independentes, isto é, $\text{posto}(A)=n$.

O estimador ótimo \hat{x} , pelo procedimento de mínimos quadrados (Rust e Burrus, 1972), tem como solução:

$$\hat{x} = (A^T S^{-1} A)^{-1} A^T S^{-1} \hat{b}. \quad (B.4)$$

Para o modelo linear padrão, apresentado na Equação B.1, o vetor \hat{x} estimado é o valor particular do vetor Z que minimiza a forma quadrática:

$$\theta(z) = (\hat{b} - Az) S^{-1} (\hat{b} - Az) . \quad (B.5)$$

A superfície residual (Equação B.5) é dada para um valor de \hat{b} particular.

O valor mínimo desta função é dada por:

$$r_0 = (\hat{b} - A\hat{x}) S^{-1} (\hat{b} - A\hat{x}) . \quad (B.6)$$

Para um valor k constante, a projeção no plano Z de $(r_0 + k^2)$ da superfície residual é um k-elipsóide centrado no valor mínimo \hat{x} . A sua fórmula é dada por:

$$(z - \hat{x}) A^T S^{-1} A (z - \hat{x}) = k^2 , \quad (B.7)$$

$$\text{COV}(\hat{x}) = (A^T S^{-1} A)^{-1} .$$

Supondo o problema com $n=2$, tem-se a sua representação de superfície residual dada pela Figura B.1.

Os autovetores da matriz $A^T S^{-1} A$ fornecem a direção dos eixos principais. A localização do elipsóide depende dos valores de \hat{b} , que determinam o vetor \hat{x} através das equações normais:

$$A^T S^{-1} A \hat{x} = A^T S^{-1} \hat{b} . \quad (B.7)$$

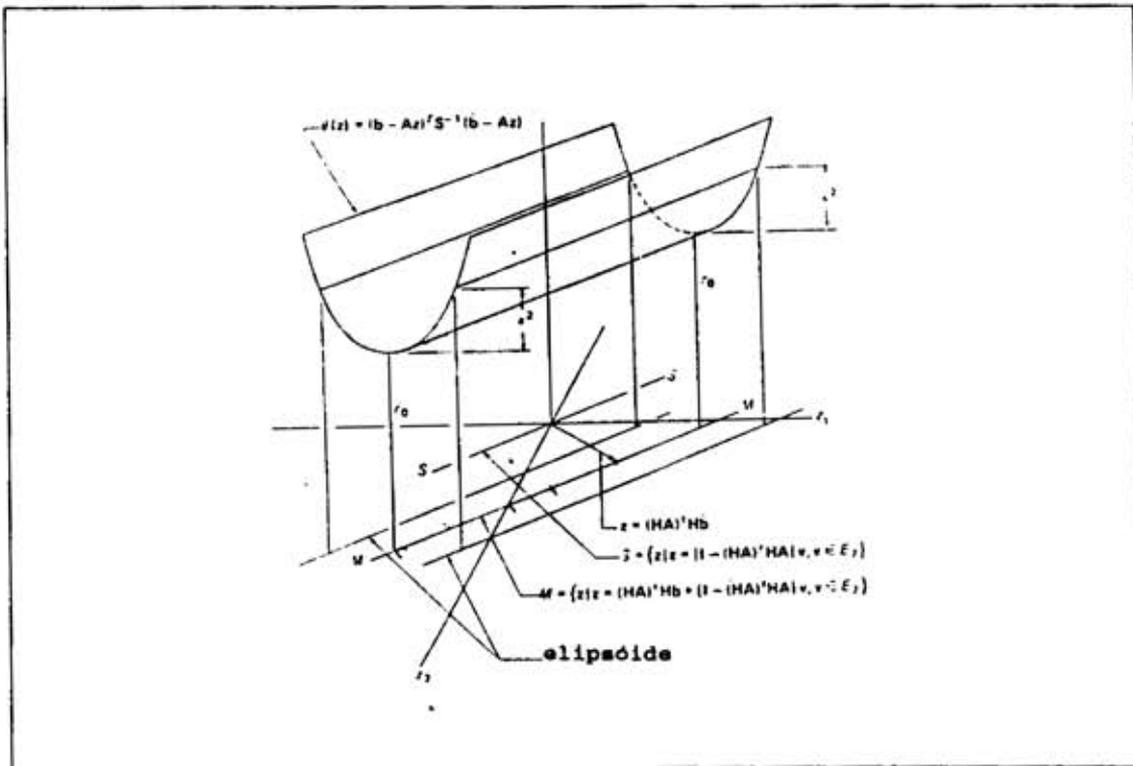


Fig. B.1 - Superfície residual em um k -elipsóide para o problema com $n=2$.

FONTE: Rust e Burrus (1972).

Diz-se que as equações normais são ditas malcondicionadas se pequenas perturbações em \hat{b} provocam grandes perturbações em \hat{x} .

Supondo que a Equação B.7 é malcondicionada e \hat{b} é dada pela Equação B.1, considerando o vetor de erro Δx definido por:

$$\hat{x} = x + \Delta x, \quad (\text{B.8})$$

e admitindo que $S^{-1} = H^T H$, onde H é uma matriz simétrica não-singular, tem-se o erro relativo entre \hat{x} e \hat{b} (Rust e

Burrus, 1972):

$$\frac{\|\Delta x\|}{\|x\|} \leq \left(\|(A^T H^T A H)^{-1} A^T H^T\|_E \|HA\|_E \|\hat{H}e\| \right) / \|\mathbf{H}b\|. \quad (\text{B.9})$$

Essa expressão fornece o limite superior para este erro relativo. A norma euclidiana é dada por:

$$\|B\|_E = \left(\sum_{i=1}^m \sum_{j=1}^n B_{ij}^2 \right)^{1/2} = [\text{trace}(B^T B)]^{1/2}. \quad (\text{B.10})$$

O número de condição de um sistema de equações normais é definido por:

$$n = \|(A^T H^T A H)^{-1} A^T H^T\|_E \|HA\|_E \quad (\text{B.11})$$

ou pela inversa generalizada:

$$n = \|(HA)^+ \|_E \|HA\|_E. \quad (\text{B.12})$$

Sabendo que para uma matriz qualquer B com $m \geq n$ e $\text{posto}(B) = n$, a inversa generalizada de B é $n \times m$, definida por:

$$B^+ = (B^T B)^{-1} B^T, \quad (\text{B.13})$$

onde B^+ é a inversa à esquerda de B.

Para uma matriz qualquer B com $m \leq n$ e $\text{posto}(B) = m$, a inversa generalizada de B é $n \times m$, definida

por:

$$B^+ = B^T(BB^T)^{-1} \quad (B.14)$$

onde B^+ é a inversa à direita de B .

Para o caso onde B é $n \times n$, e $\text{posto}(B) = n$, a inversa generalizada é a inversa ordinária B^{-1} .

O grau de malcondicionamento pode ser medido pelo número de condição (Rust e Burrus, 1972; Mascarenhas e Pratt, 1975). Quanto maior é o número de condição, maior será a sensibilidade do estimador às perturbações do ruído.

No caso de um sistema sobredeterminado, a forma quadrática a ser minimizada representa uma parábola e o alongamento do elipsóide está diretamente ligado ao número de condição. Quanto mais o elipsóide se afasta do formato da esfera, maior é o malcondicionamento do sistema.

Pode-se mostrar que a razão entre o maior e o menor eixo principal desse elipsóide indica o grau de malcondicionamento (Rust e Burrus, 1972).

Para o caso do sistema subdeterminado, o parabolóide se degenera para um formato de calha e existem infinitas soluções para minimização da forma quadrática.

A Figura B.2 mostra a superfície residual e um k -elipsóide para o problema com $n = 2$ e $p = 1$ (caso subdeterminado).

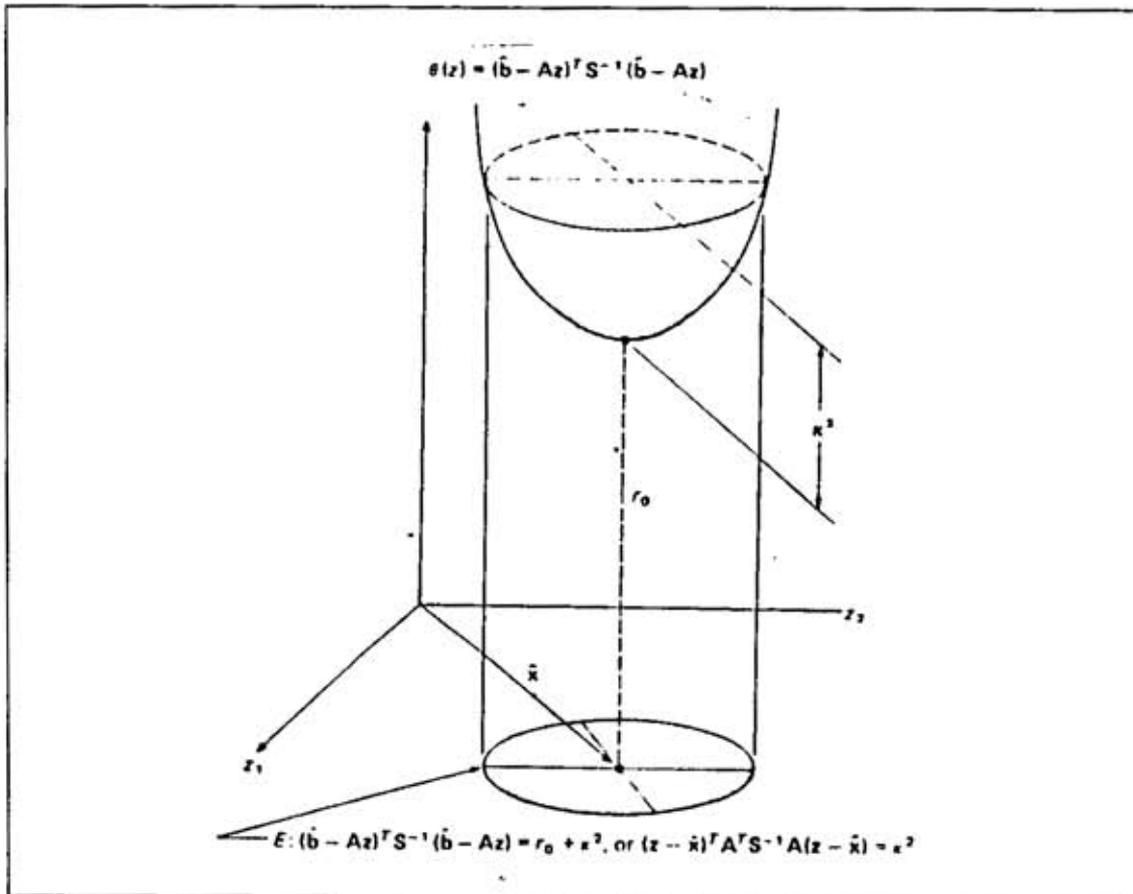


Fig. B.2 - Superfície residual e um k -elipsóide para um problema com $n = 2$ e $p = 1$.
 FONTE: Rust e Burrus (1972).

APÊNDICE CMATRIZ INVERSA GENERALIZADA

Dada uma matriz H ($m \times n$), a matriz H^+ é obtida pelo seguinte limite (Mascarenhas, 1974):

$$H^+ = \lim_{\alpha \rightarrow \infty} (H^T H + \alpha I)^{-1} H^T = \lim_{\alpha \rightarrow \infty} H^T (H H^T + \alpha I)^{-1} H^T. \quad (C.1)$$

Dado um sistema sobredeterminado de equações lineares do tipo $Y = HX$, onde $H_{m \times n}$, $m \geq n$ e posto de H igual a n , a solução de mínima norma que minimiza o resíduo $\|Y - HX\|^2$ é dada por $\hat{X} = H^+ Y$.

Rust e Burrus (1972) mostram que \hat{X} é o vetor único em $R(H^T)$ que satisfaz a equação:

$$HX = \hat{Y}, \quad (C.4)$$

onde \hat{Y} é dado pela projeção de Y em $R(H)$. O vetor \hat{X} satisfaz o conjunto normal de equações:

$$H^T H X = H^T Y. \quad (C.5)$$

A matriz inversa H^+ é chamada de inversa generalizada ou pseudo-inversa da matriz H . Um caso particular é dado quando a matriz é quadrada e não-singular, resultando na matriz inversa. Se as colunas de H são linearmente independentes, (caso sobredeterminado), tem-se que H^+ será dado por:

$$H^+ = (H^T H)^{-1} H^T. \quad (C.6)$$

Caso as linhas de H sejam linearmente independentes (caso subdeterminado), tem-se que H^+ será dado por:

$$H^+ = H^T (H^T H)^{-1}. \quad (C.7)$$

Uma solução geral vista na literatura mostra que um sistema linear dado por $Y = HX$ é definido por:

$$X = H^+ Y + (I - H^+ H)^{-1} V. \quad (C.8)$$

Para o caso sobredeterminado, a solução é dada por:

$$X = H^+ Y, \quad (C.9)$$

onde $H^+ H = I$.

Para o caso subdeterminado, $H^+ H \neq I$, e não há solução única para o sistema linear ou para problemas de mínimos quadrados. O vetor $H^+ Y$ é a solução de mínima norma (ver detalhes em Mascarenhas, 1974). A geometria das soluções pode ser vista na Figura C.1.

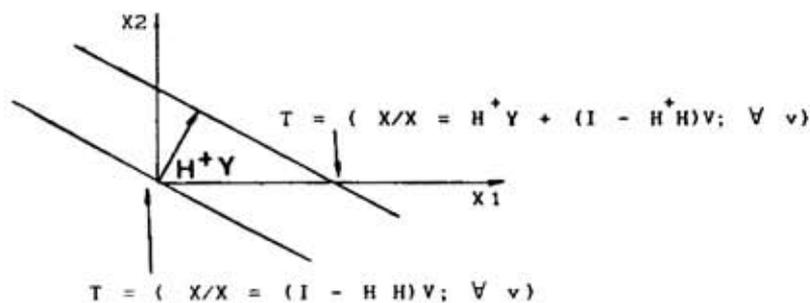


Fig. C.1 - Geometria das soluções de um sistema subdeterminado.

APÊNDICE DEXPRESSÃO PARA MATRIZ INVERSA DE COEFICIENTES DE COR-
RELAÇÃO SUPONDO UM PROCESSO MARKOVIANO.

A matriz de coeficientes de correlação para um processo markoviano é definida por:

$$R_{n \times n} = \begin{bmatrix} 1 & \rho & \rho^2 & \rho^3 & \dots & \rho^{n-1} \\ \rho & 1 & \rho & \rho^2 & \dots & \rho^{n-2} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho^{n-1} & \rho^{n-2} & \rho^{n-3} & \rho & & 1 \end{bmatrix}. \quad (D.1)$$

Para o caso 3x3, tem-se que sua inversa é dada por:

$$R = [(1 - \rho^2)^{-1}] \begin{bmatrix} 1 & \rho & 0 \\ -\rho & 1 + \rho^2 & -\rho \\ 0 & -\rho & 1 \end{bmatrix}. \quad (D.2)$$

APÊNDICE EDETECÇÃO DE BORDAS

Deseja-se indicar uma mudança súbita do nível de cinza (bordas) entre duas regiões relativamente homogêneas. Em geral, para detectar bordas utiliza-se filtragem espacial do tipo passa-altas, seguidas de um processo de limiarização: se a saída do filtro ultrapassa o limiar, uma borda local é detetada. Caso contrário, a borda não é detetada.

Para obter uma detecção de borda com indicação da direção, utiliza-se um vetor gradiente. Assim, denota-se a diferença na direção vertical por Deltay e na direção horizontal por Deltax. Sua representação é dada por:

$$\text{Deltax} = F(x+1, y) - F(x-1, y), \quad (\text{E.1})$$

$$\text{Deltay} = F(x, y+1) - F(x, y-1). \quad (\text{E.2})$$

A magnitude da borda, em cada ponto (x, y) , é calculada por:

$$A(x, y) = [(\text{Deltax})^2 + (\text{Deltay})^2]^{1/2} \quad (\text{E.3})$$

A direção da borda $FI(x, y)$ é a direção perpendicular ao gradiente $Teta(x, y)$, ou seja:

$$FI(x, y) = Teta(x, y) + \pi/2, \quad (\text{E.4})$$

onde $Teta(x, y) = \text{Arctg}(\text{Deltax} / \text{Deltay})$.

Operadores não-lineares do tipo gradiente foram propostos por vários autores, tais com Roberts e Sobel (Pratt, 1978).

No ambiente SITIM, a detecção de borda é obtida aplicando um tipo de diferenciação espacial na imagem. Este operador é gerado a partir do seguinte esquema:

| | | |
|---|---|---|
| a | b | c |
| d | e | f |
| g | h | i |

onde $e = |a - i| + |c - g| + |d - f| + |a - i|$.

Fig. E.1 - Representação esquemática do operador gradiente.

A binarização da imagem gradiente é efetuada pela aquisição do histograma da imagem gradiente, e a partir de um fator de corte fornecido pelo usuário, calcula-se o nível de cinza limitante para a borda. Os valores acima do limite são bordas e assumem valores iguais a 255. Caso contrário, assumem valores iguais a zero.

APÊNDICE FLITERATURA RECOMENDADA

- ASSEFI, T. Stochastic process, estimation theory, and image enhancement. New York, N. Y., John Wiley & Sons, 1979. 259 p.
- BEGNI, G.; RAYSSIGUIER, M. Specifications et bilans de qualité image du système SPOT. Acta Astronautica, 10(1):33-42, 1983. Great Britain.
- CHAVEZ JR., P. S. Digital processing of SPOT simulator and LANDSAT TM data for mountain region, Arizona. In: SPOT simulator Symposium, Arizona. Proceedings, Arizona, 1984, p. 56-66.
- DAILY, M. I.; ELACHI, C.; FARR, T.; STROMBERG, W.; WILLIAMS, S.; SCHABER, G. Application of multispectral RADAR and LANDSAT imagery to geologic mapping in Death Valley. NASA, Jet Propulsion Laboratory publication, 1978. 47 p. (JPL 78-19).
- DUDA, R. O.; HART, P. E. Pattern classification and scene analysis. New York, N. Y., John Wiley & Sons. 1973. 482p.
- DUTRA, L. V.; MENEZES, P. R. Aplicações de transformações IHS para realce de cores em imageamento LANDSAT. In: Simpósio Latino Americano de Sensoriamento Remoto, 4., Reunion Plenária SELPER, 6., Gramado, 10-15, ago. 1986. Anais. São José dos Campos, INPE/SELPER/SBC, 1986, v.1, p. 675-681.

- Utilização da transformação no espaço de cores, contraste linear e filtragem para realce de imagens coloridas. São José dos Campos, INPE, ago. 1987. 6p. (INPE/-4310-PRE/1176)
- DUTRA, L. V.; FORESTI, C.; MENEZES, P. R.; KURKDJIAN, M. L. N. O. Utilização de transformação IHS para integração de imagens de diferentes resoluções: Estudo do solo urbano. In: Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens, 1., Petrópolis, 19-20, Abr., 1988. Anais. Petrópolis, Sociedade Brasileira de Computação, 1988, p. 144-151
- KUMAR, P. R.; VARAIYA, P. Stochastic systems estimation; identification and adaptive control. New Jersey, Prentice Hall, 1986. 358p.
- LEWIS, F. L. Optimal estimation with an introduction to stochastic control theory. New York, N. Y., John Wiley & Sons, 1989. 376p.
- MASCARENHAS, N. D. A.; PRATT, W.K. Digital image restoration under a regression model. IEEE transactions on circuits and systems, CAS - 22(3):252-266:1975.
- MUNIER, P.; RIVEREAU, J. C. Map production and map updating using SPOT data. Toulouse, SPOT image, France.
- PRATT, W. K. Digital image processing. New York, John Wiley, 1978, 750p.
- ROSENFELD, A.; A. C. Digital picture processing. 2. ed., New York, N Y, Academic, 1982. V. 2
- VAN TREES, H. L. Detection, estimation and modulation theory. New York, N Y, John Wiley & Sons, 1968. V. 1.

VITERBI, A. J. Principles of coherent communication. New York, N Y, Mc Graw Hill, 1966.

WELCH, R. Spatial resolution requirements for urban studies. International Journal of Remote Sensing, 3(2):139-146, 1982.

WELCH, R.; EHLERS, M. Merging multiresolution SPOT HRV and LANDSAT TM data. Photogrammetric Engineering and Remote Sensing, 53(3):301-303, Mar. 1987.

APÊNDICE GFLUXOGRAMAS

A seguir são mostrados cinco fluxogramas, que representam vários métodos de fusão de dados. Supõe-se que as imagens multiespectrais e pancromática associem a mesma área no terreno e que seus "pixels" estejam registrados (superpostos).

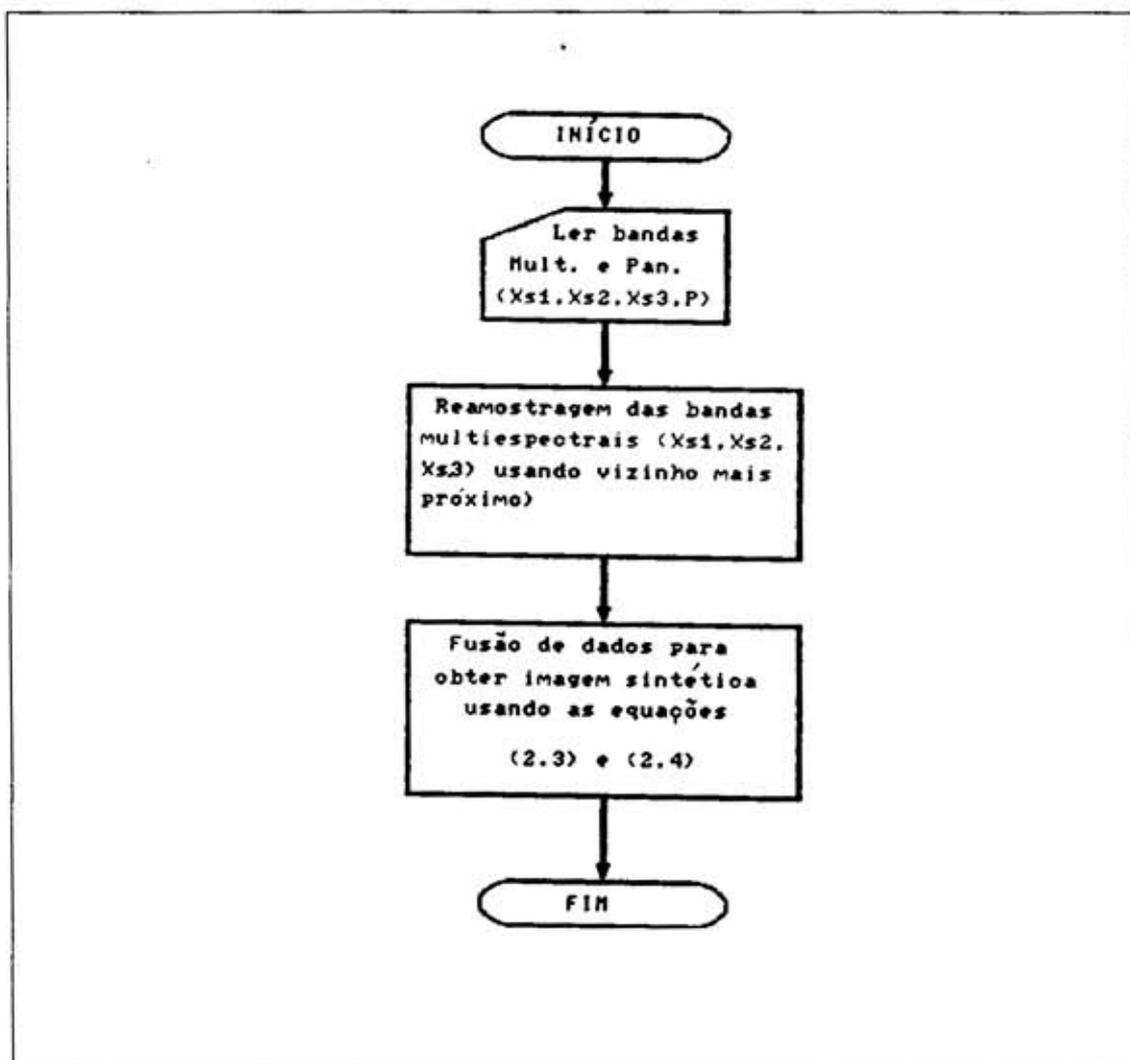


Fig. G.1 - Fluxograma de fusão de imagens usando modelo de Cliche.

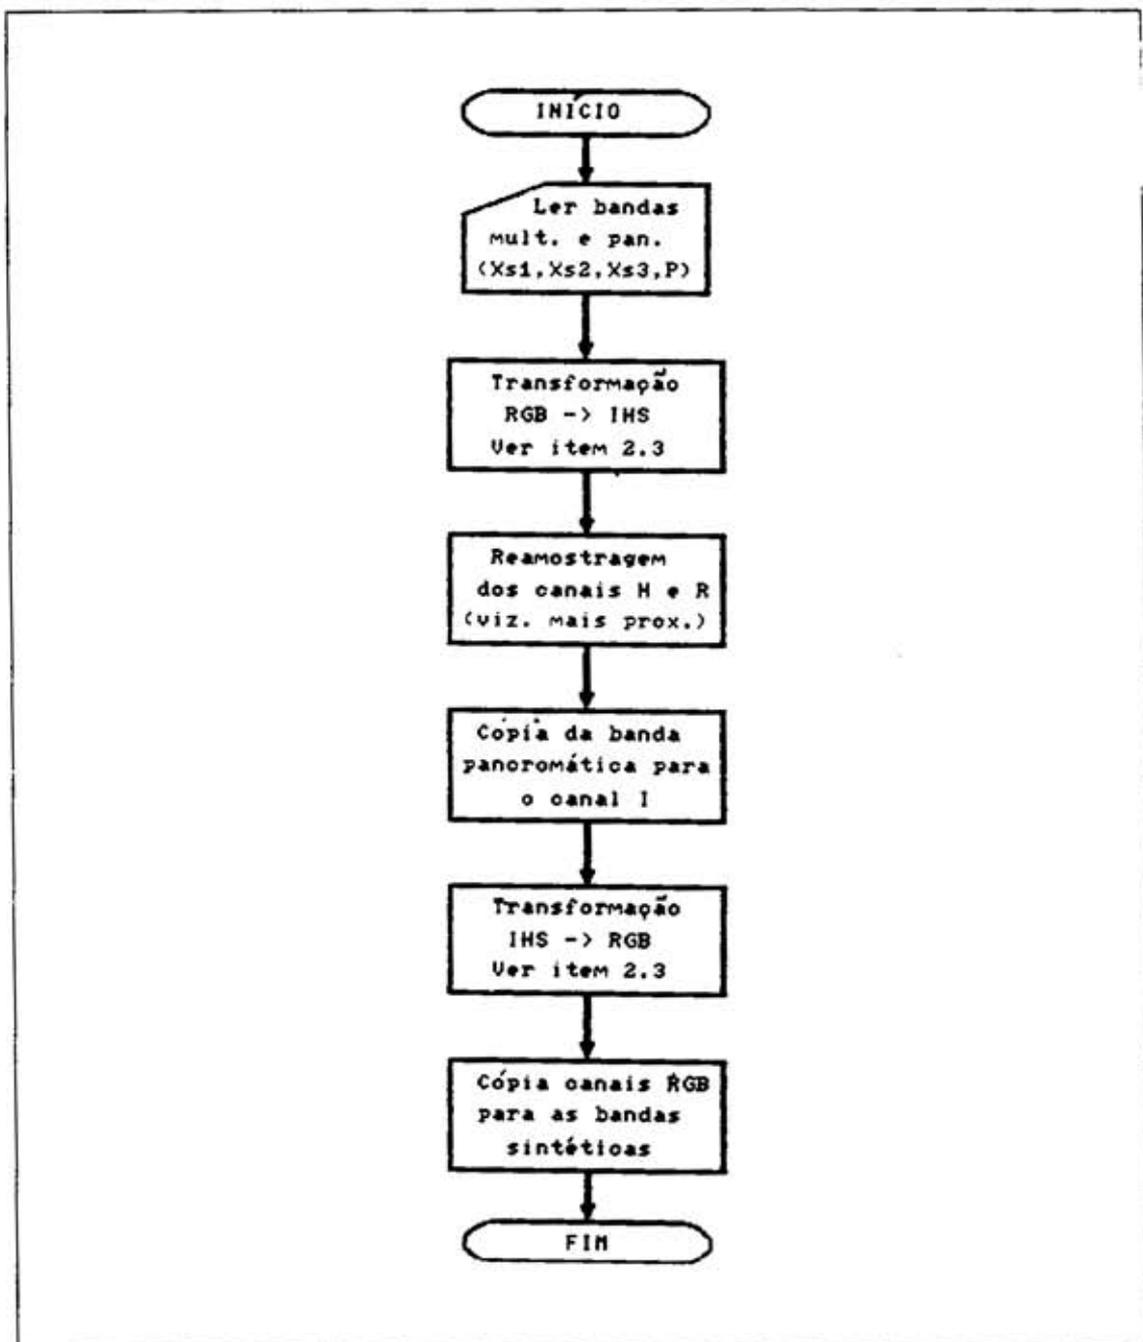


Fig. G.2 - Fluxograma de fusão de imagens usando modelo de Dutra.

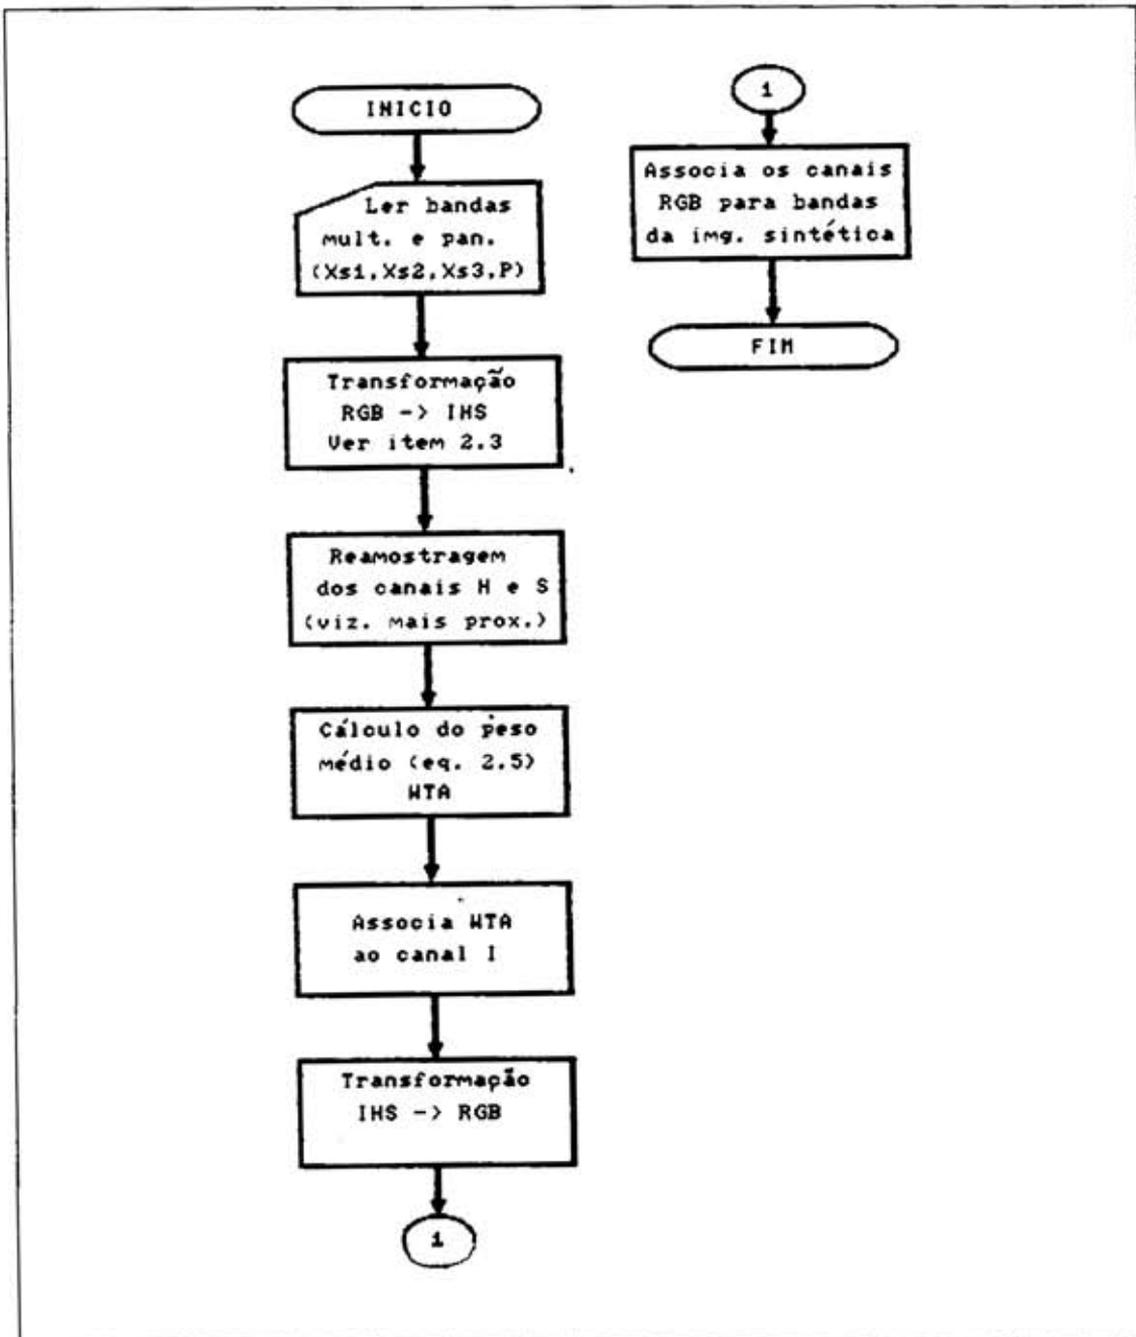


Fig. G.3 - Fluxograma de fusão de imagens usando modelo de Carper.

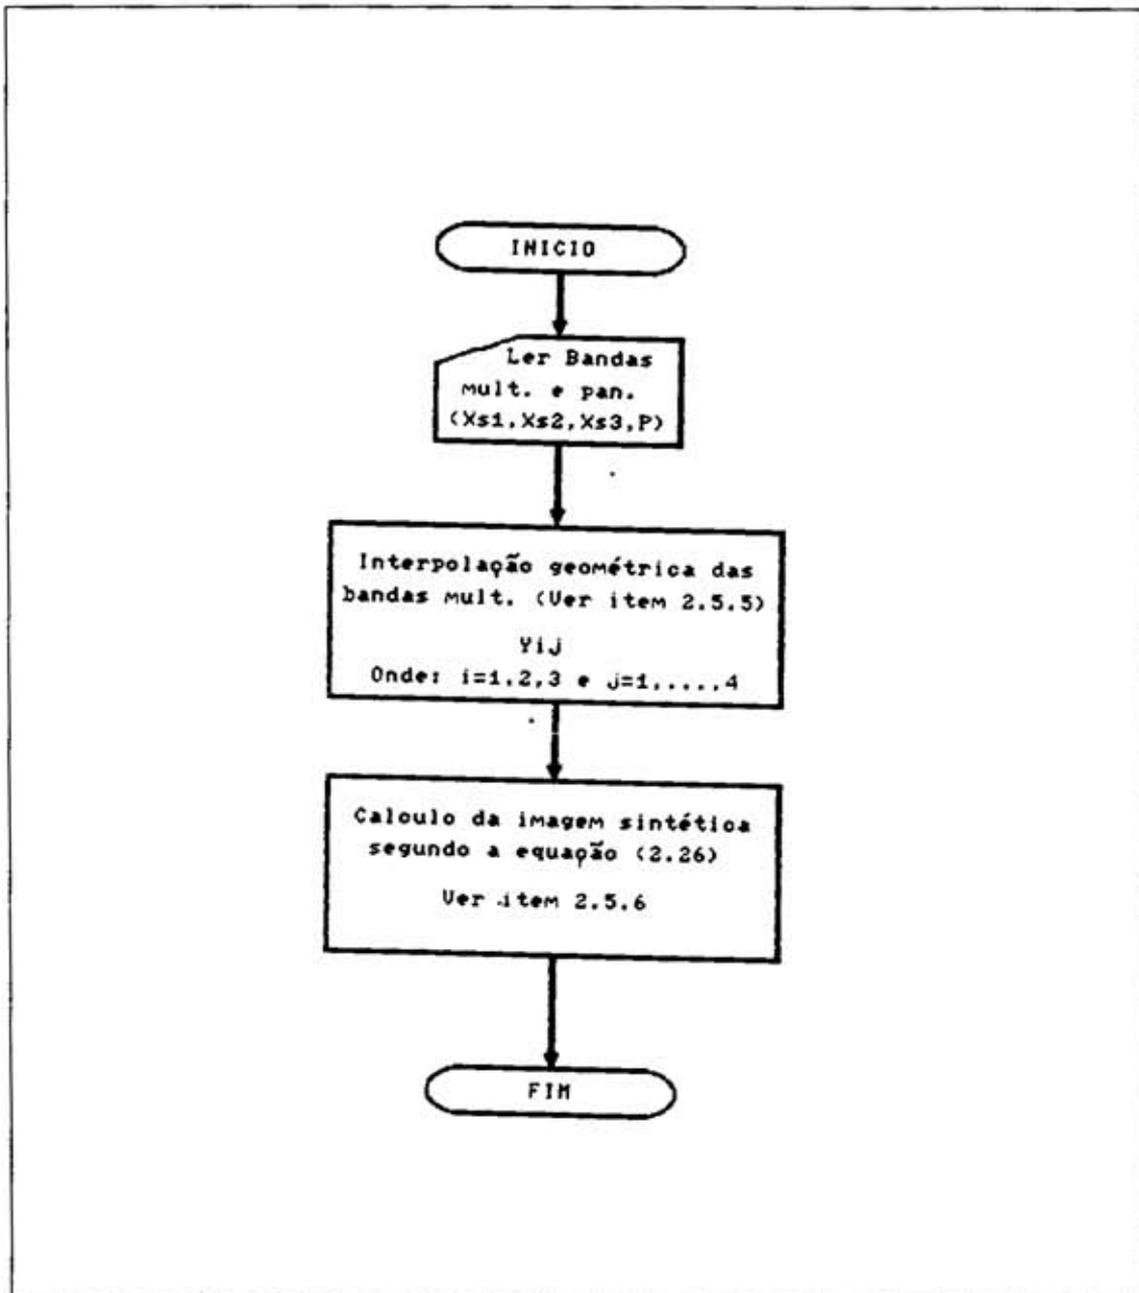


Fig. G.4 - Fluxograma da fusão de dados pelo método desenvolvido em BRUM (1989).

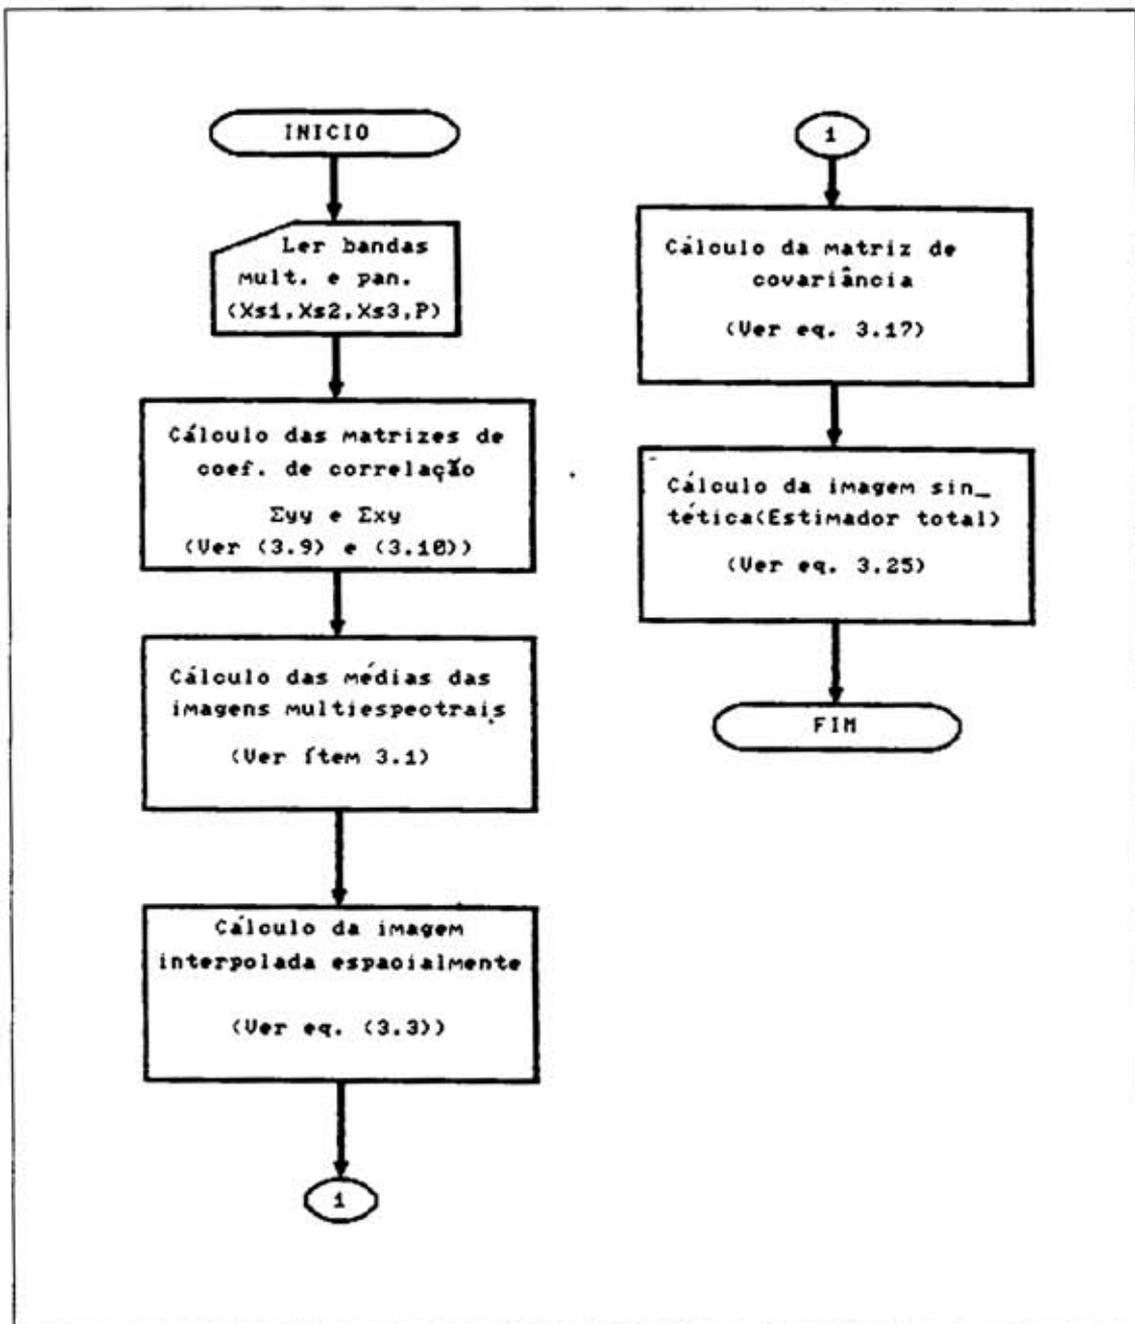


Fig. G.5 - Fluxograma de fusão de dados usando estatística bayesiana.

APÊNDICE H

FIGURAS

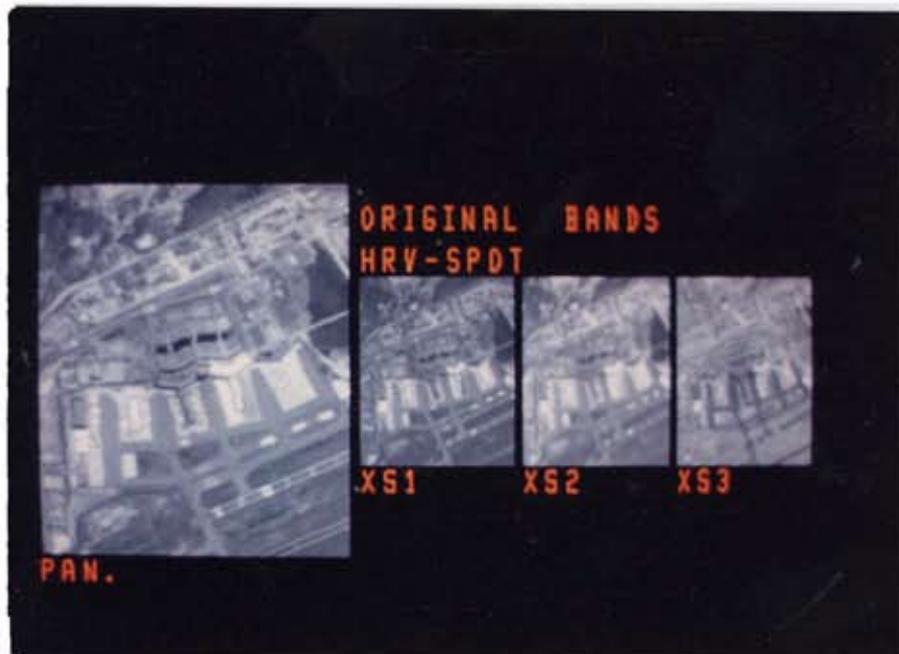


Fig. H.1 - Bandas originais - HRV-SPOT.

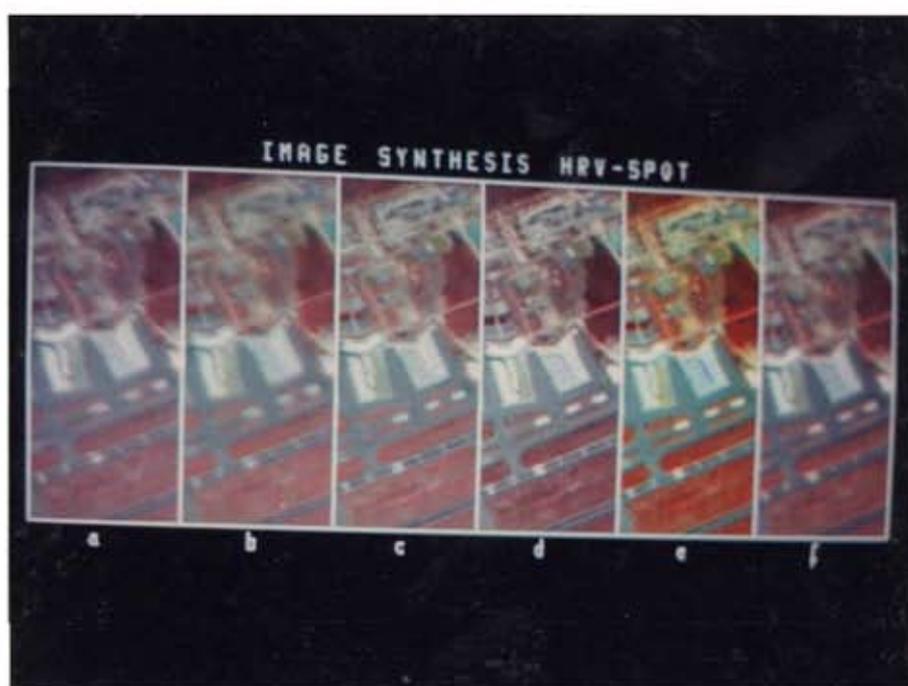


Fig. H.2 - Imagem sintética. a) Cliche; b) Brum; c) Bayes; d) Dutra; e) IHS com Sat.; f) Carper.

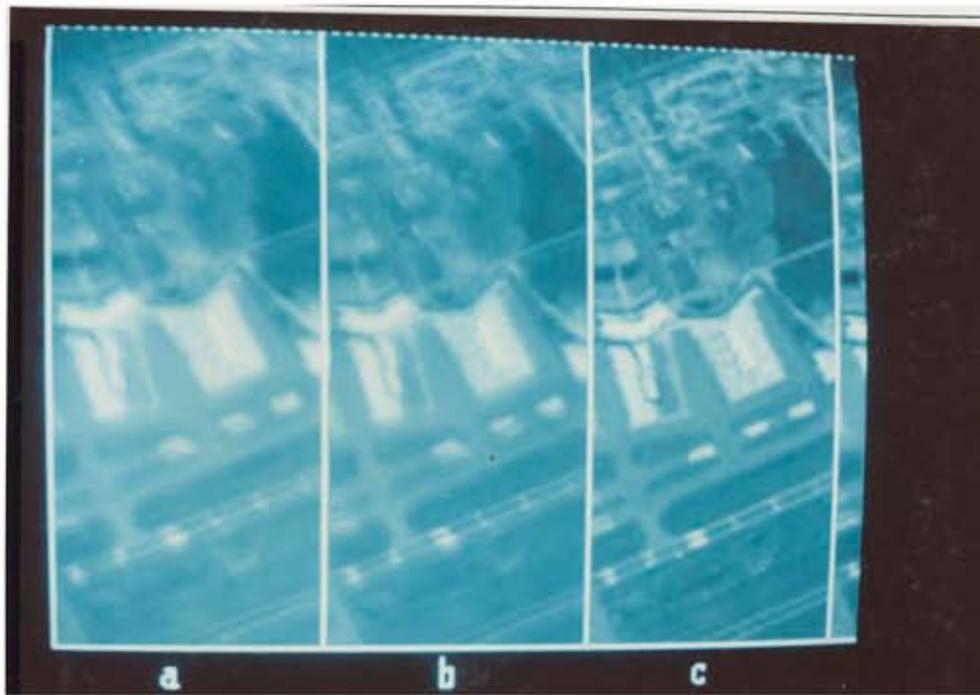


Fig. H.3 - Zoom da Figura H.2 - Banda 2. a) Cliche; b) Brum; c) Bayes.

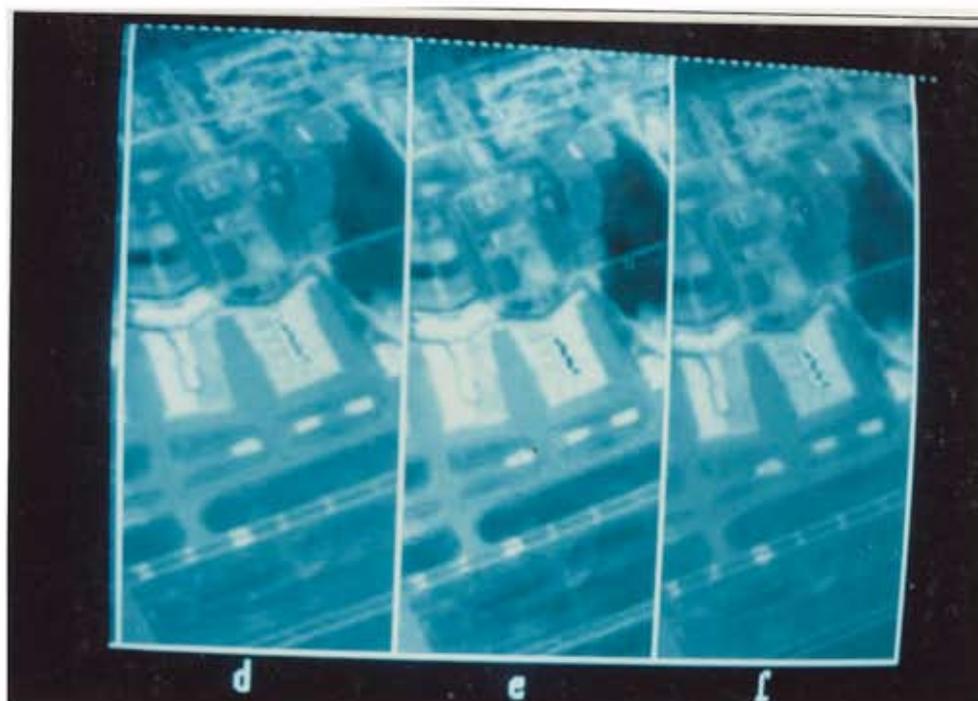


Fig. H.4 - Zoom da figura H.2. d) Dutra; e) IHS com sat.;
f) Carper.

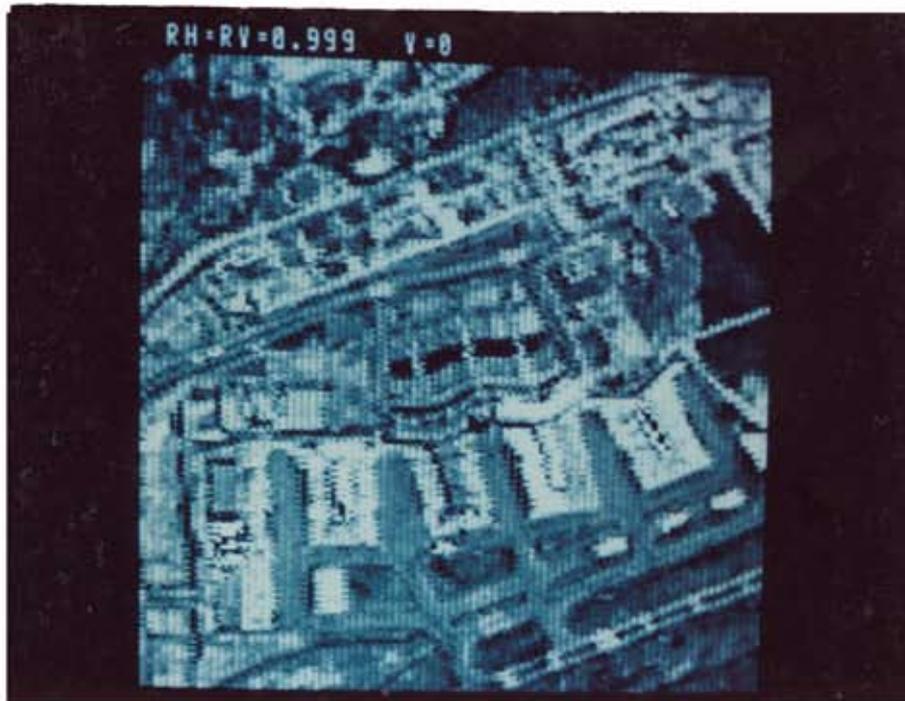


Fig. - H.5 Sistema malcondicionado. Zoom banda 2.
 $\rho_H = \rho_V = 0,999$ e matriz V nula.