

Ronaldo de Freitas Zampolo

**RESTAURAÇÃO DE IMAGENS VIA FILTRAGEM DE KALMAN
E CONSIDERAÇÕES SOBRE A AVALIAÇÃO DA QUALIDADE
DE IMAGENS RESTAURADAS**

Florianópolis
2003

UNIVERSIDADE FEDERAL DE SANTA CATARINA

**PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA**

**RESTAURAÇÃO DE IMAGENS VIA FILTRAGEM DE KALMAN
E CONSIDERAÇÕES SOBRE A AVALIAÇÃO DA QUALIDADE
DE IMAGENS RESTAURADAS**

Tese submetida à
Universidade Federal de Santa Catarina
como parte dos requisitos para a
obtenção do grau de Doutor em Engenharia Elétrica.

RONALDO DE FREITAS ZAMPOLO

Florianópolis, junho de 2003.

RESTAURAÇÃO DE IMAGENS VIA FILTRAGEM DE KALMAN E CONSIDERAÇÕES SOBRE A AVALIAÇÃO DA QUALIDADE DE IMAGENS RESTAURADAS

Ronaldo de Freitas Zampolo

‘Esta Tese foi julgada adequada para obtenção do Título de Doutor em Engenharia Elétrica, Área de Concentração em *Comunicações e Processamento de Sinais*, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina.’

Prof. Rui Seara, Dr.
Orientador

Prof. Edson Roberto De Pieri, Ph.D.
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica

Banca Examinadora:

Prof. Rui Seara, Dr.
Presidente

Prof. Jacques Szczupak, Ph.D.

Prof. Max Henrique Machado Costa, Ph.D.

Prof. Sidnei Noceti Filho, Dr.

Prof. Joceli Mayer, Ph.D.

Eng. Daniel Távora de Queiroz Cobra, Ph.D.

Eng. Orlando José Tobias, Dr.

Dedicado a Bianca, Kelly,
Renata, Helena e Jaime.

AGRADECIMENTOS

A Deus, pelas oportunidades de crescimento.

À minha família, pelo amor incondicional.

Ao meu orientador, Prof. Rui Seara, pelo convívio enriquecedor.

Aos membros da banca examinadora, pelas observações valiosas.

Aos companheiros do LINSE, pela amizade, auxílio, estímulo e paciência.

Aos amigos Márcio, Fernanda, Anna, Jorge, Jô, Tati, Rafa, Rê, Jack, Fabi, Ivete, Carlos, Ludgero, Cecília e Rosilene.

A todos aqueles que de alguma forma contribuíram para que este trabalho pudesse ser concluído.

Ao CNPq, pelo apoio financeiro.

Resumo da Tese apresentada à UFSC como parte dos requisitos necessários para a obtenção do Grau de Doutor em Engenharia Elétrica.

RESTAURAÇÃO DE IMAGENS VIA FILTRAGEM DE KALMAN E CONSIDERAÇÕES SOBRE A AVALIAÇÃO DA QUALIDADE DE IMAGENS RESTAURADAS

Ronaldo de Freitas Zampolo

Junho/2003

Orientador: Rui Seara, Dr.

Área de Concentração: Comunicações e Processamento de Sinais.

Palavras-chave: restauração de imagens, filtro de Kalman, ROMKF, programação evolucionária, medidas de qualidade em imagem.

Número de Páginas: 136

RESUMO: A presente tese trata da utilização de *programação evolucionária* (PE) em sistemas de restauração de imagens via filtragem de Kalman e da proposta de uma medida para avaliação da qualidade de imagens restauradas baseada na percepção visual humana. A PE é usada na etapa de estimação paramétrica do *filtro de Kalman de modelo de ordem reduzida* (reduced order model Kalman filter – ROMKF). Em consequência da função de controle da estimação paramétrica apresentar ótimos locais e da utilização de algoritmos de otimização sensíveis às condições iniciais, as estratégias tradicionais reiniciam o processo de restauração diversas vezes, com diferentes condições iniciais, na tentativa de contornar os problemas de convergência indesejável. Contudo, as simulações apresentadas mostram que a estratégia de reinícios é ineficiente e, por outro lado, uma única restauração via ROMKF-PE é suficiente para se obter uma imagem que é representativa do melhor que o sistema de restauração pode oferecer. Esta tese também propõe uma medida para avaliação da qualidade de imagens restauradas, denominada *medida de qualidade composta* (MQC), que é baseada na percepção visual humana. No desenvolvimento da MQC, são realizados experimentos que avaliam a correlação entre a percepção humana da qualidade em imagens e medidas objetivas dos efeitos de distorção em frequência e injeção de ruído, considerados isoladamente. A MQC é baseada na *medida de qualidade de ruído* (noise quality measure - NQM) e na *medida de qualidade de distorção em frequência* (MQD), sendo validada experimentalmente.

Abstract of Thesis presented to UFSC as partial fulfilment of the requirements for the degree of Doctor in Electrical Engineering.

IMAGE RESTORATION VIA KALMAN FILTERING AND CONSIDERATIONS ON RESTORED IMAGE QUALITY ASSESSMENT

Ronaldo de Freitas Zampolo

June/2003

Advisor: Rui Seara, Dr.

Area of Concentration: Communications and Signal Processing.

Keywords: image restoration, Kalman filter, ROMKF, evolutionary programming, image quality measures.

Number of Pages: 136

ABSTRACT: This thesis addresses the use of *evolutionary programming* (EP) in image restoration systems via Kalman filtering and the proposal of a measure for restored image quality assessment based on human visual perception. EP is used in the *reduced order model Kalman filter* (ROMKF) estimation stage. Since the parametric estimation function presents local optima and an initial-condition sensitive optimization algorithm is commonly used, traditional strategies restart the restoration procedure several times with different initial conditions as an attempt to bypass convergence problems. The presented simulations show that the restart strategy performs poorly and, on the other hand, just one single restoration via ROMKF-EP is sufficient to obtain an image, which is representative of the best quality permitted by the restoration system. This thesis also proposes a measure for restored image quality assessment, termed *composed quality measure* (CQM), which is based on human visual perception. In the CQM development, experiments are made in order to evaluate correlation between human perception of image quality and objective measures for frequency distortion and noise injection, which are considered isolated effects. The CQM is based on the *noise quality measure* (NQM) and *frequency distortion quality measure* (DQM), being validated experimentally.

SUMÁRIO

LISTA DE FIGURAS	IX
LISTA DE TABELAS.....	XI
LISTA DE SÍMBOLOS.....	XII
LISTA DE ACRÔNIMOS	XVI
CAPÍTULO 1 INTRODUÇÃO.....	1
1.1 PERSPECTIVA HISTÓRICA.....	1
1.2 RESTAURAÇÃO DE IMAGENS: DEFINIÇÃO DO PROBLEMA	2
1.3 ESTRATÉGIAS TRADICIONAIS EM RESTAURAÇÃO DE IMAGENS.....	3
1.4 MODELOS DA PERCEPÇÃO VISUAL HUMANA, FERRAMENTAS DE OTIMIZAÇÃO E MICROELETRÔNICA	5
1.5 ABORDAGENS RECENTES EM RESTAURAÇÃO DE IMAGENS	7
1.6 FILTRO DE KALMAN EM DUAS DIMENSÕES	8
1.7 CONTRIBUIÇÕES DESTA TESE.....	9
1.8 ORGANIZAÇÃO DO MANUSCRITO DA TESE	10
CAPÍTULO 2 RESTAURAÇÃO DE IMAGENS.....	13
2.1 INTRODUÇÃO.....	13
2.2 MODELOS DE AQUISIÇÃO/DEGRADAÇÃO E SÍNTESE DE IMAGENS.....	14
2.3 SISTEMAS DE RESTAURAÇÃO DE IMAGENS.....	21
2.4 PRINCIPAIS DESAFIOS NA RESTAURAÇÃO DE IMAGENS	23
2.5 CONCLUSÕES.....	31
CAPÍTULO 3 FILTRAGEM DE KALMAN EM DUAS DIMENSÕES.....	32
3.1 INTRODUÇÃO.....	32
3.2 FILTRAGEM DE KALMAN UNIDIMENSIONAL.....	32
3.3 RESTAURAÇÃO DE IMAGENS VIA FILTRAGEM DE KALMAN	36
3.4 APROXIMAÇÕES DO FILTRO DE KALMAN ORIGINAL.....	41
3.4.1 <i>FILTRO DE KALMAN POR FAIXAS (STRIP KALMAN – SK)</i>	41
3.4.2 <i>FILTRO DE KALMAN DE ATUALIZAÇÃO REDUZIDA (REDUCED UPDATE KALMAN FILTER – RUKF)</i>	43
3.4.3 <i>FILTRO DE KALMAN DE MODELO DE ORDEM REDUZIDA (REDUCED ORDER MODEL KALMAN FILTER – ROMKF)</i>	44
3.5 CONCLUSÕES.....	49
CAPÍTULO 4 COMPUTAÇÃO EVOLUCIONÁRIA	50
4.1 INTRODUÇÃO.....	50
4.2 BREVE HISTÓRICO E BASES FILOSÓFICAS	50
4.3 DIFERENTES ALGORITMOS.....	53
4.3.1 <i>ALGORITMO GENÉTICO (AG)</i>	54
4.3.2 <i>PROGRAMAÇÃO EVOLUCIONÁRIA (PE)</i>	60
4.4 CONCLUSÕES.....	64
CAPÍTULO 5 RESTAURAÇÃO DE IMAGENS VIA ROMKF E PROGRAMAÇÃO EVOLUCIONÁRIA	66
5.1 INTRODUÇÃO.....	66
5.2 CONSIDERAÇÕES À ABORDAGEM TRADICIONAL DE ESTIMAÇÃO EM RESTAURAÇÃO DE IMAGENS	67

5.3 RESULTADOS EXPERIMENTAIS.....	71
5.3.1 PRIMEIRO EXPERIMENTO.....	72
5.3.2 SEGUNDO EXPERIMENTO.....	78
5.4 CONCLUSÕES.....	85
CAPÍTULO 6 MEDIDAS DA QUALIDADE DE UMA IMAGEM	87
6.1 INTRODUÇÃO.....	87
6.2 MEDIDAS CONVENCIONAIS PARA AVALIAÇÃO DA QUALIDADE DE UMA IMAGEM	88
6.2.1 RAZÃO ENTRE SINAL E RUÍDO (SIGNAL TO NOISE RATIO – SNR)	88
6.2.2 RAZÃO ENTRE PICO DO SINAL E RUÍDO (PEAK SIGNAL TO NOISE RATIO – PSNR)....	89
6.2.3 RAZÃO ENTRE SINAL DEGRADADO E RUÍDO (BLURRED SIGNAL TO NOISE RATIO – BSNR).....	89
6.2.4 MELHORAMENTO NA RAZÃO ENTRE SINAL E RUÍDO (IMPROVEMENT IN SIGNAL TO NOISE RATIO – ISNR).....	90
6.2.5 DISCUSSÃO	90
6.3 MEDIDAS DA QUALIDADE DE UMA IMAGEM COERENTES COM A PERCEPÇÃO HUMANA	91
6.3.1 FUNÇÃO DE SENSIBILIDADE AO CONTRASTE (CONTRAST SENSITIVITY FUNCTION – CSF) E FUNÇÃO DE LIMIAR DE CONTRASTE (CONTRAST THRESHOLD FUNCTION – CTF)	92
6.3.2 RAZÃO ENTRE SINAL E RUÍDO PONDERADA (WEIGHTED SIGNAL TO NOISE RATIO – WSNR)	93
6.3.3 MEDIDAS DE CONTRASTE	94
6.3.4 TRATAMENTO EM SEPARADO DOS EFEITOS DA DISTORÇÃO EM FREQUÊNCIA E AMPLIFICAÇÃO DE RUÍDO	98
6.3.5 MEDIDA DE DISTORÇÃO (DISTORTION MEASURE – DM) E MEDIDA DE QUALIDADE DE RUÍDO (NOISE QUALITY MEASURE – NQM).....	100
6.3.6 DISCUSSÃO	103
6.4 AVALIAÇÃO DAS MEDIDAS DE QUALIDADE NQM E DM EM RELAÇÃO À QUALIDADE SUBJETIVA.....	103
6.4.1 AVALIAÇÃO DA NQM.....	104
6.4.2 AVALIAÇÃO DA DM	106
6.5 PROPOSTA E VALIDAÇÃO EXPERIMENTAL DE UMA MEDIDA PARA DISTORÇÃO EM FREQUÊNCIA: MEDIDA DE QUALIDADE PARA DISTORÇÃO EM FREQUÊNCIA (MQD). 110	
6.6 PROPOSTA E VALIDAÇÃO EXPERIMENTAL DE UMA MEDIDA DE QUALIDADE COMPOSTA	114
6.6.1 DISCUSSÃO	118
6.7 CONCLUSÕES.....	118
CAPÍTULO 7 RESTAURAÇÃO USANDO MQC+ROMKF-PE.....	120
7.1 INTRODUÇÃO.....	120
7.2 EXPERIMENTO 01	120
7.3 EXPERIMENTO 02	122
7.4 CONCLUSÕES.....	125
CAPÍTULO 8 CONCLUSÕES.....	126
8.1 CONTRIBUIÇÕES DESTA TESE.....	126
8.2 SUGESTÃO PARA FUTUROS TRABALHOS.....	128
REFERÊNCIAS BIBLIOGRÁFICAS.....	129

LISTA DE FIGURAS

Fig. 1.1 – Uma das fotos enviadas pela Ranger 7.....	2
Fig. 2.1 – Aquisição de imagens.	15
Fig. 2.2 – Restauração via filtragem inversa: (a) imagem original; (b) imagem degradada por movimento horizontal (de comprimento de 9 pixels); (c) restauração em condições ideais (sem ruído e degradação perfeitamente identificada); (d) restauração a partir de imagem degradada com ruído e degradação perfeitamente identificada (imagem degradada: SNR = 40 dB ; restauração: SNR = 7 dB); (e) restauração a partir de imagem degradada isenta de ruído e degradação incorretamente identificada (movimento horizontal, de comprimento de 7 pixels).	26
Fig. 2.3 – Filtragem inversa: (a) módulo da resposta em frequência do filtro de degradação; (b) módulo da resposta em frequência do filtro inverso; (c) módulo da resposta em frequência do filtro inverso modificado, segundo (2.17); (d) módulo da resposta em frequência do filtro inverso modificado, segundo (2.18) ($K = 1$ e $\Omega = 300$ amostras).	27
Fig. 2.4 – Comparação de resultados entre filtro inverso e filtro de Wiener: (a) imagem degradada (SNR = 40 dB); (b) imagem degradada (SNR = 22 dB); (c) restauração de (a) usando filtro inverso (SNR = 7 dB); (d) restauração de (b) usando filtro inverso (SNR = -10 dB); (e) restauração de (a) usando filtro de Wiener (SNR = 23 dB); (f) restauração de (b) usando filtro de Wiener (SNR = 17 dB).	30
Fig. 3.1 – Sistema completo (geração do sinal observado e filtro de Kalman).	34
Fig. 3.2 – Exemplos de direção e sentido de processamento: (a) da esquerda para a direita, de cima para baixo; (b) da direita para a esquerda, de cima para baixo; (c) de cima para baixo, da esquerda para a direita; e (d) de baixo para cima, da esquerda para a direita.	37
Fig. 3.3 – Região correspondente na imagem original aos elementos do vetor de estado, considerando o processamento da esquerda para a direita, de cima para baixo.	40
Fig. 3.4 – Região dos pixels de contorno.	40
Fig. 3.5 – As duas primeiras faixas verticais (com superposição) de uma imagem a ser restaurada por um filtro SK.	42
Fig. 3.6 – Elementos centrais do vetor de estado que são preservados para compor a imagem restaurada.	42
Fig. 3.7 – Vetor de estado completo, mostrando a região que será atualizada (X_1) e a região que não será atualizada (X_2) no RUKF.	44
Fig. 3.8 – Modelo de suporte $M_1 \times M_2 \times M_3$ NSHP, adaptado ao processamento linha-a-linha, da esquerda para a direita, de cima para baixo.	45
Fig. 3.9 – Os elementos que não podem ser representados em função do vetor de estado reduzido anterior (elementos mais à direita do modelo de suporte).	46
Fig. 3.10 – Aproximações dos elementos mais à direita do suporte do vetor de estado reduzido: (a) vizinho mais próximo; (b) wrap around; (c) melhor estimativa.	47
Fig. 4.1 – Exemplo de um cromossomo de 12 bits ou genes.	55
Fig. 4.2 – Cálculo de parâmetros de uma <i>função aptidão</i> a partir de um cromossomo de 12 bits, sendo que 3 bits são reservados para cada parâmetro. Cada parâmetro, portanto, pode assumir 8 valores distintos. Nesse exemplo, os parâmetros foram concatenados de forma seqüencial.	56
Fig. 4.3 – Cruzamento simples entre dois cromossomos.	57
Fig. 4.4 – Exemplo de mutação em um cromossomo.	58
Fig. 4.5 – Ciclo básico de um algoritmo genético.	59
Fig. 4.6 – Ciclo básico da PE.	62
Fig. 5.1 – Seção da imagem <i>cameraman</i> , tomada neste experimento como imagem original.	72
Fig. 5.2 – Imagem degradada sinteticamente com PSF do tipo movimento horizontal de câmera de dimensão 1×7 e adição de ruído do tipo Gaussiano ($BSNR=40$ dB).	72
Fig. 5.3 – Suporte do tipo NSHP de dimensão $1 \times 6 \times 2$, usado nas simulações do primeiro experimento. ...	74
Fig. 5.4 – Imagens restauradas via ROMKF, usando DHSM, na etapa de estimação paramétrica, para condições iniciais aleatórias. A imagem da extrema esquerda na primeira linha é referente à 74	74

Fig. 5.5 – Imagens restauradas via ROMKF, usando PE, na etapa de estimação paramétrica, para condições iniciais aleatórias. A imagem da extrema esquerda na primeira linha é referente à restauração de número 1. A imagem referente à restauração de número 2 é a imediatamente à direita da número 1 e, assim, sucessivamente até a imagem da extrema direita na segunda linha que é referente à restauração de número 12.....	76
Fig. 5.6 – Imagem <i>cameraman</i> , tomada neste experimento como imagem original.....	78
Fig. 5.7 – Imagem com lado esquerdo degradado sinteticamente com PSF do tipo movimento horizontal de câmera de dimensão 1×7 e lado direito inalterado. É adicionado ruído do tipo Gaussiano para $BSNR=40$ dB.....	79
Fig. 5.8 – Imagem restaurada típica, usando ROMKF-PE, dividindo a imagem degradada em 4 regiões para fins de processamento.....	80
Fig. 5.9 – Evolução da média de J_N da população por geração e valor de J_N do melhor indivíduo por geração. De cima para baixo, da esquerda para a direita, curvas correspondentes às restaurações de número 1 a 6, respectivamente.....	81
Fig. 5.10 – Evolução da variância de J_N da população ao longo das gerações. De cima para baixo, da esquerda para a direita, curvas correspondentes às restaurações de número 1 a 6, respectivamente.....	83
Fig. 6.1 – Curva da Função de Sensibilidade ao Contraste (Contrast Sensitivity Function – <i>CSF</i>).....	92
Fig. 6.2 – Curva da Função de Limiar de Contraste (Contrast Threshold Function – <i>CTF</i>) real.....	93
Fig. 6.3 – Resposta em frequência de filtros do tipo $G_i(f)$ para diferentes valores de i . Da esquerda para a direita, de cima para baixo: $i = 0$, $i = 1$, $i = 2$, $i = 3$, $i = 4$, $i = 5$ e $i = 6$. Na última curva (embaixo, à direita), é mostrado o somatório das curvas anteriores.....	97
Fig. 6.4 – Estrutura de avaliação de um sistema de restauração de imagens em que os efeitos de distorção em frequência e injeção de ruído são considerados isoladamente.....	99
Fig. 6.5 – Imagem original do experimento de avaliação da <i>NQM</i> (Imagem “Lena”)......	105
Fig. 6.6 – Avaliação da <i>NQM</i>	105
Fig. 6.7 – Imagem original #01 usada no experimento de avaliação da <i>DM</i> (Imagem “Lena”).....	107
Fig. 6.8 – Imagem original #02 usada no experimento de avaliação da <i>DM</i> (Imagem “Baboon”).....	108
Fig. 6.9 – Imagem original #03 usada no experimento de avaliação da <i>DM</i> (Imagem “Peppers”).....	108
Fig. 6.10 – Imagem original #04 usada no experimento de avaliação da <i>DM</i> (Imagem “Bridge”).....	109
Fig. 6.11 – Avaliação da <i>DM</i> , para os conjuntos de imagens gerados a partir das imagens originais #01, #02, #03 e #04.....	109
Fig. 6.12 – Avaliação da <i>MQD</i> para o conjunto obtido a partir da imagem original #01.....	112
Fig. 6.13 – Avaliação da <i>MQD</i> para o conjunto obtido a partir da imagem original #02.....	112
Fig. 6.14 – Avaliação da <i>MQD</i> para o conjunto obtido a partir da imagem original #03.....	113
Fig. 6.15 – Avaliação da <i>MQD</i> para o conjunto obtido a partir da imagem original #04.....	113
Fig. 6.16 – Classificação média em função da <i>DM</i> e da <i>NQM</i> para o conjunto de imagens degradadas por combinação entre distorção em frequência e injeção de ruído.....	115
Fig. 6.17 – Classificação média em função da <i>MQD</i> e da <i>NQM</i> para o conjunto de imagens degradadas por combinação entre distorção em frequência e injeção de ruído.....	115
Fig. 7.1 – Imagem degradada sinteticamente com PSF do tipo movimento horizontal de câmera de dimensão 1×7 e adição de ruído do tipo Gaussiano ($BSNR = 40$ dB).....	121
Fig. 7.2 – Imagem restaurada via ROMKF-PE e <i>MQC</i> como função objetivo na etapa de estimação paramétrica.....	122
Fig. 7.3 – Imagem restaurada via ROMKF, sem máscara e sem ponderação ($k = 1$) do parâmetro que modela a variância do ruído de observação.....	123
Fig. 7.4 – Imagem restaurada via ROMKF, sem máscara e com ponderação ($k = 10$) do parâmetro que modela a variância do ruído de observação.....	124
Fig. 7.5 – Imagem restaurada via ROMKF, com máscara de ponderação do parâmetro que modela a variância do ruído de observação [70].....	124

LISTA DE TABELAS

Tabela 4.1 – Programação evolucionária: algoritmo usado nas simulações do Capítulo 5	64
Tabela 5.1 – Dados numéricos das restaurações via ROMKF, usando DHSM, na etapa de estimação paramétrica, para condições iniciais aleatórias.....	75
Tabela 5.2 – Dados numéricos das restaurações via ROMKF, usando PE, na etapa de estimação paramétrica, para condições iniciais aleatórias	76
Tabela 7.1 – Medidas referentes às imagens restauradas do Experimento 02.....	123

LISTA DE SÍMBOLOS

$v(m, n)$	imagem adquirida, imagem degradada;
$x(m, n)$	objeto, imagem original;
$\hat{x}(m, n)$	imagem restaurada;
$T[\mathbf{g}]$	efeito de transformação entre os planos do objeto e da imagem;
$c(m, n)$	função de espalhamento de ponto (<i>point spread function</i> – PSF);
$\eta(m, n)$	ruído de degradação;
$a(m, n)$	coeficientes do filtro AR;
$\xi(m, n)$	ruído de entrada do filtro AR;
$X(\omega_1, \omega_2)$	transformada de Fourier de $x(m, n)$;
$\hat{X}(\omega_1, \omega_2)$	transformada de Fourier de $\hat{x}(m, n)$;
$V(\omega_1, \omega_2)$	transformada de Fourier de $v(m, n)$;
$C(\omega_1, \omega_2)$	transformada de Fourier de $c(m, n)$;
$\hat{C}^{-1}(\omega_1, \omega_2)$	aproximação de $C^{-1}(\omega_1, \omega_2)$;
$H(\omega_1, \omega_2)$	transformada de Fourier de $\eta(m, n)$;
$\Phi_{xx}(\omega_1, \omega_2)$	espectro de potência de $x(m, n)$;
$\Phi_{\eta\eta}(\omega_1, \omega_2)$	espectro de potência de $\eta(m, n)$;
\mathbf{x}_k	vetor de estado;
\mathbf{A}_k	matriz de transição do estado \mathbf{x}_k para o estado \mathbf{x}_{k+1} ;
$\mathbf{\Gamma}_k$	matriz de ponderação do ruído de entrada;
ξ_k	ruído de entrada;
\mathbf{v}_k	sinal observado;
\mathbf{C}_k	matriz de observação;

η_k	ruído de saída ou de observação;
\mathbf{R}_k	matriz de covariância de ξ_k ;
\mathbf{Q}_k	matriz de covariância de η_k ;
δ_{kl}	operador de Kronecker;
$\hat{\mathbf{x}}_k$	estimativa de \mathbf{x}_k ;
V_k	conjunto de todas as amostras observadas desde 0 até k ;
\mathbf{G}_k	ganho de Kalman;
$\hat{\mathbf{x}}_{m n}$	estimativa de \mathbf{x}_m , dado V_n ;
$\bar{\mathbf{x}}_k$	média de \mathbf{x}_k ;
$Var[\mathbf{g}]$	operador de variância;
$E[\mathbf{g}]$	operador de expectância;
$P_{m,n}$	erro quadrático médio entre \mathbf{x}_m e $\hat{\mathbf{x}}_{m n}$;
\mathbf{u}_k	vetor determinístico;
\mathbf{E}_k	matriz de ponderação de \mathbf{u}_k ;
D_1	suporte de $a(m,n)$;
D_2	suporte de $c(m,n)$;
M_1	extensão vertical do suporte do vetor de estado;
M_2	extensão horizontal do suporte do vetor de estado, à esquerda da amostra atual;
M_3	extensão horizontal do suporte do vetor de estado, à direita da amostra atual;
J	função custo usada na etapa de estimação paramétrica do ROMKF;
N	número de amostras processadas da imagem degradada;
R_{ee}	covariância do processo inovação no estado estacionário;

P_c	probabilidade de cruzamento;
P_m	probabilidade de mutação;
\mathbf{p}_i	vetor de parâmetros do indivíduo i ;
σ_i	variável (desvio padrão) de controle da mutação do indivíduo i ;
q	número de oponentes;
μ	número de indivíduos de uma população;
l	geração de uma população;
ρ	termo que define uma PSF parametrizada;
J_N	função J normalizada em relação ao número de amostras processadas;
P	número de parâmetros a estimar;
$s(m, n)$	imagem de interesse sem ruído;
$s_\eta(m, n)$	imagem contaminada;
P_{\max}	valor da máxima excursão de um sinal (pico-a-pico);
$v'(m, n)$	imagem degradada isenta de ruído;
\bar{v}	média de $v'(m, n)$;
σ_η^2	variância do ruído de observação;
$S(\omega_1, \omega_2)$	transformada de Fourier de $s(m, n)$;
$S_\eta(\omega_1, \omega_2)$	transformada de Fourier de $s_\eta(m, n)$;
$C_{HP}(\omega_1, \omega_2)$	contraste de Hess & Pointer;
$G_i(f)$	filtro passa-banda log-cosseno sintonizado em 2^i ciclos/imagem;
$S_i(\omega_1, \omega_2)$	transformada de Fourier da imagem resultante da filtragem de $S(\omega_1, \omega_2)$ por $G_i(\omega_1, \omega_2)$;

$s_i(m, n)$	transformada inversa de $S_i(\omega_1, \omega_2)$;
$c_i^p(m, n)$	contraste de Peli na banda centrada em 2^i ciclos/imagem;
$c_i^{PL}(m, n)$	contraste de Peli-Lubin na banda centrada em 2^i ciclos/imagem;
$O_s(m, n)$	versão sintetizada da imagem modelo;
$I_s(m, n)$	versão sintetizada da imagem restaurada;

LISTA DE ACRÔNIMOS

AG	algoritmo genético;
AR	auto-regressivo;
BSNR	razão entre sinal degradado e ruído (<i>blurred signal to noise ratio</i>);
CSF	função de sensibilidade ao contraste (<i>contrast sensitivity function</i>);
CTF	função de limiar de contraste (<i>contrast threshold function</i>);
DHSM	<i>Downhill simplex method</i> ;
DM	medida de distorção (<i>distortion measure</i>);
ISNR	melhoramento na razão entre sinal e ruído (<i>improvement in signal to noise ratio</i>);
MA	<i>moving-average</i> ;
MQC	medida de qualidade composta;
MQD	medida de qualidade de distorção;
MSE	erro quadrático médio (<i>mean square error</i>);
NQM	medida de qualidade de ruído (<i>noise quality measure</i>);
NSHP	meio plano assimétrico (<i>non-symmetric half plane</i>);
PE	programação evolucionária;
PSF	função de espalhamento de ponto (<i>point spread function</i>);
PSNR	razão entre pico do sinal e ruído (<i>peak signal to noise ratio</i>);
ROMKF	filtro de Kalman de modelo de ordem reduzida (<i>reduced order model Kalman filter</i>);
RUKF	filtro de Kalman de atualização reduzida (<i>reduced update Kalman filter</i>);
SA	arrefecimento simulado (<i>simulated annealing</i>);
SK	filtro de Kalman por faixas (<i>strip Kalman</i>);
SNR	razão entre sinal e ruído (<i>signal to noise ratio</i>);
WSNR	razão entre sinal e ruído ponderada (<i>weighted signal to noise ratio</i>).

1.1 Perspectiva histórica

Nos anos 50 e 60 do século XX, a humanidade testemunhou a chamada *corrida ao espaço*, cuja finalidade aparente seria a de estender os domínios e possibilidades humanos para além dos limites da Terra. Contudo, implicitamente, havia uma disputa entre as potências americana e soviética, por meio de suas recém-criadas agências espaciais, que mobilizou grande volume de recursos econômicos e humanos. Nessa disputa, os referidos países tentavam demonstrar a superioridade dos seus respectivos sistemas político-econômicos e, obviamente, das ideologias que lhes davam sustentação.

Deixando de lado as questões ideológicas e políticas, a *conquista do espaço* trouxe grandes contribuições em diversas áreas do conhecimento. Ciência, filosofia e religião tiveram vários de seus conceitos reavaliados como resultado das informações inéditas recebidas das sondas, satélites e missões tripuladas. Informações que vêm mudando o modo de vida do ser humano e de como esse se relaciona com o Universo.

No tocante à ciência, os avanços não são devidos exclusivamente às informações enviadas de fora da Terra, mas decorrem, muitas vezes, das dificuldades encontradas nas diversas missões espaciais e do esforço na tentativa de solucioná-las. Nesse sentido, um aspecto das referidas missões de particular interesse para esta tese é o envio de imagens obtidas no espaço para estações terrestres. A primeira sonda que enviou fotos para a Terra foi a Ranger 7, lançada em 28 de julho de 1964 [57], cuja missão era obter e transmitir à Terra fotografias da superfície lunar. Antes de se chocar com a Lua, a Ranger 7 enviou 4.300 imagens (Fig. 1.1). Após as viagens da Ranger 7, diversas outras imagens vieram (da própria Terra, galáxias, planetas, etc.), revelando cenários antes apenas vislumbrados pela imaginação.

Porém, as condições nas quais é feita a aquisição de uma imagem espacial são muito adversas. Além dos evidentes rigores ambientais, como diferenças bastante acentuadas de temperatura e gravidade zero, abundam outros fatores que contribuem para a degradação de uma imagem, como, por exemplo, os movimentos de rotação e translação do equipamento fotográfico em relação ao objeto a ser fotografado, a dificuldade para corrigir um eventual desajuste ou desgaste do equipamento de aquisição, interferência eletromagnética, etc. [8], [56]. Assim, naqueles dias de pioneirismo, em decorrência da incipiente tecnologia espacial, era comum que as imagens provenientes das sondas apresentassem qualidade aquém do aceitável.

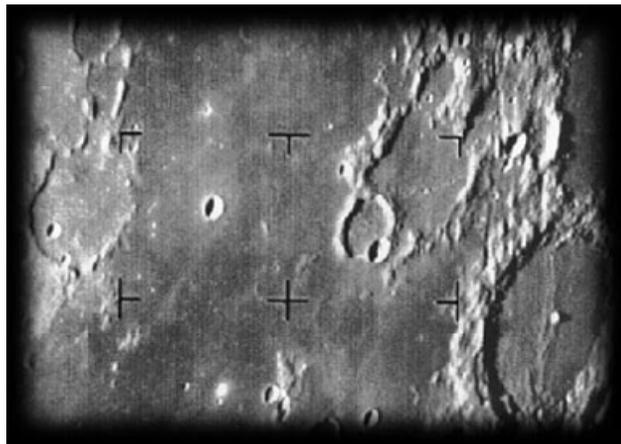


Fig. 1.1 – Uma das fotos enviadas pela Ranger 7 [57].

Como os investimentos na obtenção e o valor científico daquelas imagens eram inestimáveis, surgiu a imperiosa necessidade de que um processamento posterior à aquisição melhorasse a qualidade do material fotografado. É dessa maneira, premida por fatores de ordem política, econômica e científica, que a restauração de imagens recebe um vigoroso impulso da corrida espacial [8], [56].

1.2 Restauração de imagens: definição do problema

A restauração de imagens define-se, portanto, como um ramo do processamento de sinais, cujo objetivo é melhorar a qualidade de uma imagem degradada, usando modelos que descrevam as características do sistema de aquisição daquela imagem. Um sistema de

restauração é orientado no sentido de perseguir o que seria a imagem resultante de uma aquisição perfeita (chamada de *imagem original*), a partir de uma versão ou versões disponíveis dessa imagem. Essas versões apresentam-se mais ou menos degradadas em função das características do sistema de aquisição real. A restauração de imagens é, essencialmente, um procedimento de estimação, pois procura obter uma aproximação da imagem original a partir de uma versão degradada sua e de algum conhecimento sobre as características do sistema de aquisição.

Matematicamente, a restauração de imagens é considerada um problema de difícil solução, em decorrência de seu *mau-condicionamento*. Essa característica significa que pequenos desvios, naqueles que seriam os parâmetros mais adequados ao sistema de restauração, levam a grandes desvios na imagem resultante, tendo como referência a imagem original [3]. Os parâmetros do sistema de restauração advêm do conhecimento sobre o processo de aquisição e também sobre certas características da imagem original.

1.3 Estratégias tradicionais em restauração de imagens

As estratégias tradicionais em restauração consideram que o sistema de aquisição encontra-se perfeitamente modelado e identificado, não obstante, os modelos serem sempre aproximações dos sistemas reais e, na maioria das situações práticas, os parâmetros de tais modelos serem parcialmente conhecidos.

Esse conhecimento parcial, aliado ao *mau-condicionamento*, levou ao desenvolvimento de técnicas que visam estimar o tipo e os parâmetros da degradação, a partir da imagem degradada, uma vez que nem sempre é possível o estudo ou o acesso ao sistema de aquisição. Dentre as referidas técnicas, podem-se citar, como as mais difundidas, aquelas que: procuram estimar a resposta dos sistemas de degradação a partir das características presentes em regiões das imagens degradadas onde deveria haver uma borda ou um ponto em fundo uniforme [3]; analisam a resposta em frequência da imagem degradada à procura de padrões de zeros que identifiquem a degradação [3]; usam o processamento homomórfico para identificação de degradações invariantes [14].

O uso de estratégias tradicionais em situações práticas requer, portanto, uma etapa de identificação do sistema de aquisição, anterior à restauração propriamente dita. Essa identificação é feita verificando, quando possível, a resposta do sistema de aquisição a

diferentes imagens-padrão. Quando a realização de experimentos de identificação no sistema de aquisição não for possível, a estimação da degradação é feita a partir da imagem degradada disponível. As razões de tal impossibilidade podem ser: a inacessibilidade do sistema de aquisição, o custo proibitivo dos experimentos de identificação e a variância temporal dos parâmetros do sistema de aquisição. Em geral, as publicações que tratam da restauração de imagens em uma abordagem tradicional consideram a identificação da degradação e a restauração propriamente dita como etapas isoladas [1], [3], [37].

Todo sistema de restauração possui um critério de qualidade subjacente, o qual efetivamente orienta o processo de estimação da imagem original e responde pela qualidade da restauração. Nas abordagens tradicionais, esse critério é, via de regra, baseado no *erro quadrático médio* (mean square error – MSE). Os filtros bidimensionais de Wiener e de Kalman são exemplos típicos de estratégias orientadas pelo MSE, destacando-se, também, os sistemas que usam como critério a minimização do MSE com restrições [8].

Além do supracitado critério de qualidade subjacente, são usadas medidas para quantificar o melhoramento de qualidade resultante do procedimento de restauração, bem como para caracterizar o nível de ruído presente na imagem degradada. Essas medidas são usadas para avaliar ou ajustar um determinado sistema de restauração, uma vez que requerem sinais normalmente indisponíveis em situações práticas, tais como a imagem original e uma versão isenta de ruído da imagem degradada. Uma característica adicional é que essas medidas tradicionais, bem como o MSE, são baseadas na avaliação da energia dos sinais de interesse. A *razão entre sinal e ruído* (signal to noise ratio – SNR), *razão entre pico do sinal e ruído* (peak signal to noise ratio – PSNR), *razão entre imagem degradada e ruído* (blurred signal to noise ratio – BSNR) e o *melhoramento na razão entre sinal e ruído* (improvement in signal to noise ratio – ISNR) são exemplos desse tipo de medida [23].

Embora a avaliação da energia dos sinais de interesse não represente adequadamente a percepção humana da qualidade de imagens, as medidas anteriormente citadas tornaram-se bastante populares no processamento de imagens, em particular na restauração. A justificativa para tal popularidade advém da baixa complexidade computacional e da simplicidade algébrica de tais medidas, fatores relevantes considerando o grande volume

de dados a serem processados em aplicações bidimensionais e a capacidade dos processadores, principalmente dos mais antigos.

1.4 Modelos da percepção visual humana, ferramentas de otimização e microeletrônica

Há três áreas das quais a restauração de imagens depende, no tocante à qualidade das imagens restauradas e exequibilidade de suas estratégias: a pesquisa sobre a percepção visual humana, o desenvolvimento de ferramentas de otimização e a microeletrônica.

A percepção visual humana tem sido objeto de investigação por parte de pesquisadores ligados à biologia, medicina, psicologia e até engenharia, estes últimos interessados em modelos matemáticos, a partir dos quais se possa aproximar, cada vez mais, o desempenho de suas aplicações às características do sistema visual humano [9], [10], [11], [15], [23], [32], [40], [55], [62], [63], [64], [71], [77], [78]. De especial relevância à restauração de imagens, são os estudos sobre o contraste. As medidas de contraste mais simples, como as de Michelson e Weber-Fechner [23], foram desenvolvidas a partir de padrões simples (pontos luminosos e sinais periódicos em fundo uniforme) e atribuem um único valor de contraste para toda a imagem sob análise. Medidas de contraste mais elaboradas foram desenvolvidas, visando avaliar o contraste em imagens complexas, o que não é feito pelas medidas mais simples anteriormente comentadas. Hess e Pointer [23] definiram uma medida de contraste no domínio da frequência, mas que não se mostrou capaz de descrever adequadamente as variações locais de contraste no domínio da seqüência. Posteriormente, Peli estabeleceu uma medida que é obtida da decomposição de uma imagem por um banco de filtros do tipo log-cosseno [62]. A medida de Peli avalia uma imagem de maneira que são associados a cada pixel valores de contraste em função da localização desse pixel e das frequências de sintonia dos filtros log-cosseno. Em [63], são realizadas comparações entre diversas medidas de contraste, mostrando que a medida de Peli com modificações (medida de Peli-Lubin com filtro de quadratura) é a mais representativa da percepção humana com relação ao contraste em imagens complexas. Destacam-se, também, os experimentos que avaliam os limiares de percepção do sistema visual humano ao contraste em função da frequência espacial angular. Desse tipo de experimento, são obtidas as funções de *sensibilidade ao contraste* (contrast sensibility function – *CSF*) e de *limiar de contraste*

(contrast threshold function – *CTF*), com as quais se pode modelar certas condições do ambiente de visualização (iluminação, distância entre observador e imagem, dimensões do dispositivo de visualização, etc.), bem como características específicas de um determinado observador [9] – [11].

A restauração de imagens, não raro, recai no problema da otimização de parâmetros de uma função, cuja complexidade é determinada pelo critério de qualidade subjacente usado pelo sistema de restauração. Sendo assim, as ferramentas para otimização têm papel fundamental, pois depende delas a capacidade de encontrar uma boa estimativa da imagem original. Simplicidade de implementação e baixa carga computacional têm sido os dois fatores mais amplamente usados na escolha de estratégias de otimização. Contudo, as abordagens que mais atendem aos referidos fatores possuem, geralmente, como principais desvantagens, a forte dependência do seu resultado final em função das condições iniciais e restrições severas quanto ao tipo de funções que podem ser otimizadas. Técnicas, como as baseadas no gradiente de uma função e a clássica Downhill Simplex Method (DHSM), são exemplos dessas abordagens [68]. Há, contudo, outras estratégias de baixa sensibilidade às condições iniciais e que não apresentam restrições em relação às características das funções a otimizar. A principal razão para que essas estratégias de baixa sensibilidade não sejam usadas mais freqüentemente está na elevada complexidade computacional, preço a pagar pela robustez que elas exibem. Nessa categoria, encontram-se estratégias como o *arrefecimento simulado* (simulated annealing – SA) [68], os *algoritmos genéticos* [31], [53] e a *programação evolucionária* [6], [7], [27], [28], [29], [30].

Os avanços na microeletrônica, por sua vez, têm sido fundamentais para o aprimoramento da restauração de imagens. A utilização de modelos do sistema e da percepção visuais humanos torna o sistema de restauração de imagens mais sofisticado, pois aproxima a aplicação do usuário, mas acarreta aumento considerável de carga computacional. Da mesma forma, a ferramenta de otimização deve ser adequada à função que se deseja otimizar. Se o critério de qualidade subjacente apresenta ótimos locais, o correto é optar pelas estratégias de otimização mais robustas, o que leva a mais aumento de complexidade computacional. Ou seja, quanto mais refinado o modelo, mais complexo o sistema. Com a redução cada vez maior da relação entre custo e poder de computação,

modelos e estratégias anteriormente de difícil implementação vêm se tornando cada vez mais factíveis.

1.5 Abordagens recentes em restauração de imagens

As abordagens recentes em restauração de imagens possuem, naturalmente, suas bases nas chamadas estratégias tradicionais, às quais são incorporados modelos da percepção humana, ferramentas de otimização mais robustas e possibilidades outras, como a adaptabilidade espacial, no sentido de atender necessidades verificadas em situações práticas.

Se nas estratégias tradicionais, a identificação do sistema de aquisição é uma etapa que antecede o procedimento de restauração, dentre as abordagens mais recentes há sistemas autodidatas nos quais a identificação é automática e concomitante à restauração propriamente dita [4], [5], [49], [50], [51].

Em resposta à crescente complexidade dos sistemas de restauração, a utilização de ferramentas de otimização robustas, ou seja, de baixa sensibilidade às condições iniciais, tem sido mais freqüente, a julgar pelo aumento do número artigos nas quais a restauração de imagens é usada em associação ao arrefecimento simulado [21], [33], [66], algoritmos genéticos [12], [19], [20], [34], [83] e programação evolucionária [79], [84], [85].

Os modelos do sistema visual humano, quando não estão implícitos no critério de qualidade que orienta os algoritmos de restauração, têm sido usados no desenvolvimento de medidas e metodologias para avaliar a qualidade de sistemas de restauração. Medidas como a *razão entre sinal e ruído ponderada* (weighted signal to noise ratio – *WSNR*), bem como a *medida de qualidade de ruído* (noise quality measure – *NQM*) e a *medida de distorção* (distortion measure – *DM*), têm sido usadas em lugar das medidas baseadas exclusivamente na energia dos sinais de interesse (ver Seção 1.3). A *WSNR* é definida de maneira semelhante à *SNR*, mas os sinais de interesse são ponderados pela *CSF* [23]. A *DM* e a *NQM* são propostas em [23] em conjunto com uma nova metodologia para avaliação da qualidade de sistemas de restauração, na qual os efeitos de distorção em freqüência são considerados de maneira isolada em relação à injeção de ruído. A *NQM* é baseada no contraste de Peli e apresenta desempenho superior ao *SNR*, *PSNR* e *WSNR* [23]. A *DM*, até então, não tinha sido objeto de investigação.

Um outro recurso apresentado por sistemas de restauração mais recentes é a capacidade de adaptação dos seus parâmetros (filtro de restauração de parâmetros variantes) quando as características das diferentes regiões de uma imagem assim o exigem. Essa etapa de adaptação é importante quando da restauração de cenas reais, pois as mesmas apresentam características não-estacionárias. Além disso, é comum, em situações práticas, que uma imagem apresente degradações variantes em função de diferentes planos de profundidade, não podendo ser restaurada convenientemente por um filtro invariante [5].

1.6 Filtro de Kalman em duas dimensões

As principais motivações para adaptar o filtro de Kalman ao processamento de imagens estão na sua capacidade de processar sinais não-estacionários (adaptabilidade), linearidade e recursividade. O filtro de Kalman é ainda ótimo, segundo o MSE e para a classe dos filtros lineares. Mesmo tratando-se de um procedimento recursivo, a complexidade computacional em aplicações bidimensionais mostrou-se bastante elevada, o que vem estimulando o desenvolvimento de aproximações, como o *filtro de Kalman por faixas* (strip Kalman – SK), o *filtro de Kalman de atualização reduzida* (reduced update Kalman filter – RUKF) e o *filtro de Kalman de modelo de ordem reduzida* (reduced order model Kalman filter – ROMKF) [4], [80].

As abordagens de restauração baseadas no filtro de Kalman têm incorporado modificações no sentido de apresentar recursos autodidatas, adaptação espacial e resultados mais condizentes com as características da percepção visual humana.

Em [4] e [5], o ROMKF é usado em conjunção com uma função baseada no critério de máxima verossimilhança para estimação de parâmetros. Não obstante a função usada possuir sabidamente múltiplos ótimos locais, um algoritmo de otimização sensível às condições iniciais é usado. Com o objetivo de contornar os problemas de convergência aos referidos ótimos locais, é sugerida uma estratégia na qual sucessivos reinícios do procedimento de restauração geram um conjunto de restaurações das quais a de melhor qualidade é selecionada como sendo a restauração final.

Em [70] e [75], são usadas máscaras para que o filtro de Kalman possa tratar de maneira diferenciada as regiões da imagem que está sendo processada, procurando melhorar a qualidade subjetiva da restauração. Uma estratégia semelhante é usada em [72], para

restauração de imagens médicas, na qual um pixel é classificado como sendo pertencente a uma borda, textura ou região plana. Para cada um dos tipos, estão associados diferentes valores de variância do ruído de observação. Apesar de procurarem melhorar a qualidade percebida das restaurações, nenhuma métrica baseada no sistema visual humano é usada na validação das técnicas apresentadas.

1.7 Contribuições desta tese

O presente trabalho apresenta duas contribuições relacionadas à avaliação de um sistema de restauração de imagens.

A primeira das contribuições defende a utilização de ferramentas robustas, de baixa sensibilidade às condições iniciais, para otimização em restauração de imagens. Algoritmos de otimização sensíveis às condições iniciais são comumente adotados na restauração, em razão da baixa complexidade computacional que apresentam, mesmo quando as funções a serem otimizadas sabidamente apresentam múltiplos ótimos locais [5], [51]. Nesse caso, são adotadas estratégias para tentar contornar a convergência a ótimos locais, como reiniciar várias vezes o processo de restauração com diferentes condições iniciais. Esse procedimento só se justifica se o custo computacional da implementação de um sistema de restauração com estratégias de baixa sensibilidade às condições iniciais for tão elevado que torne inviável tal implementação. Considerando, contudo, a capacidade e o custo dos processadores atuais, bem como o fato de que a restauração de imagens é quase sempre realizada *a posteriori*, em *off-line*, melhorar a qualidade dos sistemas parece ser um fator de maior relevância do que a redução do tempo de processamento da restauração. Nesse sentido, as simulações apresentadas no Capítulo 5 mostram que a utilização de algoritmos sensíveis às condições iniciais para otimizar funções de múltiplos ótimos locais não permite a avaliação adequada de um sistema de restauração, bem como atesta que a estratégia de múltiplos reinícios é inócua. Por outro lado, quando se empregam estratégias de otimização de baixa sensibilidade às condições iniciais, há aumento de complexidade computacional do sistema, mas o resultado obtido é representativo do melhor que o sistema de restauração consegue produzir. Dessa maneira, sabendo o quanto de melhoramento de qualidade um determinado sistema de restauração consegue, pode-se proceder a refinamentos e ajustes, quando for necessário e conveniente.

A segunda contribuição consiste na proposta de uma medida da qualidade de uma imagem, baseada em modelos da percepção visual humana e que segue uma metodologia de avaliação [23] na qual os efeitos de distorção em frequência e injeção de ruído devidos ao sistema de restauração são considerados isoladamente. Primeiramente, uma medida para avaliação de imagens degradadas apenas por distorção em frequência (*medida de qualidade de distorção – MQD*) é apresentada e validada experimentalmente. Em seguida, como uma imagem degradada apresenta tanto distorção em frequência quanto injeção de ruído, é proposta e validada experimentalmente uma medida para avaliação de qualidade em que é usada uma combinação da *NQM* [23] e da *MQD*, denominada *medida de qualidade composta (MQC)*. As medidas propostas (*MQD* e *MQC*) têm aplicação na avaliação e ajuste dos parâmetros de sistemas de restauração antes que o mesmo seja usado em uma situação prática, uma vez que requerem a disponibilidade da imagem original e uma versão da imagem degradada isenta de ruído, sinais que são indisponíveis em situações práticas.

1.8 Organização do manuscrito da tese

O presente texto encontra-se organizado conforme mostrado a seguir.

No Capítulo 2, é apresentada uma introdução à restauração de imagens. Primeiramente, a restauração é abordada dentro de um contexto histórico, no qual se enfatiza o impulso dado a essa área pela corrida espacial e a sua presença, decorrente dos contínuos avanços científicos e tecnológicos, em diversas aplicações nos dias atuais, como na medicina, fotografia comum, exploração de recursos naturais, codificação e transmissão digital, etc. Em seguida, são discutidos os modelos matemáticos que descrevem os sistemas de aquisição/degradação, síntese e restauração de imagens. Então, os principais desafios encontrados no procedimento de restauração de imagens, a amplificação do ruído da imagem degradada e sensibilidade da restauração em função dos parâmetros e do conhecimento sobre o sistema de aquisição, são brevemente estudados e discutidos.

O Capítulo 3 é dedicado à filtragem de Kalman em duas dimensões. São apresentadas as motivações que estimularam a adaptação do filtro de Kalman, originalmente unidimensional, para o processamento em duas dimensões. Em seguida, as equações que definem o filtro de Kalman, bem como suas principais características, são relacionadas. O

capítulo é encerrado abordando três aproximações do filtro de Kalman bidimensional, usadas para reduzir a carga computacional: o *filtro de Kalman por faixas* (strip Kalman-SK), o *filtro de Kalman de atualização reduzida* (reduced update Kalman filter – RUKF) e o *filtro de Kalman de modelo de ordem reduzida* (reduced order model Kalman filter – ROMKF). O ROMKF é especialmente enfatizado, sendo a estratégia usada nas simulações do Capítulo 5.

A computação evolucionária é o tema tratado no Capítulo 4. Inicialmente, são apresentadas as motivações, um pouco da história e das características dessa ferramenta de otimização. Depois, duas das principais estratégias em computação evolucionária são discutidas: os algoritmos genéticos e a programação evolucionária (PE). Essa última estratégia é usada nas simulações do Capítulo 5, como ferramenta para otimização, em conjunção com o ROMKF.

No Capítulo 5, é apresentada uma das contribuições desta tese. São feitas comparações entre dois conjuntos de restaurações via ROMKF. O primeiro conjunto usa, na etapa de estimação paramétrica do ROMKF, um algoritmo de alta sensibilidade às condições iniciais (DHSM) e o segundo conjunto usa um algoritmo de baixa sensibilidade às condições iniciais (PE). É verificado, assim, um desempenho superior do sistema sob estudo, em termos de regularidade dos resultados, quando se usa um algoritmo de baixa sensibilidade às condições iniciais.

O Capítulo 6 é dedicado à discussão das principais medidas usadas na avaliação da qualidade de uma imagem. São abordadas medidas tradicionais, como a *SNR*, *PSNR*, *BSNR* e *ISNR*; e também as medidas baseadas em modelos da percepção visual humana, tais como a *WSNR*, *DM* e *NQM*. Essas duas últimas são apresentadas no contexto de uma proposta recente de avaliação de sistemas de restauração. São ainda apresentados os resultados de experimentos, os quais objetivam verificar se a *DM* e a *NQM* realmente representam adequadamente a percepção humana. Face aos resultados obtidos, é proposta uma nova medida para avaliação da qualidade de imagens degradadas exclusivamente por distorção em frequência (*medida de qualidade de distorção – MQD*). Em seguida, é apresentada uma medida para avaliação da qualidade em imagens degradadas pelos efeitos combinados de distorção em frequência e injeção de ruído, denominada *medida de qualidade composta (MQC)*.

No Capítulo 7, são apresentadas simulações que reúnem em um mesmo sistema a restauração de imagens via ROMKF-PE e a *MQC*.

No Capítulo 8, são apresentadas as conclusões desta tese. Para tanto, os resultados dos Capítulos 5 e 6 são reavaliados de maneira a enfatizar sua correlação no contexto da restauração de imagens, também como suas contribuições e limitações. Na seção final, são apresentadas sugestões para futuros trabalhos referentes aos assuntos abordados nesta tese.

Ao final do texto, são relacionadas as referências bibliográficas.

2.1 Introdução

A restauração de imagens tem por objetivo recuperar a imagem original a partir de uma versão degradada ou versões degradadas da referida imagem. A área de restauração de imagens teve grande impulso graças à corrida espacial promovida pelas agências americana e soviética nos anos 50 e início dos anos 60 [3], [8], [56], [57]. Naquele período, as primeiras sondas espaciais começaram a enviar às estações terrestres imagens inéditas de corpos celestes e da própria Terra. Contudo, freqüentemente, essas imagens chegavam degradadas às estações terrestres devido a diversos fatores como turbulência atmosférica, rotação e deslocamento das sondas em relação ao objeto fotografado, desajustes no equipamento de aquisição e interferência eletromagnética no processo de transmissão. O elevado investimento de recursos e inestimável valor científico daquelas imagens determinaram a necessidade de que um processamento posterior recuperasse a qualidade perdida do material obtido. A literatura específica relata a importância e o sucesso obtido pelos pesquisadores na restauração daquelas primeiras imagens, a partir de adaptações das técnicas unidimensionais de processamento de sinais para o caso bidimensional [56].

Nos dias de hoje, após expressivo desenvolvimento teórico-tecnológico, a restauração de imagens encontra-se disseminada em diversas áreas [3], [8], tais como: fotografia convencional; exploração de recursos naturais; sistemas aeroespaciais, astronômicos [56] e médicos [52]; codificação e transmissão digital. A restauração de imagens é usada principalmente quando há impossibilidade de nova aquisição da imagem de interesse (por exemplo, fotos históricas e eventos naturais raros), quando o custo de nova aquisição é proibitivo (por exemplo, imagens espaciais obtidas com equipamento sofisticado [8][56]),

ou quando a introdução de degradações inaceitáveis é inerente às características do próprio sistema de aquisição (por exemplo, imagens radiográficas e de ultra-som [52]) [51].

Os sistemas de restauração de imagens são projetados a partir de um conjunto de conhecimentos que envolve álgebra linear, teoria de estimação, otimização numérica de funções e solução de problemas mal-condicionados. O mal-condicionamento significa que pequenos desvios nos parâmetros do sistema de restauração levam a grandes desvios na qualidade da imagem restaurada [3].

Neste capítulo, alguns tópicos são apresentados no sentido de proporcionar uma visão geral dos modelos associados aos sistemas de aquisição/degradação, síntese e restauração de imagens. Não obstante, as seções subseqüentes são organizadas de maneira a enfatizar aqueles aspectos mais explorados nesta tese. Material introdutório adicional sobre restauração de imagens é encontrado em [1], [13], [14], [17], [25], [37], [38], [39], [43], [44], [49], [50], [61], [65] e [67].

2.2 Modelos de aquisição/degradação e síntese de imagens

Considerar-se-á *imagem*, daqui em diante, como sendo a representação bidimensional de um determinado *objeto*, representação esta obtida através de um processo denominado *aquisição*. Os sistemas de aquisição, portanto, transferem informação do que se convencionou chamar *plano do objeto* para o *plano da imagem* (Fig. 2.1) [3].

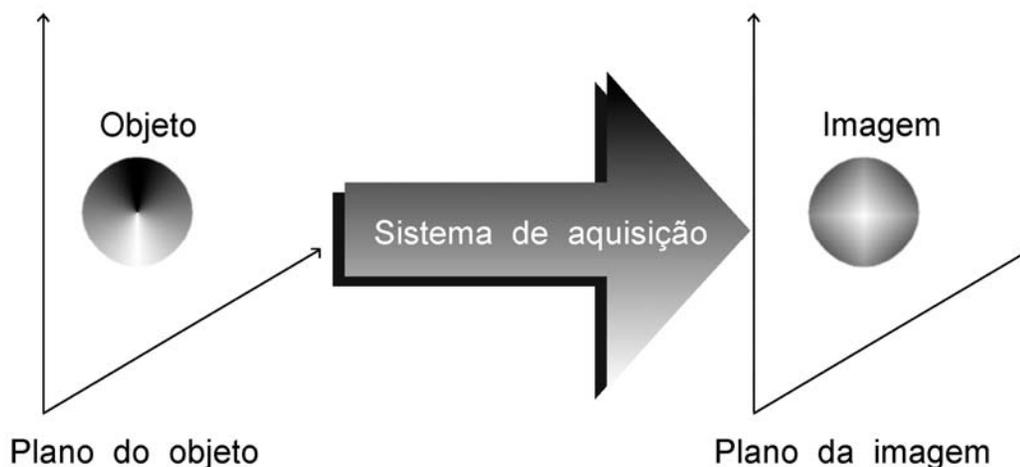


Fig. 2.1 – Aquisição de imagens.

A fim de esclarecer as idéias e os termos expostos no parágrafo anterior, tomar-se-á como exemplo a fotografia convencional. Neste caso, o *objeto* corresponde à cena que se deseja fotografar; o *sistema de aquisição* compreende a câmera fotográfica, o filme, o meio de propagação da luz, bem como os processos de sensibilização e revelação do filme; a *imagem* consiste na fotografia obtida.

Esta transferência entre os supracitados planos está representada pela expressão (2.1)

$$v(m,n) = T[x(k,l)], \quad (2.1)$$

onde (m,n) e (k,l) são as coordenadas do plano da imagem e do plano do objeto, respectivamente; $v(m,n)$ e $x(k,l)$ representam, respectivamente, a imagem adquirida e o objeto; $T[\cdot]$ indica o efeito de transferência entre os planos do objeto e da imagem.

Uma observação que se faz necessária é que o objeto e a imagem adquirida são originalmente definidos em coordenadas contínuas. Contudo, (m,n) e (k,l) são coordenadas discretas, subentendendo-se, assim, o procedimento de discretização necessário ao processamento digital.

Os sistemas de aquisição podem ser classificados quanto à [3]:

- a) *Linearidade*: o sistema de aquisição é dito (não) linear se a transferência (não) pode ser representada por uma função, cuja relação entre entrada e saída obedece ao *princípio da superposição* [58] expresso a seguir:

Princípio da superposição: sejam $x_1(k,l)$ e $x_2(k,l)$ as entradas, e $v_1(m,n)$ e $v_2(m,n)$ as respectivas saídas de um sistema de aquisição, caracterizado por $T[\cdot]$, como expresso em (2.2) e (2.3). O sistema $T[\cdot]$ obedece ao *princípio da superposição*, se, para uma entrada equivalente à soma ponderada das entradas $x_1(k,l)$ e $x_2(k,l)$, sempre se tem como saída a soma ponderada de $v_1(m,n)$ e $v_2(m,n)$, tal qual descrita em (2.4), onde k_1 e k_2 são constantes.

$$v_1(m,n) = T[x_1(k,l)] , \quad (2.2)$$

$$v_2(m,n) = T[x_2(k,l)] , \quad (2.3)$$

$$k_1 \cdot v_1(m,n) + k_2 \cdot v_2(m,n) = T[k_1 \cdot x_1(k,l) + k_2 \cdot x_2(k,l)] . \quad (2.4)$$

Quase todos os sistemas de aquisição são, a rigor, não-lineares. Contudo, aproximá-los por modelos lineares traduz-se em facilidade, uma vez que há à disposição um conjunto de ferramentas bastante eficiente para análise de tal classe de sistemas. A desvantagem nas linearizações está na exclusão ou inadequada representação de certas características dos sistemas de aquisição.

- b) *Variância espacial*: as características de transferência entre plano do objeto e plano da imagem podem variar ou não nas diferentes regiões da imagem. Quando as características (não) se modificam, o sistema é dito (in)variante.

Considerando o sistema de aquisição linear e discreto, (2.1) pode ser representado por (2.5) e (2.6), para os casos variante e invariante, respectivamente.

$$v(m,n) = \sum_{(k,l)} c(m,n,k,l)x(k,l) , \quad (2.5)$$

$$v(m,n) = \sum_{(k,l)} c(m-k,n-l)x(k,l) , \quad (2.6)$$

onde $c(m, n)$ é chamada de *função de espalhamento de ponto* (point spread function - PSF) e modela a transferência entre os planos objeto-imagem.

Em muitas imagens, as degradações verificadas são devidas ao próprio sistema de aquisição (degradação inerente ao sistema de aquisição). Um exemplo é o caso de sistemas médicos de raio-x, nos quais a nitidez da imagem radiográfica é diretamente proporcional à potência da radiação incidente no paciente. Como o risco à saúde daquele que se submete ao referido exame também é diretamente proporcional à potência da radiação incidente, esta deve ser ajustada para atender ao compromisso entre *risco à saúde* \times *qualidade da imagem*. Caso a integridade do paciente fosse desconsiderada, a qualidade da radiografia seria melhor do que realmente é, o que seria um contra-senso, considerando que a finalidade do procedimento em questão é, normalmente, a recuperação ou manutenção da saúde. Mesmo quando a degradação não é inerente ao processo de aquisição, a posterior degradação pode ser modelada em conjunto com a aquisição, como se aquisição e degradação fossem estágios de um único sistema. É nesse sentido que, muitas vezes neste trabalho, se emprega o termo *sistema de aquisição/degradação* ao invés de simplesmente *sistema de aquisição*, não obstante, quando do uso deste último, o efeito de eventual degradação esteja implícito.

Em [8], encontram-se modeladas algumas das PSFs mais comuns, dentre as quais:

a) *Deslocamento linear entre objeto e câmera*: degradação típica quando há movimento relativo, linear, entre objeto e equipamento de aquisição. Por exemplo, quando um trem em movimento é fotografado com obturador da máquina fotográfica ajustado em baixa velocidade. Visualmente, o efeito é equivalente a um borramento da imagem em uma única direção (a do movimento relativo). A expressão (2.7) apresenta o modelo para o caso de deslocamento linear horizontal.

$$c(n) = \begin{cases} \frac{1}{N}, & \text{se } -\frac{N}{2} \leq n \leq \frac{N}{2} \\ 0, & \text{outro caso} \end{cases} \quad (2.7)$$

onde N é uma constante que representa o valor do deslocamento, em pixels, entre objeto e câmera.

b) *Má focalização*: a má focalização ocorre quando o objeto de interesse, cuja imagem se deseja, encontra-se posicionado, em relação ao equipamento de aquisição, a uma distância diferente da distância focal do referido equipamento. O efeito visual é o de um borramento uniforme em todas as direções (borramento circular). A expressão (2.8) modela esse tipo de degradação.

$$c(m, n) = \begin{cases} \frac{1}{\pi r^2}, & \text{se } (m^2 + n^2) \leq r^2 \\ 0, & \text{outro caso} \end{cases} \quad (2.8)$$

onde r indica o raio da degradação.

c) *Degradação bidimensional uniforme*: neste tipo de degradação, a energia referente a um único ponto do que seria a imagem original é distribuída em um conjunto de pontos de área retangular. É o equivalente bidimensional ao filtro unidimensional de resposta ao impulso igual ao pulso retangular. O efeito visual dessa degradação assemelha-se ao efeito da má focalização. Na expressão (2.9), é apresentado o modelo da degradação bidimensional uniforme.

$$c(m, n) = \begin{cases} \frac{1}{MN}, & \text{se } -\frac{M}{2} \leq m \leq \frac{M}{2} \text{ e } -\frac{N}{2} \leq n \leq \frac{N}{2} \\ 0, & \text{outro caso} \end{cases} \quad (2.9)$$

onde M e N são constantes que indicam a extensão da degradação nas direções vertical e horizontal, respectivamente.

d) *Turbulência atmosférica*: este é um fenômeno observado comumente na aquisição de imagens aeroespaciais, decorrente da variação contínua do índice de refração da atmosfera situada entre o objeto de interesse e o equipamento de aquisição. A turbulência atmosférica apresenta características complexas como aleatoriedade e variâncias espacial e temporal. No entanto, ajustando-se adequadamente a velocidade de aquisição, a turbulência atmosférica é modelada, considerando o teorema do limite central [60], como sendo Gaussiana [37] (2.10). Visualmente, o efeito dessa degradação também se assemelha à má focalização.

$$c(m, n) = K \exp\left(-\frac{m^2 + n^2}{2\sigma^2}\right), \quad (2.10)$$

onde K é uma constante de normalização e σ , o desvio padrão, indicando a severidade da degradação.

Um comentário pertinente neste ponto do texto diz respeito ao limite imposto pelos modelos, ou pelas PSFs reais, no quanto de qualidade da imagem original se pode recuperar através do processo de restauração. Um exemplo dessa limitação está no fato de que, à exceção da turbulência atmosférica, as PSFs apresentadas possuem zeros no domínio da frequência. Portanto, nas frequências de ocorrência desses zeros, há perda completa de informação (módulo e fase) da imagem original, exigindo que se use artifícios, como considerações a respeito do comportamento da imagem original no domínio da frequência, a fim de estimar a referida informação perdida [37].

Por outro lado, as características das PSFs também podem ser aproveitadas na identificação do tipo e do valor dos parâmetros da degradação apresentada por determinada imagem, em situações nas quais essas informações não são conhecidas *a priori*. Dessa forma, os mesmos zeros que inviabilizam a restauração perfeita da imagem original fornecem um padrão a partir do qual é possível identificar o tipo e os parâmetros para as degradações (a), (b) e (c) supracitadas [3]. Outras suposições acerca das características dos sistemas de aquisição também são usadas na estimação e identificação do modelo de degradação. Por exemplo, a consideração de invariância e linearidade é usada na identificação via filtragem homomórfica [14][58] e técnicas que avaliam os pixels em regiões onde se julga haver originalmente bordas ou pontos [3].

Além da PSF, os sistemas de aquisição introduzem perturbações estocásticas (ruído) na imagem gerada. As fontes de ruído variam de acordo com os processos físicos usados para aquisição. Por exemplo, em sistemas de fotografia convencional (sistema fotoquímico), o ruído se deve ao comportamento não determinístico da deposição dos grânulos de prata em filmes fotográficos durante os processos de exposição e revelação; em câmeras digitais (sistema fotoeletrônico), deve-se à atividade luminosa e eletrônica na superfície do detetor [3]. O ruído pode ser modelado, genericamente, como sendo de dois tipos:

- a) *Aditivo*: modelo usado normalmente quando o ruído mostra-se não correlacionado ao sinal de imagem, podendo, contudo, prestar-se também à descrição de ruídos correlacionados. O sistema de aquisição passa, então, a ser expresso como:

$$v(m, n) = T[x(k, l)] + \eta(m, n), \quad (2.11)$$

onde $\eta(m, n)$ denota o ruído aditivo.

- b) *Multiplicativo*: a perturbação é necessariamente considerada como sendo correlacionada ao sinal de imagem, passando o sistema de aquisição a ser representado por:

$$v(m, n) = T[x(k, l)] \cdot \exp[k \cdot \eta(m, n)], \quad (2.12)$$

onde k é uma constante, $\eta(m, n)$ é normalmente assumido como sendo ruído branco Gaussiano e $\exp[k \cdot \eta(m, n)]$ denota, então, o ruído multiplicativo.

A rigor, os sistemas de aquisição são geralmente variantes e não-lineares, apresentando também ruído correlacionado ao sinal de imagem. São admitidas simplificações que, no entanto, acarretam imprecisões de modelagem, sempre que não há relevante comprometimento na descrição do comportamento do sistema de aquisição sob análise ou, dito de outra forma, quando a modelagem precisa e detalhada não resulta em ganho substancial na qualidade de representação do sistema de aquisição [3]. Logo, dependendo do caso, sistemas de fato complexos são modelados usando linearização e suposição de invariância de seus parâmetros, bem como consideração de não-correlação entre ruído e sinal de imagem.

No entanto, nem sempre é possível que as simplificações citadas sejam feitas, por exemplo, quando os objetos que compõem certas cenas fotografadas estão em diferentes profundidades e conseqüentemente apresentam diferentes níveis de degradação. Nesses casos, tais profundidades estão associadas a diferentes PSFs. Nesta tese, por motivos que ficarão claros no Capítulo 5, os sistemas de aquisição são considerados lineares, variantes e com adição de ruído do tipo branco Gaussiano à sua saída (2.13):

$$v(m, n) = \sum_{(k, l)} c(m, n, k, l) x(m - k, n - l) + \eta(m, n). \quad (2.13)$$

Em muitas situações, convém expressar a imagem original como saída de um filtro auto-regressivo (AR), cuja entrada consiste em um sinal do tipo ruído branco Gaussiano (2.14) [39]:

$$x(m, n) = \sum_{(k,l)} a(m, n, k, l)x(m - k, n - l) + \xi(m, n), \quad (2.14)$$

onde $a(m, n, k, l)$ e $\xi(m, n)$ representam, respectivamente, os coeficientes e o ruído de entrada do filtro AR. A expressão (2.14) é também conhecida por *síntese de uma imagem*.

Em (2.14), os coeficientes do filtro AR estão na sua forma mais geral, podendo assim representar filtros AR variantes ou invariantes no espaço. Os coeficientes $a(m, n, k, l)$ podem também ser interpretados como sendo os parâmetros de um estimador de $x(m, n)$ e o ruído $\xi(m, n)$ como o erro de estimação a ele associado. Em outras palavras, $a(m, n, k, l)$ são medidas da correlação entre a amostra $x(m, n)$ e suas amostras vizinhas.

2.3 Sistemas de restauração de imagens

Os sistemas de restauração de imagens são concebidos com o intuito de recuperar, “idealmente”, a *qualidade original* de imagens que apresentam *degradações inaceitáveis*. Dois termos do período anterior necessitam de maior esclarecimento: *qualidade original* e *degradações inaceitáveis*.

Por *qualidade original* quer-se referir à qualidade que a imagem teria se o processo de aquisição fosse, no limite, isento de degradações. Já o termo *degradações inaceitáveis* é empregado porque não há aquisição perfeita [3], [13], [14], [37]. Ou seja, em sistemas reais, há sempre alguma degradação na aquisição de imagens. Certas aquisições requerem restauração e outras não, dependendo do tipo, do nível da degradação e da aplicação pretendida.

O fato de não haver aquisição perfeita, estabelece que, via de regra, *imagem original* e *qualidade original* só existem em sentido abstrato, matemático, salvo em casos especiais como, por exemplo, nas simulações deste trabalho. No entanto, mesmo nos referidos casos especiais, em que a imagem original encontra-se disponível e é usada como referência para avaliações de qualidade da restauração, todo o processo de estimação da *imagem* ou da *qualidade original* está associado aos modelos adotados e não aos elementos reais.

Portanto, *imagem* e *qualidade originais* devem ser entendidas como *imagem* e *qualidade originais* no sentido dos modelos matemáticos usados na caracterização do sistema de aquisição.

Os sistemas de restauração, a exemplo dos sistemas de aquisição/degradação, podem ser classificados de diversas maneiras [43]. As classificações mais relevantes para este trabalho são quanto à:

- a) *Linearidade*: os sistemas de restauração cuja entrada e saída (não) obedecem ao princípio da superposição são ditos (não) lineares. A semelhança do que foi comentado na Seção 2.2, os sistemas de restauração lineares são mais fáceis de analisar e projetar, mas trazem como desvantagem limitações nas possibilidades de restauração.
- b) *Variância espacial*: se os parâmetros do sistema de restauração (não) se modificam quando se processam diferentes regiões de uma imagem, diz-se que o referido sistema é (in)variante. Os sistemas de restauração variantes são necessários para restaurar imagens obtidas por sistemas de aquisição variantes e/ou para tratar adequadamente as eventuais características não estacionárias de uma imagem, mesmo que esta tenha sido adquirida por um sistema invariante [5], [70]. Sistemas para restauração a parâmetros variantes são matematicamente mais complexos, contudo conferem maior flexibilidade ao processo de restauração, resultando, quando corretamente usados, em restaurações de melhor qualidade do que aquelas obtidas por sistemas invariantes.
- c) *Recursividade*: os sistemas recursivos são aqueles que usam o resultado da iteração anterior para o cálculo da iteração corrente, com o objetivo de reduzir carga computacional [2].
- d) *Autodidatismo*: as abordagens tradicionais para restauração de imagens consideram que o sistema de aquisição/degradação foi perfeitamente modelado e identificado, e que certas características da imagem original são conhecidas *a priori* [3]. Mas,

freqüentemente, em situações práticas, essas informações estão indisponíveis ou são parcialmente conhecidas *a priori*, sendo, portanto, necessária uma etapa de estimação que pode ser anterior ou concomitante ao procedimento de restauração propriamente dito [49]. Quando cabe ao sistema de restauração a tarefa de estimar informações (do sistema de aquisição/degradação e/ou da imagem original) a fim de ajustar os seus próprios parâmetros, diz-se que o referido sistema de restauração é autoidadada. Entretanto, os níveis de autoidadatismo variam de acordo com o quanto de conhecimento acerca do sistema de aquisição/degradação e/ou imagem original se dispõe. A inserção de recursos autoidadados em sistemas de restauração torna-os mais flexíveis, mas também acarreta um aumento de complexidade computacional.

- e) *Comportamento estocástico/determinístico*: dependendo da formulação do sistema de restauração, a imagem restaurada pode ser obtida segundo métodos determinísticos ou de estimação estatística [43]. Os sistemas determinísticos são, em geral, mais rápidos do que os estocásticos. No entanto, esses últimos são mais robustos, prestando-se à restauração de um conjunto mais amplo de imagens.
- f) *Domínio de definição*: O procedimento de restauração pode ser definido no domínio da seqüência e/ou da freqüência. As técnicas definidas no domínio da seqüência possuem a vantagem de prescindir das etapas de transformação e transformação inversa inerente às técnicas baseadas no domínio da freqüência, além de serem mais adequadas à restauração variante.

2.4 Principais desafios na restauração de imagens

Em se tratando de sistemas lineares, uma primeira idéia de como se proceder à restauração de uma imagem é a técnica denominada de filtragem inversa, que consiste simplesmente em multiplicar, no domínio da freqüência, a imagem degradada pelo inverso da resposta ao impulso do filtro de degradação, como expresso em (2.15).

$$\hat{X}(\omega_1, \omega_2) = \frac{V(\omega_1, \omega_2)}{C(\omega_1, \omega_2)} = C^{-1}(\omega_1, \omega_2)V(\omega_1, \omega_2), \quad (2.15)$$

onde $\hat{X}(\omega_1, \omega_2)$, $V(\omega_1, \omega_2)$ e $C(\omega_1, \omega_2)$ denotam, respectivamente, as respostas em frequência da imagem restaurada (estimativa da imagem original), imagem degradada e resposta ao impulso do filtro de degradação.

Os principais desafios da restauração de imagens podem ser evidenciados ao se estudar as características do procedimento de restauração por filtragem inversa. Essas características são brevemente discutidas a seguir.

A aplicação direta do filtro inverso traz alguns problemas, requerendo que (2.15) seja modificada segundo (2.16).

$$\hat{X}(\omega_1, \omega_2) = \hat{C}^{-1}(\omega_1, \omega_2)V(\omega_1, \omega_2), \quad (2.16)$$

onde $\hat{C}^{-1}(\omega_1, \omega_2)$ é uma aproximação de $C^{-1}(\omega_1, \omega_2)$.

Um dos referidos problemas ocorre quando $C(\omega_1, \omega_2)$ apresenta zeros (ver Seção 2.2). Nesse caso, em alguns pontos, o filtro inverso tende ao infinito, não sendo possível representá-lo convenientemente em situações práticas. Uma maneira de contornar a dificuldade em questão é definir $\hat{C}^{-1}(\omega_1, \omega_2)$ como segue:

$$\hat{C}^{-1}(\omega_1, \omega_2) = \begin{cases} C^{-1}(\omega_1, \omega_2), & C(\omega_1, \omega_2) \neq 0 \\ 0, & C(\omega_1, \omega_2) = 0 \end{cases} \quad (2.17)$$

Atribuir valor nulo para $\hat{C}^{-1}(\omega_1, \omega_2)$, quando $C(\omega_1, \omega_2) = 0$, em nada modifica o valor de $\hat{X}(\omega_1, \omega_2)$ em relação ao valor calculado em (2.15), desde que:

- a) a imagem degradada esteja isenta de ruído;
- b) $C(\omega_1, \omega_2)$ tenha sido corretamente identificada.

A não modificação do valor de $\hat{X}(\omega_1, \omega_2)$ decorre do fato de que, nos pontos nos quais $C(\omega_1, \omega_2) = 0$, há perda completa de informação.

Os itens (a) e (b) do parágrafo anterior são exigências necessárias não apenas para o caso de degradações que apresentem zeros no domínio da frequência, mas sempre que a técnica de filtragem inversa é empregada, sob pena de se produzir restaurações de baixa qualidade.

Por exemplo, a presença de ruído, mesmo em níveis considerados pequenos, na imagem degradada faz com que a restauração produzida por filtragem inversa apresente uma razão sinal-ruído (signal to noise ratio – SNR)¹ ruim como mostra a Fig. 2.2. Isso ocorre porque, justamente nas regiões onde a energia da imagem é menor do que ou mesmo comparável à energia do ruído (zeros do filtro de degradação e alta frequência), o ganho do filtro de restauração é elevado. Uma maneira de lidar, na filtragem inversa, com a amplificação de ruído de alta frequência é definir $\hat{C}^{-1}(\omega_1, \omega_2)$ como apresentado em (2.18).

$$\hat{C}^{-1}(\omega_1, \omega_2) = \begin{cases} C^{-1}(\omega_1, \omega_2), & \omega_1^2 + \omega_2^2 \leq \Omega^2 \\ K, & \omega_1^2 + \omega_2^2 > \Omega^2 \end{cases} \quad (2.18)$$

onde Ω e K são, respectivamente, o limite no espaço de frequências, dentro do qual o filtro inverso não é alterado, e o valor assumido pelo filtro de restauração fora do referido limite.

O valor de Ω é escolhido de maneira que a energia da imagem original na região exterior ao limite estabelecido por esse parâmetro seja não significativa. Quanto ao valor de K , é comum fazê-lo igual à unidade ($K = 1$), a fim de não modificar a SNR da região externa ao limite estabelecido por Ω . A Fig. 2.3 ilustra as idéias apresentadas em (2.17) e (2.18).

Em (2.19), pode ser observado que, mesmo se $C(\omega_1, \omega_2)$ for corretamente identificada, não é possível recuperar $X(\omega_1, \omega_2)$ se houver ruído presente na imagem degradada.

$$\begin{aligned} \hat{X}(\omega_1, \omega_2) &= C^{-1}(\omega_1, \omega_2)V(\omega_1, \omega_2) \\ &= C^{-1}(\omega_1, \omega_2)[C(\omega_1, \omega_2)X(\omega_1, \omega_2) + H(\omega_1, \omega_2)] \\ &= C^{-1}(\omega_1, \omega_2)C(\omega_1, \omega_2)X(\omega_1, \omega_2) + C^{-1}(\omega_1, \omega_2)H(\omega_1, \omega_2) \\ &= X(\omega_1, \omega_2) + C^{-1}(\omega_1, \omega_2)H(\omega_1, \omega_2) \end{aligned} \quad (2.19)$$

onde $H(\omega_1, \omega_2)$ é a resposta em frequência do ruído aditivo presente na imagem degradada.

Quanto aos erros de identificação de $C(\omega_1, \omega_2)$, a Fig. 2.2 mostra como a filtragem inversa apresenta-se bastante sensível a este aspecto.

¹ Maiores detalhes no Capítulo 6 (Seção 6.2.1)

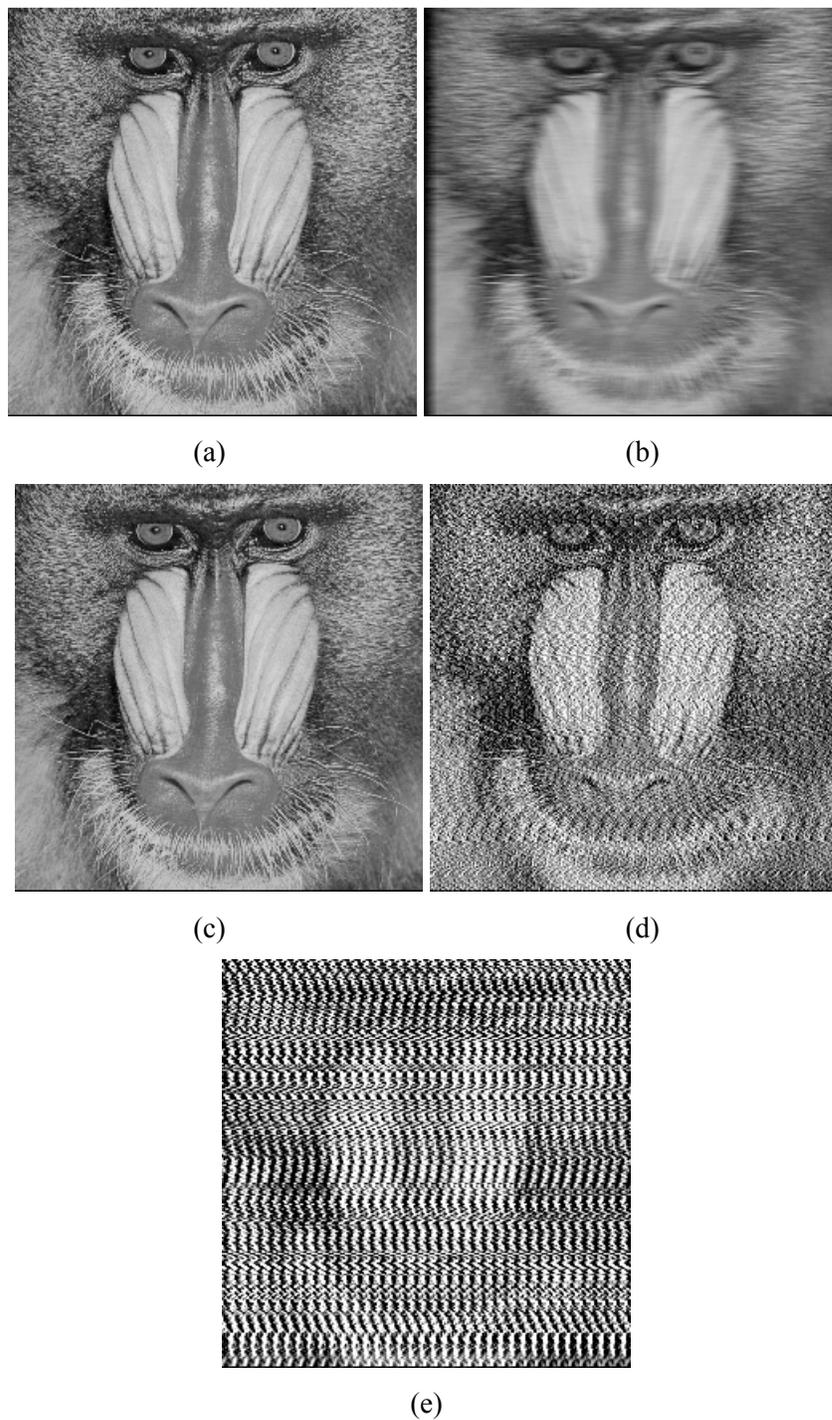
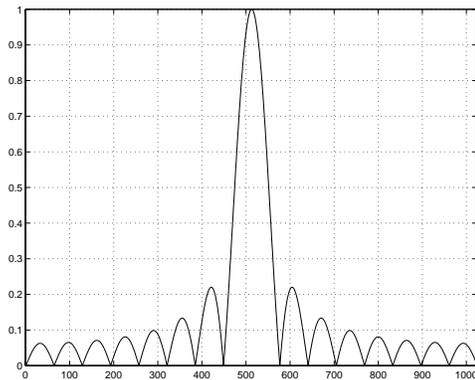
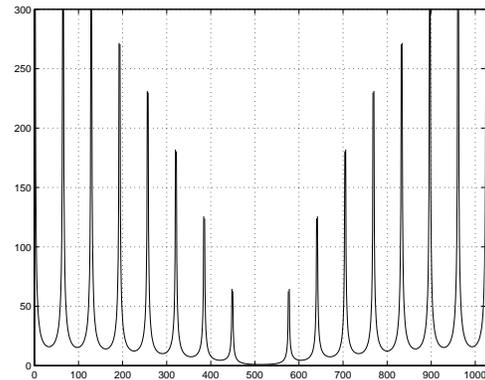


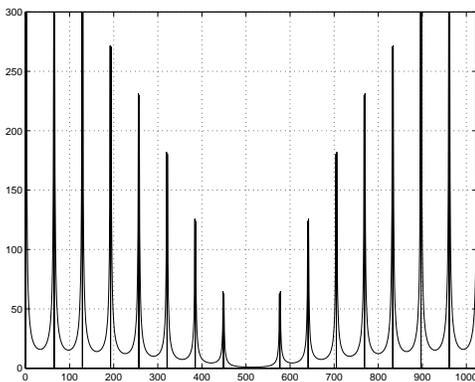
Fig. 2.2 – Restauração via filtragem inversa: (a) imagem original; (b) imagem degradada por movimento horizontal (de comprimento de 9 pixels); (c) restauração em condições ideais (sem ruído e degradação perfeitamente identificada); (d) restauração a partir de imagem degradada com ruído e degradação perfeitamente identificada (imagem degradada: SNR = 40 dB ; restauração: SNR = 7 dB); (e) restauração a partir de imagem degradada isenta de ruído e degradação incorretamente identificada (movimento horizontal, de comprimento de 7 pixels).



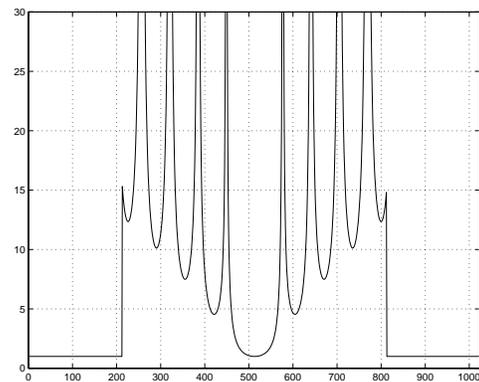
(a)



(b)



(c)



(d)

Fig. 2.3 – Filtragem inversa: (a) módulo da resposta em frequência do filtro de degradação; (b) módulo da resposta em frequência do filtro inverso; (c) módulo da resposta em frequência do filtro inverso modificado, segundo (2.17); (d) módulo da resposta em frequência do filtro inverso modificado, segundo (2.18) ($K = 1$ e $\Omega = 300$ amostras).

Pelas razões e exemplos apresentados, além das constatações de que sempre há ruído na imagem degradada e o procedimento de identificação de $C(\omega_1, \omega_2)$ não é exato, a restauração de imagens por filtragem inversa não é usada em situações práticas.

Outras técnicas de restauração são mais adequadas para restauração de imagens com ruído. Dentre essas técnicas, destaca-se, pela sua importância histórica e teórica, a restauração usando filtro de Wiener [38]. Esse filtro é ótimo no sentido de minimizar o erro

quadrático médio (mean square error – MSE), definido em (2.20). Em (2.21), é apresentada a expressão usada para calcular a estimativa da imagem original, usando filtro de Wiener.

$$E\{[x(m,n) - \hat{x}(m,n)]^2\} \quad (2.20)$$

onde $E\{\cdot\}$ e $\hat{x}(m,n)$ denotam o operador de valor esperado e a imagem restaurada, respectivamente.

$$\hat{X}(\omega_1, \omega_2) = \frac{\Phi_{xx}(\omega_1, \omega_2)C^*(\omega_1, \omega_2)}{\Phi_{xx}(\omega_1, \omega_2)|C(\omega_1, \omega_2)|^2 + \Phi_{\eta\eta}(\omega_1, \omega_2)} V(\omega_1, \omega_2) \quad (2.21)$$

onde $C^*(\omega_1, \omega_2)$, $\Phi_{xx}(\omega_1, \omega_2)$ e $\Phi_{\eta\eta}(\omega_1, \omega_2)$ denotam, respectivamente, o conjugado de $C(\omega_1, \omega_2)$, o espectro de potência da imagem original e do ruído de degradação.

Pode-se verificar em (2.21) que o filtro de Wiener necessita que $C(\omega_1, \omega_2)$ e as estatísticas de segunda ordem de $x(m,n)$ e $\eta(m,n)$ sejam conhecidas, as quais são estimadas, na maioria dos casos práticos, a partir da imagem degradada. Duas outras interessantes características do filtro de Wiener são:

- a) o referido filtro tende ao filtro inverso, à medida que o ruído presente na imagem degradada diminui;
- b) um mesmo filtro pode ser usado para restaurar não apenas uma imagem específica, mas uma classe de imagens, desde que degradadas pelo mesmo sistema e possuam espectro de potência semelhantes.

A Fig. 2.4 ilustra o desempenho superior do filtro de Wiener, em comparação ao filtro inverso no tocante à amplificação do ruído presente na imagem degradada.

Contudo, face às características do sistema visual humano, o MSE não é o critério mais adequado para medir a qualidade de uma imagem. Por isso, outras estratégias de restauração procuram minimizar um critério de desempenho que pode ser denominado MSE com restrições [8], como apresentada em (2.22).

$$E\{[x(m,n) - \hat{x}(m,n)]^2 + \alpha \cdot [h(m,n) * \hat{x}(m,n)]^2\} \quad (2.22)$$

onde α é uma constante de ponderação e $h(m,n)$ é a resposta ao impulso de um filtro que tem por objetivo realçar certas características de $\hat{x}(m,n)$. O símbolo $*$ denota a operação de convolução em duas dimensões. Em geral, $h(m,n)$ representa a resposta ao impulso de

um filtro passa-altas, de modo que seja possível um balanço entre MSE e componentes de alta frequência de $\hat{x}(m, n)$.

As abordagens até agora comentadas possuem em comum as características de linearidade e somente tratar processos estacionários. Essa última, em particular, acarreta dificuldades quando se necessita de parâmetros variantes no sistema de restauração (ver Seção 2.3(b)). No entanto, essa dificuldade pode ser contornada, se forem usadas estratégias baseadas no filtro de Kalman [41], pois é de sua formulação original a possibilidade de adaptação amostra a amostra dos parâmetros do sistema de restauração.

Apesar de minimizar o MSE, assim como o filtro de Wiener, o filtro de Kalman mostra-se mais flexível para incorporar modificações em sua estrutura que o tornem mais adequado ao sistema visual humano, podendo ser inclusive aplicado em sistemas modelados como não-lineares [22], [70]. Há, ainda, outro aspecto do filtro de Kalman que o difere do filtro de Wiener: o filtro de Kalman é recursivo.

Pelas suas características, foram usados filtros bidimensionais de Kalman na obtenção das restaurações desta tese. Uma introdução à filtragem bidimensional de Kalman é apresentada no Capítulo 3, bem como os detalhes sobre o sistema de restauração utilizado.

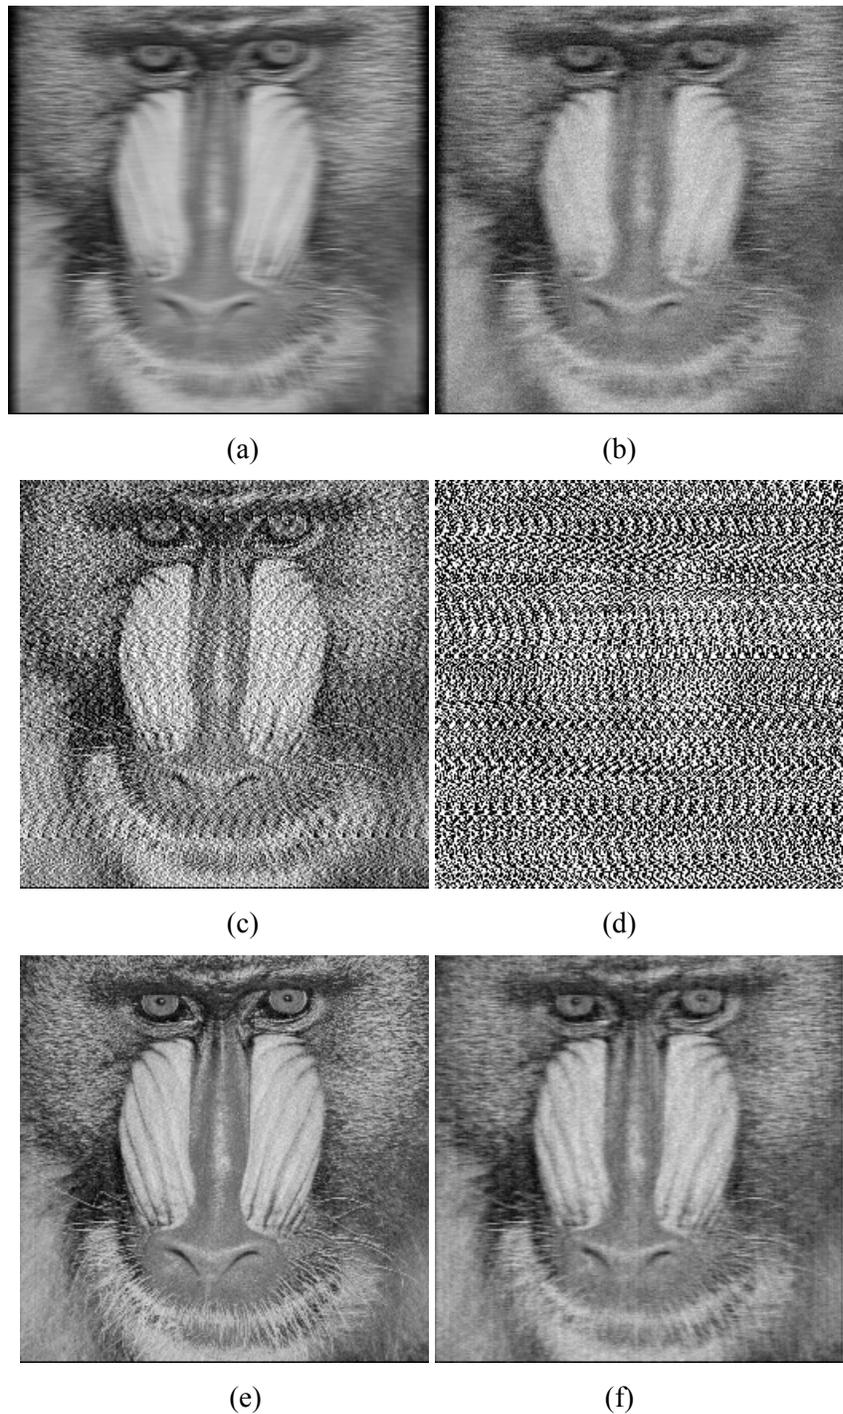


Fig. 2.4 – Comparação de resultados entre filtro inverso e filtro de Wiener: (a) imagem degradada (SNR = 40 dB); (b) imagem degradada (SNR = 22 dB); (c) restauração de (a) usando filtro inverso (SNR = 7 dB); (d) restauração de (b) usando filtro inverso (SNR = -10 dB); (e) restauração de (a) usando filtro de Wiener (SNR = 23 dB); (f) restauração de (b) usando filtro de Wiener (SNR = 17 dB).

2.5 Conclusões

Este capítulo apresenta uma introdução à restauração de imagens. Primeiramente, um pouco da história da restauração é relatada, cujo início remonta ao período da corrida espacial americana e soviética nos anos 50 e 60. Visando, inicialmente, ao melhoramento da qualidade de imagens provindas das sondas espaciais, a restauração de imagens está presente, nos dias de hoje, em um grande número de aplicações, tais como: astronomia, exploração de recursos naturais, fotografia convencional, sistemas médicos e aeroespaciais. Essa ampliação nas áreas em que a restauração é aplicada deve-se aos avanços científicos e tecnológicos relacionados, principalmente, à microeletrônica e à pesquisa em processamento de sinais. Esses dois fatores permitiram o desenvolvimento de métodos para restauração ao mesmo tempo poderosos e de custo relativamente baixo.

Após o breve apanhado histórico, o texto concentra-se em certos aspectos teóricos que estruturam os sistemas de restauração: os modelos matemáticos usados e suas características. Inicia-se abordando a questão do modelo matemático que descreve o sistema de aquisição/degradação de imagens. Esse sistema é considerado como sendo o responsável pelo mapeamento entre os planos objeto-imagem, resultando na representação em duas dimensões (imagem) de um determinado objeto. Passível de ser classificado segundo vários critérios, o sistema de aquisição/degradação considerado nesta tese possui as seguintes características: linear, variante e com adição de ruído branco Gaussiano à sua saída. São ainda apresentados e comentados os modelos matemáticos das PSFs mais comuns.

Em seguida, são apresentados alguns aspectos atinentes ao modelo dos sistemas de restauração. Possíveis classificações são abordadas e comentadas.

E, por fim, são discutidos os principais desafios na restauração de imagens através de exemplos usando filtragem inversa e de Wiener. Dentre os referidos desafios, encontram-se a identificação de certos parâmetros do sistema de aquisição e da imagem original, bem como as limitações na qualidade da restauração em função do tipo de PSF e da injeção de ruído na imagem degradada. Comenta-se, ainda, que face às características do filtro de Kalman, optou-se por utilizar estratégias de restauração nele baseadas. O filtro bidimensional de Kalman é abordado com detalhes no Capítulo 3.

3.1 Introdução

Este capítulo trata do filtro de Kalman em duas dimensões e de suas características no contexto da chamada *filtragem ótima*. Primeiramente, o filtro de Kalman original [41], unidimensional (1-D), é abordado. São apresentadas, de maneira sucinta, suas principais características e as equações que o compõe.

Em seguida, são discutidas as razões e os meios pelos quais o filtro de Kalman original é estendido para aplicações bidimensionais (2-D), em particular para a restauração de imagens.

O capítulo prossegue abordando o problema da carga computacional e do elevado volume de memória necessário na implementação do filtro 2-D de Kalman. Devido a esses dois fatores, diversos autores propõem aproximações ao filtro 2-D de Kalman, as quais, se por um lado, oferecem redução de complexidade computacional e memória, por outro, resultam em desvios da solução ótima obtida pelo filtro de Kalman. Três das aproximações mais usadas e suas respectivas características são apresentadas e comentadas.

3.2 Filtragem de Kalman unidimensional

O filtro de Kalman considera que o sistema sobre o qual a operação de filtragem irá atuar pode ser modelado pelas seguintes expressões:

$$\mathbf{x}_{k+1} = \mathbf{A}_k \mathbf{x}_k + \mathbf{\Gamma}_k \xi_k, \quad (3.1)$$

$$\mathbf{v}_k = \mathbf{C}_k \mathbf{x}_k + \boldsymbol{\eta}_k, \quad (3.2)$$

onde \mathbf{x}_k , \mathbf{A}_k , $\mathbf{\Gamma}_k$, ξ_k , \mathbf{v}_k , \mathbf{C}_k e $\boldsymbol{\eta}_k$ são conhecidos, respectivamente, como vetor de estado, matriz de transição de estado, matriz de ponderação do ruído de entrada, ruído de

entrada, sinal observado, matriz de observação e ruído de saída ou observação. As matrizes \mathbf{A}_k , $\mathbf{\Gamma}_k$ e \mathbf{C}_k , assim como as estatísticas de segunda ordem de ξ_k e η_k são consideradas conhecidas; o sinal observado \mathbf{v}_k é disponível e o vetor de estado \mathbf{x}_k , desconhecido. Os ruídos ξ_k e η_k são considerados do tipo branco Gaussiano, de média zero, sendo válidas, portanto, as seguintes expressões:

$$E[\xi_k \xi_l^T] = \delta_{kl} \mathbf{Q}_k, \quad (3.3)$$

$$E[\eta_k \eta_l^T] = \delta_{kl} \mathbf{R}_k, \quad (3.4)$$

$$E[\eta_k \xi_l^T] = 0, \quad \forall (k, l), \quad (3.5)$$

onde $E[\cdot]$ é o operador de valor esperado (ou expectância) de uma variável aleatória; T indica a operação de transposição de um vetor; \mathbf{R}_k e \mathbf{Q}_k representam as matrizes de covariância dos vetores ξ_k e η_k , respectivamente; δ_{kl} é o operador de Kronecker, definido por:

$$\delta_{kl} = \begin{cases} 0 & k \neq l \\ 1 & k = l \end{cases} \quad (3.6)$$

O filtro de Kalman estima o vetor de estado referente à amostra k , considerando as observações desde a amostra 0 até k . A estimativa obtida pelo filtro de Kalman é tal que o valor esperado do módulo do erro de estimação ao quadrado (3.7) seja minimizado.

$$E[(\mathbf{x}_k - \hat{\mathbf{x}}_k)^T (\mathbf{x}_k - \hat{\mathbf{x}}_k) | V_k] \quad (3.7)$$

onde $\hat{\mathbf{x}}_k$ é uma estimativa do vetor de estado \mathbf{x}_k e V_k é o conjunto de todas as amostras observadas desde 0 até k , ou seja, $V_k = \{\mathbf{v}_0, \mathbf{v}_1, \dots, \mathbf{v}_k\}$.

As equações que sintetizam o filtro de Kalman são relacionadas a seguir:

$$\mathbf{P}_{0,0} = \text{Var}[\mathbf{x}_0], \quad (3.8)$$

$$\mathbf{P}_{k,k-1} = \mathbf{A}_{k-1} \mathbf{P}_{k-1,k-1} \mathbf{A}_{k-1}^T + \mathbf{\Gamma}_{k-1} \mathbf{Q}_{k-1} \mathbf{\Gamma}_{k-1}^T, \quad (3.9)$$

$$\mathbf{G}_k = \mathbf{P}_{k,k-1} \mathbf{C}_k^T (\mathbf{C}_k \mathbf{P}_{k,k-1} \mathbf{C}_k^T + \mathbf{R}_k)^{-1}, \quad (3.10)$$

$$\mathbf{P}_{k,k} = (\mathbf{I} - \mathbf{G}_k \mathbf{C}_k) \mathbf{P}_{k,k-1}, \quad (3.11)$$

$$\hat{\mathbf{x}}_{0|0} = E[\mathbf{x}_0], \quad (3.12)$$

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{A}_{k-1} \hat{\mathbf{x}}_{k-1|k-1}, \quad (3.13)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{G}_k (\mathbf{v}_k - \mathbf{C}_k \hat{\mathbf{x}}_{k|k-1}), \quad (3.14)$$

onde, \mathbf{G}_k e $\hat{\mathbf{x}}_{m|n}$ são o ganho de Kalman e a estimativa de \mathbf{x}_m dado V_n , respectivamente.

Os termos $Var[\mathbf{x}_0]$ e $\mathbf{P}_{m,n}$ são definidos como segue:

$$Var[\mathbf{x}_0] = E[(\mathbf{x}_0 - \bar{\mathbf{x}}_0)(\mathbf{x}_0 - \bar{\mathbf{x}}_0)^T], \quad (3.15)$$

$$\mathbf{P}_{m,n} = E[(\mathbf{x}_m - \hat{\mathbf{x}}_{m|n})(\mathbf{x}_m - \hat{\mathbf{x}}_{m|n})^T], \quad (3.16)$$

onde $\bar{\mathbf{x}}_0$ representa o valor esperado de \mathbf{x}_0 .

As expressões (3.8)–(3.14) mostram que o filtro de Kalman pode ser visto como um procedimento de estimação do vetor de estado composto de duas etapas: predição (3.13) e atualização (3.14). O ganho de Kalman \mathbf{G}_k e o erro de predição do sinal observado $(\mathbf{v}_k - \mathbf{C}_k \hat{\mathbf{x}}_{k|k-1})$, este também chamado de processo de inovação, controlam a atualização do vetor de estado em (3.14).

O sistema completo, sistema gerador do sinal observado \mathbf{v}_k e filtro de Kalman, é ilustrado na Fig. 3.1.

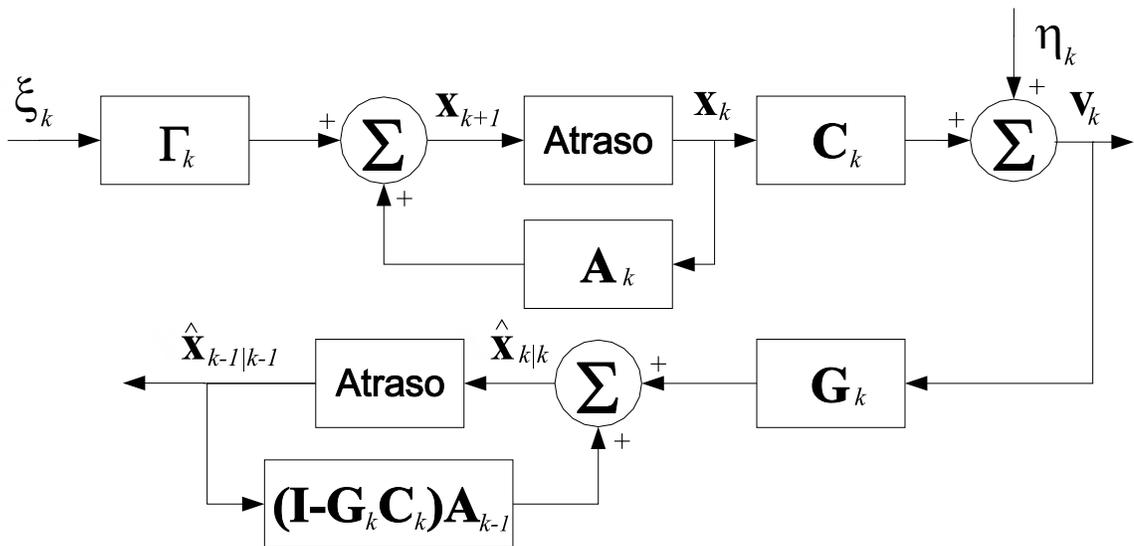


Fig. 3.1 – Sistema completo (geração do sinal observado e filtro de Kalman).

Em certas situações, pequenas modificações podem ser feitas nas equações (3.1) e (3.2) (as quais descrevem o sistema gerador do sinal observado) na tentativa de modelar não-linearidades ou por necessidade decorrente de como a filtragem é abordada (ver Seção 3.4.3). As referidas modificações alteram também as equações que descrevem o filtro de Kalman, o qual passa a ser chamado de *filtro de Kalman estendido* [2], [22]. Em (3.17) e (3.18), são mostradas, respectivamente, as alterações na descrição do sistema gerador (expressão (3.1)) e do filtro de Kalman (expressão (3.13)), pertinentes a este trabalho.

$$\mathbf{x}_{k+1} = \mathbf{A}_k \mathbf{x}_k + \mathbf{\Gamma}_k \xi_k + \mathbf{E}_k \mathbf{u}_k , \quad (3.17)$$

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{A}_{k-1} \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{E}_{k-1} \mathbf{u}_{k-1} , \quad (3.18)$$

onde \mathbf{u}_k é um vetor determinístico usado para ajustar o modelo ao sistema que se quer descrever e \mathbf{E}_k é a matriz de ponderação de \mathbf{u}_k .

As principais características do filtro de Kalman são relacionadas a seguir:

- a) *Linearidade*: essa característica permite que sejam usadas as ferramentas, já bastante conhecidas, para análise de sistemas lineares no estudo do comportamento do filtro de Kalman;
- b) *Filtro ótimo*: o filtro de Kalman é ótimo no sentido de minimizar a média do módulo do erro ao quadrado (também chamado de erro quadrático médio). Portanto, não há *filtro linear* melhor do que o filtro de Kalman, considerando que o critério de otimização citado seja adotado;
- c) *Definição no domínio da seqüência*: desenvolvido para tratar, em geral, processos não-estacionários, o filtro de Kalman é naturalmente definido no domínio da seqüência, não havendo, portanto, contraparte do referido filtro no domínio da freqüência [2], [22];
- d) *Recursividade*: a estimativa do estado é obtida de forma recursiva (a estimativa anterior é usada no cálculo da estimativa corrente), reduzindo o volume de memória

necessário e a complexidade computacional do procedimento de estimação em relação à solução clássica de mínimos quadrados [22];

- e) *Adaptabilidade*: as expressões (3.1) e (3.2), também como aquelas que sintetizam o filtro de Kalman (3.8) a (3.14), consideram, em geral, \mathbf{A}_k , $\mathbf{\Gamma}_k$, \mathbf{C}_k , $\boldsymbol{\xi}_k$ e $\boldsymbol{\eta}_k$ dependentes da amostra k . Como consequência, o filtro de Kalman apresenta ganho \mathbf{G}_k variável, o que permite que o referido filtro se adapte às características locais de sinais não-estacionários. No caso de \mathbf{A}_k , $\mathbf{\Gamma}_k$, \mathbf{C}_k , $\boldsymbol{\xi}_k$ e $\boldsymbol{\eta}_k$ serem independentes de k , todas as características anteriores são mantidas, com a vantagem de se obter expressiva redução de complexidade computacional, uma vez que o cálculo de \mathbf{G}_k pode ser efetuado antes da filtragem propriamente dita usando (3.8) a (3.11). Uma vez calculado \mathbf{G}_k , a filtragem é realizada usando (3.12) a (3.14).

Estudos mais abrangentes sobre filtro de Kalman, incluindo a derivação das expressões (3.8) a (3.14), podem ser encontrados em [2], [22], [35], [41], [42] e [60].

3.3 Restauração de imagens via filtragem de Kalman

Em virtude das características do filtro de Kalman, citadas na seção anterior, surgiu o interesse em adaptá-lo para o processamento de sinais bidimensionais [80], [81]. Essa adaptação tornaria o filtro de Kalman útil em aplicações como o tratamento de dados sísmicos, estimação de imagens contaminadas por ruído (*denoising*) e, em especial, restauração de imagens [74], [81]. O restante desta seção dedica-se à adaptação do filtro de Kalman ao problema da restauração de imagens, embora muito do que é abordado a seguir seja válido para outras aplicações bidimensionais.

Uma das primeiras medidas a serem tomadas para adaptar o filtro de Kalman ao processamento de imagens consiste em *escolher uma direção e um sentido para o processamento*. Isso decorre da necessidade de se ordenar os pixels de alguma maneira, com o intuito de se ter um “passado” no qual a recursividade do filtro de Kalman tenha em que se basear para estimar o vetor de estado “presente”. Na maioria dos trabalhos publicados sobre restauração de imagens, a escolha da direção e do sentido de processamento é arbitrária. No entanto, há estudos [18][61][70] atestando que a direção e o

sentido adotados influenciam na qualidade da restauração. Em [18], é mostrado que a direção de processamento de uma determinada região da imagem que oferece melhores resultados segue a orientação das bordas locais e, em [61] e [70], é sugerido um processamento complementar, em sentido inverso ao adotado inicialmente, para diminuir o efeito de polarização na restauração. A Fig. 3.2 mostra algumas das opções, as mais comuns, para a direção e sentido de processamento em uma imagem.

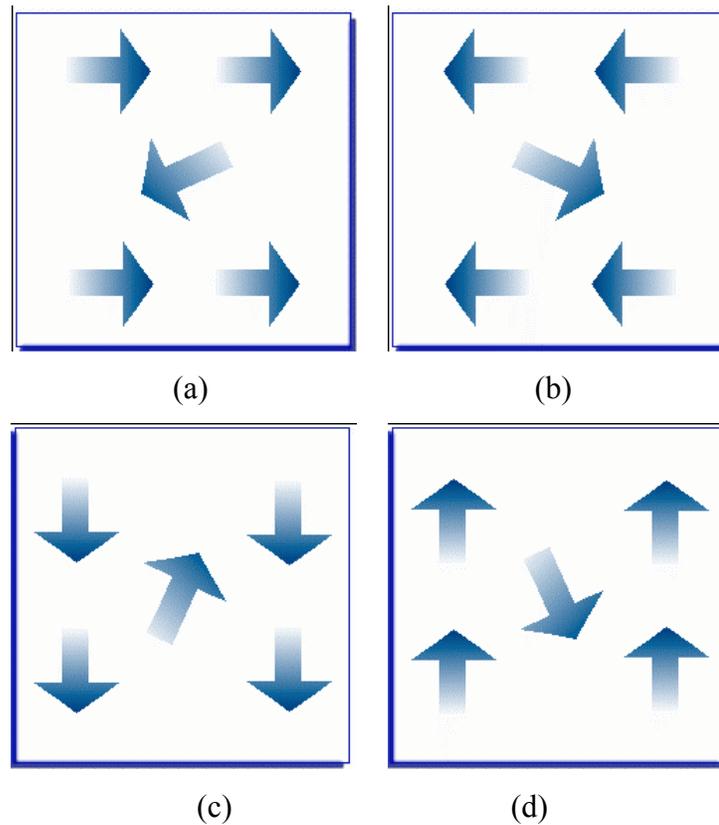


Fig. 3.2 – Exemplos de direção e sentido de processamento: (a) da esquerda para a direita, de cima para baixo; (b) da direita para a esquerda, de cima para baixo; (c) de cima para baixo, da esquerda para a direita; e (d) de baixo para cima, da esquerda para a direita.

Um aspecto relacionado diretamente à direção e ao sentido de processamento adotados é a escolha do suporte do vetor de estado. Entenda-se por suporte do vetor de estado como a região da imagem que corresponde aos elementos do vetor de estado. As diferentes abordagens da filtragem 2-D de Kalman devem suas peculiaridades tanto à maneira como as equações do sistema são utilizadas na descrição do sistema de aquisição/degradação,

quanto às escolhas referentes ao suporte do vetor de estado e à direção e ao sentido de processamento.

Podendo modelar de diferentes maneiras os processos de aquisição e degradação de imagens, as equações (3.1) e (3.2) são, contudo, utilizadas, em um grande número de situações, [4], [13], [14], [18], [44], [46], [47], [48], [59], [61], [80], [81], para representar o seguinte modelo (ver Seção 2.2).

$$x(m, n) = \sum_{(k, l) \in D_1} a(k, l)x(m - k, m - l) + \xi(m, n), \quad (3.19)$$

$$v(m, n) = \sum_{(k, l) \in D_2} c(k, l)x(m - k, n - l) + \eta(m, n), \quad (3.20)$$

onde $x(m, n)$, $v(m, n)$, $\xi(m, n)$ e $\eta(m, n)$ representam a imagem original, a imagem degradada, o ruído de entrada e o ruído aditivo de observação, respectivamente; $a(m, n)$ são os coeficientes do filtro *auto-regressivo* (AR) que modela o sistema de síntese da imagem original; $c(m, n)$ é a resposta ao impulso do filtro *moving-average* (MA) que modela o sistema de aquisição/degradação; D_1 e D_2 indicam o suporte de $a(m, n)$ e $c(m, n)$, respectivamente. Os sinais $\xi(m, n)$ e $\eta(m, n)$ são freqüentemente considerados ruídos do tipo branco Gaussiano com média nula.

Os termos $a(m, n)$ e $\xi(m, n)$ podem ainda ter outra interpretação: $a(m, n)$ pode ser considerado como uma medida da correlação do pixel $x(m, n)$ em relação aos seus vizinhos pertencentes à região D_1 ; $\xi(m, n)$ pode ser visto como o erro associado à tentativa de se representar $x(m, n)$ como combinação linear de seus vizinhos localizados em D_1 (ver também Seção 2.2).

Logo, considerando (3.19) e (3.20), pode-se dizer dos elementos de (3.1) e (3.2) que:

- a) \mathbf{x}_k contém informações da imagem original, as quais serão estimadas pelo filtro de Kalman;
- b) ξ_k , $\boldsymbol{\eta}_k$ e \mathbf{v}_k representam os ruídos $\xi(m, n)$, $\eta(m, n)$ e a imagem degradada $v(m, n)$, respectivamente;
- c) \mathbf{A}_k é organizada de maneira a incluir, nas equações do filtro de Kalman, a influência dos coeficientes de correlação $a(m, n)$;

- d) C_k é a matriz que contém informação referente à resposta ao impulso do sistema de aquisição/degradação $c(m, n)$;
- e) A matriz Γ_k é uma matriz de ponderação que serve para efetuar eventuais ajustes entre as equação do filtro de Kalman e o modelo expresso em (3.19) e (3.20).

A adaptação do filtro de Kalman para o processamento de imagens exige mais alguns cuidados, os quais não eram necessários no caso unidimensional. Um desses cuidados diz respeito às transições entre linhas, no caso do processamento da imagem ser feito linha-a-linha (ou às transições entre colunas, no processamento coluna-a-coluna). Nessas transições, verifica-se uma descontinuidade que não ocorria no caso unidimensional, descontinuidade essa que resulta em perturbações na atualização dos elementos da matriz de covariância do erro e no surgimento de artefatos na imagem restaurada. Como forma de minorar esse problema, ou seja, na tentativa de tornar as transições em questão mais suaves, são usados *pixels de contorno*. Esses pixels de contorno podem ser definidos de várias maneiras, dentre as quais destacam-se [4]:

- a) geração aleatória dos pixels de contorno, os quais devem apresentar valor médio igual ao valor médio dos pixels da imagem;
- b) pixels de contorno iguais aos pixels da linha seguinte a ser processada;
- c) diminuição da dimensão imagem que efetivamente será filtrada, deixando que os próprios pixels periféricos da imagem sirvam como condição de contorno.

Para melhor compreensão de como a adaptação do filtro de Kalman à restauração de imagens é realizado, adotar-se-á, a título de exemplo, que o processamento se verifica da esquerda para a direita, de cima para baixo (direção e sentido de processamento). O vetor de estado corresponde, na imagem original, à região ilustrada na Fig. 3.3 e definida em (3.21). Na Fig. 3.4, está indicada, em termos gerais, a região de pixels de contorno que precisa ser adicionada à (no caso das opções (a) e (b) referentes aos pixels de contorno, anteriormente citadas) ou selecionada (opção (c) dos pixels de contorno) na imagem original de maneira a satisfazer os modelos considerados.

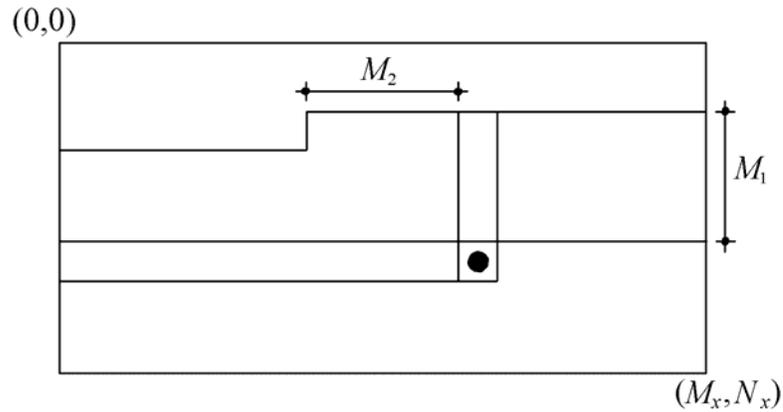


Fig. 3.3 – Região correspondente na imagem original aos elementos do vetor de estado, considerando o processamento da esquerda para a direita, de cima para baixo.

$$\begin{aligned}
 \mathbf{x}_k = & [x(m, n) \quad x(m, n-1) \quad \text{L} \quad x(m, 0) \\
 & x(m-1, N_x) \quad x(m-1, N_x-1) \quad \text{L} \quad x(m-1, 0) \\
 & \text{L} \\
 & x(m-M_1, N_x) \quad x(m-M_1, N_x-1) \quad \text{L} \quad x(m-M_1, n-M_2)]^T
 \end{aligned}
 \tag{3.21}$$

onde N_x , M_1 e M_2 denotam a dimensão horizontal da imagem original, a extensão vertical e horizontal do suporte do vetor de estado, respectivamente.

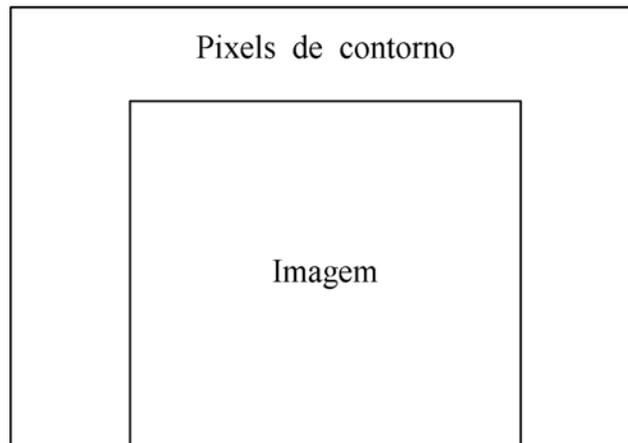


Fig. 3.4 – Região dos pixels de contorno.

Apesar da recursividade intrínseca do filtro de Kalman, sua direta utilização em processamento bidimensional eleva consideravelmente os níveis de complexidade computacional e volume de memória necessário, mesmo considerando os recursos de processamento atuais. Visando reduzir memória e complexidade, foram propostas aproximações do filtro de Kalman [80]. No entanto, tais aproximações reduzem o custo computacional e o volume de memória necessário ao preço de um certo afastamento, ou desvio, da solução ótima obtida pelo filtro de Kalman original. Estabelecido, portanto, o compromisso entre *redução de complexidade computacional e volume de memória necessário* \times *afastamento da solução ótima de Kalman*, as diversas abordagens alternativas se justificam à medida que obtêm uma redução expressiva de complexidade computacional e de volume de memória necessário com afastamento aceitável da solução ótima, senão do ponto de vista numérico, pelo menos do ponto de vista da percepção de qualidade.

A seguir, são apresentadas três dessas aproximações, sendo a última a que será usada nas simulações desta tese.

3.4 Aproximações do filtro de Kalman original

3.4.1 Filtro de Kalman por Faixas (Strip Kalman – SK)

No filtro SK, a imagem a ser processada é dividida em faixas (horizontais ou verticais, superpostas ou não) e o vetor de estado é definido como sendo uma seção das citadas faixas. Suponha-se, por exemplo, que o vetor de estado é do tipo linha, de dimensão l , esta sendo muito menor do que o número de colunas da imagem L . Nesse caso, a imagem é dividida em faixas verticais. Na restauração, uma possibilidade pode ser restaurar as faixas verticais da esquerda para a direita e, em uma mesma faixa, de cima para baixo (Fig. 3.5).

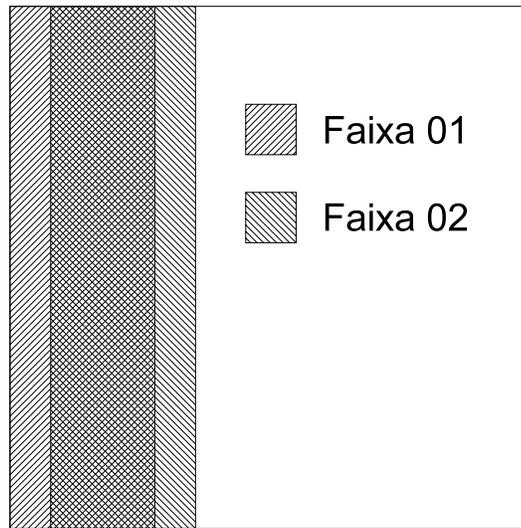


Fig. 3.5 – As duas primeiras faixas verticais (com superposição) de uma imagem a ser restaurada por um filtro SK.

Sendo o SK assim estruturado, os elementos das extremidades do vetor de estado não podem ser representados em função do estado anterior, como estabelece (3.1), a menos que se lance mão de condições de contorno [80]. De qualquer forma, a estimação dos elementos das extremidades do vetor de estado apresenta níveis de ruído elevados, considerando os respectivos níveis verificados nas estimativas dos elementos mais centrais. Em [80], é proposta a superposição das faixas de restauração, com o objetivo de reduzir o ruído de estimação na imagem restaurada. Em cada faixa de restauração, apenas os elementos mais centrais são preservados para compor a imagem restaurada (Fig. 3.6). Contudo, essa estratégia resulta na necessidade de se definir um maior número de faixas a serem processadas por imagem.

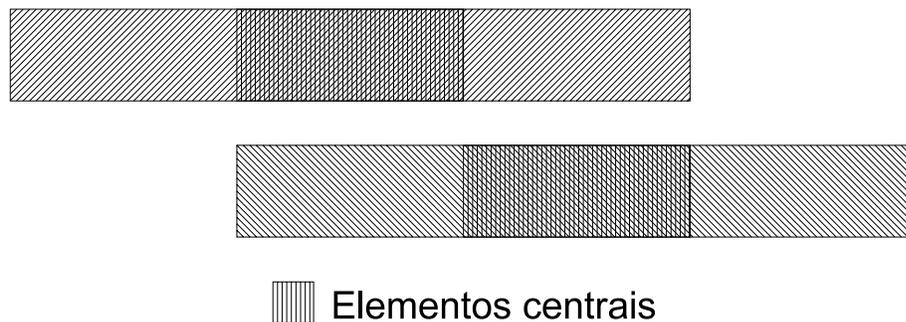


Fig. 3.6 – Elementos centrais do vetor de estado que são preservados para compor a imagem restaurada.

O SK descrito anteriormente explora adequadamente a correlação entre as linhas da imagem, mas deixa a desejar na exploração da correlação existente entre as colunas. Essa última característica pode ser apontada como a principal desvantagem do filtro sob apreciação.

Maiores detalhes sobre o SK podem ser encontrados em [74] e [80].

3.4.2 *Filtro de Kalman de Atualização Reduzida (Reduced Update Kalman Filter – RUKF)*

O RUKF é apresentado em [80] e caracteriza-se por ser uma abordagem que usa o vetor de estado completo, porém apenas os elementos mais próximos da amostra que está sendo processada são atualizados, ao invés de todo o vetor de estado. Em outras palavras, a etapa de atualização do filtro de Kalman é reduzida. Essa redução que visa a diminuição da complexidade computacional tem como consequência um desvio da resposta do filtro de Kalman original. Portanto, o RUKF, apesar de usar o vetor de estado completo, é sub-ótimo em relação ao filtro 2-D de Kalman, porque as equações de atualização desse filtro são modificadas. As desvantagens verificadas no RUKF consistem em sua limitada utilidade em filtragem adaptativa e em sua região de atualização da covariância do erro ser ainda muito maior do que a região de suporte definida por D_1 e D_2 (ver (3.19) e (3.20)) [4].

A Fig. 3.7 mostra a região de suporte do vetor de estado completo, diferenciando as regiões que serão e as que não serão atualizadas no RUKF.

Maiores detalhes sobre o RUKF podem ser encontrados em [75], [76] e [80].

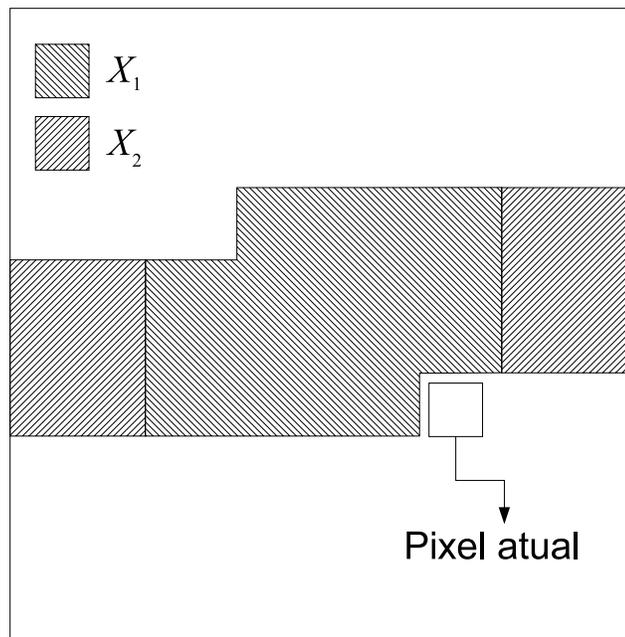


Fig. 3.7 – Vetor de estado completo, mostrando a região que será atualizada (X_1) e a região que não será atualizada (X_2) no RUKF.

3.4.3 Filtro de Kalman de Modelo de Ordem Reduzida (Reduced Order Model Kalman Filter – ROMKF)

O ROMKF foi proposto em [4], assim como as outras aproximações já discutidas, com o objetivo de reduzir a complexidade computacional no processamento de imagens, admitindo, contudo, certas perdas de qualidade na estimação do vetor de estado. A desejada redução de complexidade é obtida, no ROMKF, usando-se uma versão de dimensão reduzida do vetor de estado ao invés do vetor de estado completo. Nesse caso, diferente do que ocorre no RUKF (Seção 3.4.2), as expressões que definem o filtro de Kalman permanecem inalteradas.

Este vetor de estado reduzido é, por definição, composto pelo número mínimo de elementos capaz de conter os suportes D_1 e D_2 , ou seja, capaz de conter os elementos de correlação relevante em relação ao pixel atual e a resposta ao impulso do sistema de degradação. A referida redução acarreta, naturalmente, desvios da solução ótima do filtro de Kalman original.

A implementação do ROMKF pressupõe, como qualquer abordagem baseada no filtro de Kalman, a definição de uma região de suporte para o vetor de estado (nesse caso, vetor de estado reduzido). Comumente utilizado, foi adotado nesta tese o modelo de suporte conhecido como *Meio Plano Assimétrico de Ordem $M_1 \times M_2 \times M_3$* (*Non-Symmetric Half Plane – NSHP*) [4], e que é ilustrado na Fig. 3.8, adaptado ao processamento linha-a-linha, da esquerda para a direita, de cima para baixo.

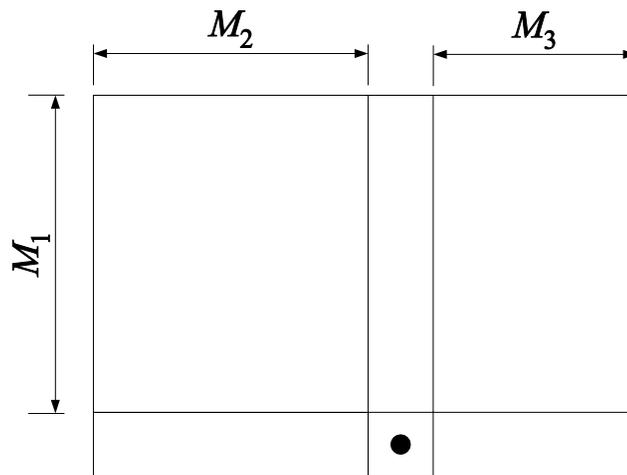


Fig. 3.8 – Modelo de suporte $M_1 \times M_2 \times M_3$ NSHP, adaptado ao processamento linha-a-linha, da esquerda para a direita, de cima para baixo.

A substituição do vetor de estado pelo vetor de estado reduzido tem, também, como consequência a impossibilidade de se representar alguns dos elementos do vetor de estado reduzido em função do vetor de estado reduzido anterior, como estabelece (3.1). É essa impossibilidade que causa o supracitado desvio da resposta do ROMKF em relação à resposta ótima do filtro de Kalman original. A Fig. 3.9 mostra, para o modelo de suporte do vetor de estado reduzido apresentado na Fig. 3.8, os elementos (os mais à direita do modelo de suporte) que não podem ser representados em função do vetor de estado reduzido anterior.

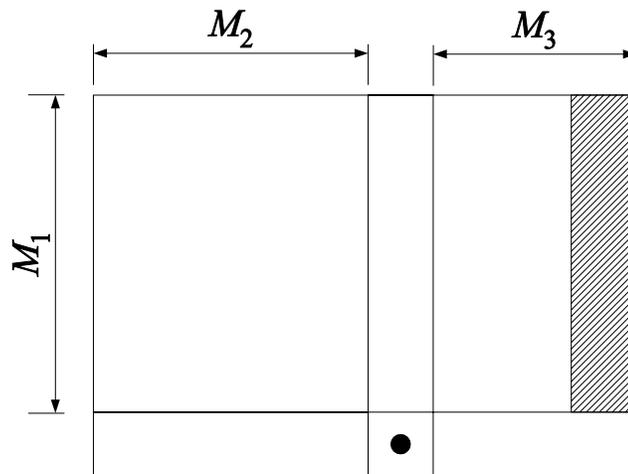


Fig. 3.9 – Os elementos que não podem ser representados em função do vetor de estado reduzido anterior (elementos mais à direita do modelo de suporte).

Os elementos mais à direita, portanto, precisam ser estimados de alguma maneira. Algumas estratégias são propostas em [4] e [5], a saber:

- a) *Vizinho mais próximo (nearest neighbour)*: os elementos imediatamente anteriores aos elementos mais à direita são tomados como estimativas destes (Fig. 3.10 (a));
- b) *Wrap around*: os primeiros elementos da linha seguinte aos elementos mais à direita no vetor de estado anterior são tomados como estimativas (Fig. 3.10 (b));
- c) *Melhor estimativa (best estimate)*: os elementos mais à direita são estimados por um outro processo qualquer, externo, segundo determinado critério de otimização (Fig. 3.10 (c)).

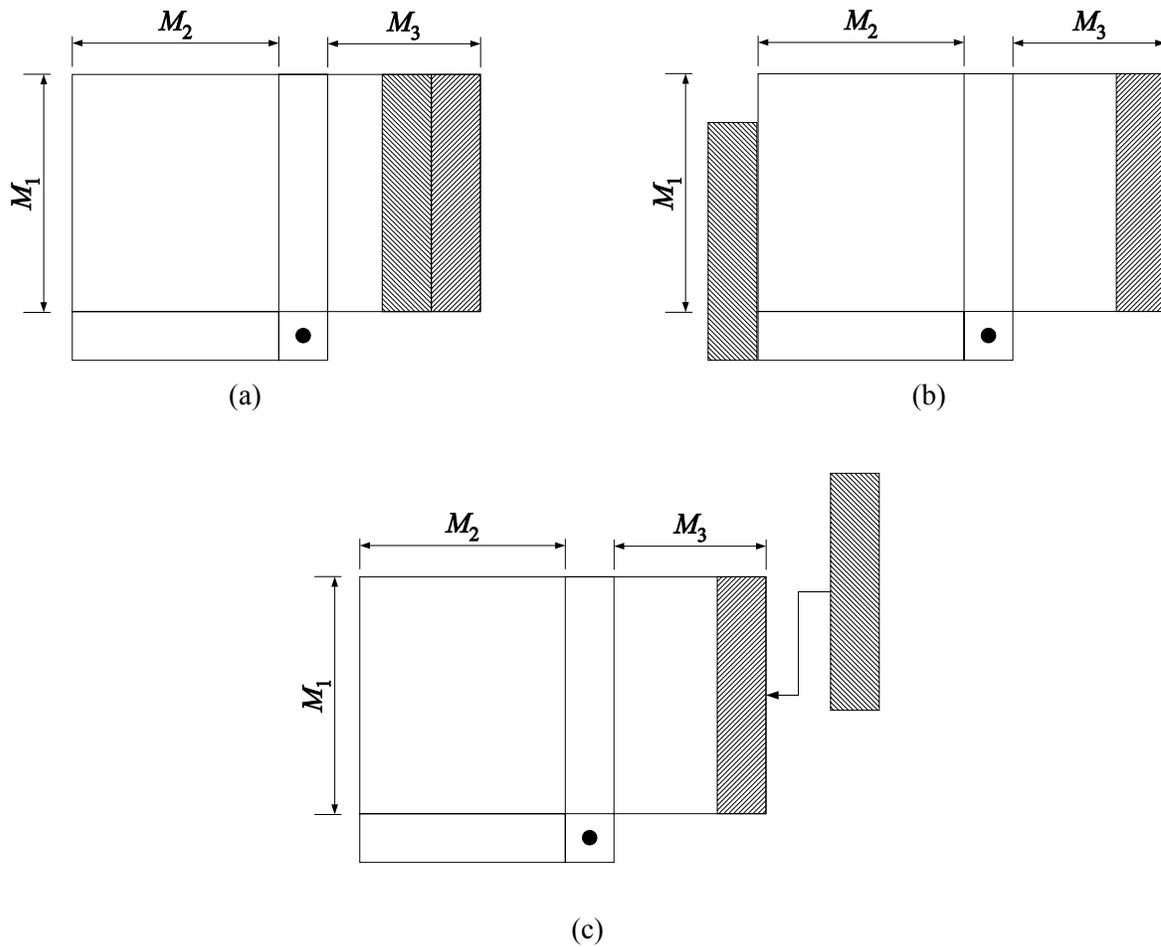


Fig. 3.10 – Aproximações dos elementos mais à direita do suporte do vetor de estado reduzido: (a) vizinho mais próximo; (b) wrap around; (c) melhor estimativa.

As duas primeiras estratégias resultam em restaurações de pior qualidade e possuem estabilidade inferior em relação à opção *melhor estimativa*. No entanto, a *melhor estimativa* exige que a formulação usada seja a do filtro de Kalman estendido [4], [5].

O ROMKF, assim como as outras abordagens baseadas em filtragem de Kalman, considera que as matrizes \mathbf{A}_k , $\mathbf{\Gamma}_k$ e \mathbf{C}_k , bem como as estatísticas de segunda ordem de ξ_k e η_k sejam conhecidas. No entanto, na maioria das situações práticas, os parâmetros que definem os referidos elementos são apenas parcialmente conhecidos, ou mesmo totalmente desconhecidos (ver Seção 2.3). Assim, em [4] e [5], o ROMKF é usado em conjunto com uma função baseada no critério de máxima verossimilhança (3.22) com a finalidade de estimar aqueles parâmetros necessários.

$$J = N \ln |R_{ee}| + \frac{1}{R_{ee}} \sum (\mathbf{v}_k - \mathbf{C}_k \hat{\mathbf{x}}_{k|k-1})^2 \quad (3.22)$$

onde N e R_{ee} representam o número de amostras da imagem degradada e a matriz de covariância do processo inovação, respectivamente.

Há ainda dois outros fatores de relevante influência na qualidade da restauração via ROMKF com *melhor estimativa*: a estratégia de obtenção da “melhor estimativa” dos elementos mais à direita do suporte do vetor de estado reduzido e a presença de ótimos locais na função de máxima verossimilhança usada na estimação paramétrica.

Quando se opta pela *melhor estimativa*, a estimação dos elementos mais à direita é um campo livre à criatividade do projetista, uma vez que o critério e a maneira de como essa estimativa é obtida permanecem em aberto. De qualquer forma, seja qual for a maneira e o critério escolhidos, um nível maior de ruído é introduzido na estimação dos elementos mais à direita do suporte (semelhante ao que acontece nas extremidades do suporte do SK (ver Seção 3.4.1)). Esse problema é atenuado aumentando em alguns pixels as dimensões do suporte do vetor de estado [4], [5].

A presença de ótimos locais na função de máxima verossimilhança pode levar à convergência para soluções não satisfatórias, caso sejam usados algoritmos de otimização sensíveis às condições iniciais. Esses são, no entanto, tradicionalmente utilizados, pois apresentam complexidade computacional significativamente mais baixa em relação aos algoritmos não sensíveis às condições iniciais. A justificativa para tal escolha reside em ser a complexidade computacional um aspecto bastante visado em processamento de imagens devido ao grande volume de dados a ser tratado. Alguns autores [4], [5] sugerem duas medidas a fim de contornar o problema da eventual convergência para ótimos locais não satisfatórios:

- a) a adoção de modelos para a degradação, reduzindo o número de parâmetros a estimar, a complexidade computacional do sistema e o número de ótimos locais;
- b) o procedimento de reiniciar várias vezes o algoritmo de restauração com diferentes condições iniciais.

No Capítulo 5, o procedimento (b) tem sua validade questionada em função da comparação de resultados obtidos por simulação para os casos em que são usados algoritmos sensíveis e não sensíveis às condições iniciais na etapa de estimação paramétrica do ROMKF.

Material adicional sobre o ROMKF é encontrado em [45] e [46].

Em [47], [48], [69] e [72], o filtro de Kalman é usado na restauração de imagens em cenários diferentes daqueles trabalhados ao longo deste capítulo.

3.5 Conclusões

O presente capítulo aborda a adaptação da formulação do filtro de Kalman, que é originalmente definida para sinais unidimensionais, a aplicações bidimensionais, em particular à restauração de imagens.

Primeiramente, é apresentado o filtro de Kalman com suas principais características. Em seguida, a adaptação do filtro de Kalman para aplicações 2-D é discutida, abordando questões relacionadas à escolha de direção e sentido de processamento e suporte do vetor de estado. O filtro 2-D de Kalman resultante apresenta elevada complexidade computacional e grande volume de memória necessário, motivando a proposição de aproximações do filtro 2-D de Kalman.

Três dessas aproximações foram discutidas: SK, RUKF e ROMKF. As características de cada uma delas foram descritas, com ênfase às do ROMKF.

4.1 Introdução

Neste capítulo, aborda-se a computação evolucionária, iniciando com um breve histórico e com as principais idéias que caracterizam essa ferramenta usada, em engenharia e outras áreas, na solução de problemas complexos, não-lineares e de comportamento imprevisível ou quando as estratégias tradicionais são inadequadas ou não funcionam. Em seguida, são apresentados dois exemplos de estratégias em computação evolucionária: *algoritmo genético* e *programação evolucionária*. As principais características de cada uma das estratégias citadas são discutidas. A *programação evolucionária* é enfatizada, pois é a estratégia usada, como ferramenta para otimização, nas simulações do Capítulo 5.

4.2 Breve histórico e bases filosóficas

As idéias que dão suporte à computação evolucionária remontam aos tempos da publicação do livro *A Origem das Espécies* [24] do naturalista inglês Charles Darwin, no qual ele divulgou seus estudos sobre a evolução dos seres vivos. Em termos gerais, Darwin postula que as espécies evoluem, modificam-se, a partir de um mecanismo natural denominado *sobrevivência do mais apto*: os indivíduos de uma determinada espécie mais adaptados ao ambiente em que vivem têm maiores chances de sobreviver nesse mesmo ambiente e de gerar descendentes, legando-lhes suas características.

A adaptação dos seres vivos ao ambiente em que vivem, esteja esse ambiente em modificação ou não, deve-se a fatores, tais como:

- a) permutas genéticas entre indivíduos de uma mesma espécie, conhecidas por *recombinação*;
- b) alterações genéticas aleatórias, denominadas *mutação*;

- c) diversidade genética presente em um agrupamento de indivíduos, o qual é chamado de *população*;
- d) pressão seletiva que o próprio ambiente exerce nas populações.

O fator *tempo* também é relevante em todo este processo, pois a adaptação se verifica, não de maneira instantânea, mas gradualmente na sucessão das gerações.

Pesquisadores da área biológica tiveram, então, o interesse em investigar os efeitos específicos dos supracitados fatores na adaptação e evolução naturais. Havendo impossibilidades óbvias na realização desse tipo de investigação *in loco*, passou-se a usar programas de computador a fim de simular populações em evolução [24]. Destaca-se, nesse período, o trabalho de John Holland [36], que teve como objetivos explicar o processo da adaptação natural e desenvolver sistemas artificiais que simulassem as características principais da referida adaptação.

A partir dos esforços daqueles pesquisadores, a robustez dos mecanismos naturais de adaptação, ou seja, a capacidade de adaptação dos seres vivos a ambientes complexos e em transformação, passa a ser implementada artificialmente através de estruturas e procedimentos computacionais.

Percebe-se que essas estruturas e procedimentos constituem uma nova ferramenta que, em função de suas características, começa a ser usada em outras áreas que não o estudo da evolução e adaptação naturais.

Ainda na Biologia, a agora chamada computação evolucionária é utilizada em simulações que auxiliam o estudo da dinâmica celular. Em seguida, a computação evolucionária passa a ser empregada no tratamento de sistemas não-lineares, reconhecimento de padrões e otimização de funções [31].

Alguns dos ramos da atividade humana que usam a computação evolucionária na atualidade [29] são:

- a) indústria farmacêutica: descoberta de novas drogas e projeto rápido de medicamentos (*fast design of medicines*);
- b) administração: busca de soluções flexíveis e análise de estratégias de decisão em ambientes multi-cenários;

- c) medicina: diagnóstico médico;
- d) forças armadas: treinamento de militares, através da simulação de situações de combate imprevistas e adaptadas às características daquele que se encontra em treinamento;
- e) engenharia: otimização de funções, inteligência artificial, projeto de dispositivos eletrônicos e topologia de circuitos, projeto de filtros, controle automático adaptativo e não-linear.

No tocante à engenharia, a computação evolucionária é aplicada em situações nas quais os algoritmos e estratégias tradicionais não conseguem bom desempenho ou simplesmente não funcionam; e na busca de soluções em problemas complexos, nos quais os sistemas envolvidos possuem comportamento caótico e/ou não-linear [29].

Considerando o contexto da chamada otimização de funções, as estratégias baseadas na computação evolucionária não se mostram limitadas em relação ao tipo de funções com as quais podem lidar, como ocorre com as estratégias tradicionais. A computação evolucionária pode ser aplicada na otimização de qualquer tipo de função, podendo esta função apresentar descontinuidades, múltiplos ótimos locais, perturbações aleatórias e não-linearidades.

A evolução pode ser vista como um processo iterativo de duas etapas ou passos: variação aleatória e seleção de indivíduos em meio a uma população. Assim, os elementos que caracterizam um determinado algoritmo como pertencente à computação evolucionária são:

- a) população de indivíduos (soluções candidatas);
- b) pressão seletiva do meio (sobrevivência dos mais aptos);
- c) variações aleatórias, seja na permuta de características entre indivíduos (recombinação) ou modificações nas características de um indivíduo isoladamente (mutação).

Cada indivíduo da população corresponde a uma solução específica para o problema que se deseja resolver. A pressão seletiva, exercida através de mecanismos específicos a

partir da associação de medidas de aptidão aos indivíduos da população, estabelece que as piores soluções geradas são descartadas, enquanto as melhores são preservadas para a próxima geração. E as variações aleatórias dizem como uma nova população é gerada a partir da população precedente.

A maneira de implementar estes elementos (população, pressão seletiva e variações aleatórias) define as diferentes estratégias na computação evolucionária, como pode ser notado nas seções que se seguem.

Não obstante as atraentes possibilidades (solução de problemas complexos, não-lineares e variantes) no emprego da computação evolucionária, há um preço a ser pago: o aumento de complexidade computacional em relação às estratégias mais tradicionais, aumento esse proporcional ao número de indivíduos estabelecido para compor a população.

Além disso, a computação evolucionária traz ainda hoje, abertos a mais profundos estudos, desafios que influenciam decisivamente seu desempenho, a saber: a escolha dos valores de seus parâmetros, de sua estrutura e da estratégia usada em seus operadores básicos. Essas escolhas estão relacionados à taxa de convergência dos algoritmos evolucionários e aos problemas de convergência prematura ou indevida.

Apesar de serem baseados naquilo que se conhece sobre os mecanismos da evolução natural, nenhuma razão há para que as estratégias e os operadores dos sistemas de evolução simulada fiquem restritos a tais conhecimentos. Ao contrário, reformulações nos operadores de recombinação, mutação e nas estratégias de seleção vêm demonstrando desempenho superior, em certos problemas, quando comparadas aos operadores e estratégias de pura inspiração nos processos de evolução natural.

A seguir, são apresentadas e discutidas as características de duas principais estratégias em computação evolucionária: os *algoritmos genéticos* e a *programação evolucionária*.

4.3 Diferentes algoritmos

Esta seção aborda duas diferentes estratégias em computação evolucionária: *algoritmo genético* e *programação evolucionária*. Para cada uma das referidas estratégias são apresentadas suas principais características, mas especial ênfase é dada à *programação*

evolucionária por ser a estratégia empregada, como ferramenta de otimização, nas simulações do Capítulo 5.

4.3.1 Algoritmo Genético (AG)

O AG é uma abordagem centrada no *genótipo* (conjunto de genes de um indivíduo) e tem inspiração, como o próprio nome revela, na dinâmica de evolução e adaptação genética dos seres vivos.

Cada indivíduo (solução candidata) de uma população é definido, ou caracterizado por um ou mais cromossomos. Como exemplo, pode-se citar os casos em que os elementos de uma população podem ser representados nas configurações *haplóide* (apenas um cromossomo) e *diploide* (dois cromossomos) [31]. A representação de um indivíduo por mais de um cromossomo procura oferecer diversidade genética adicional para que o AG possa lidar com problemas de complexidade elevada, no entanto, não há evidência suficiente da eficácia dessa estratégia, sendo mais comum a representação haplóide.

Os cromossomos são constituídos por uma seqüência de elementos, cada um destes denominado *gene*. Normalmente, os genes assumem valores binários, não obstante esta não ser a única possibilidade [27]. A Fig. 4.1 ilustra um cromossomo cujos genes são binários. A maior justificativa para que usualmente os valores dos genes sejam binários é que essa representação maximiza o chamado *paralelismo implícito* na busca de melhores soluções, propriedade que advém da chamada *teoria dos esquemas* ou *blocos de construção* (maiores detalhes ver discussão sobre *teoria dos esquemas* mais adiante). Além da maximização do *paralelismo implícito*, o outro fator que contribui para a adoção de genes binários é que a opção concorrente mais defendida, valor de gene real, resulta no aumento excessivo do espaço de busca e na conseqüente queda no desempenho do AG [28].

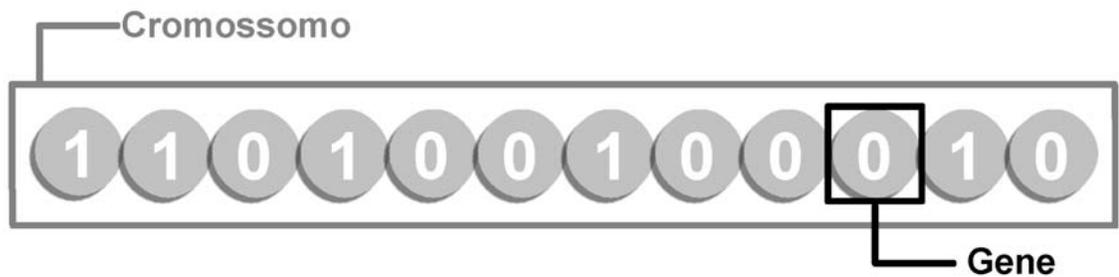


Fig. 4.1 – Exemplo de um cromossomo de 12 bits ou genes.

A cada indivíduo é associado um valor de aptidão. A determinação da aptidão requer, em primeiro lugar, que haja uma *função aptidão* que se relacione com o problema a ser resolvido, de forma que as melhores soluções possuam valores de aptidão mais altos. Em segundo lugar, é necessário que os parâmetros da função aptidão sejam codificados na forma de cromossomos. Uma forma de proceder a essa codificação consiste em definir o número de bits a ser usado e a faixa de valores representáveis pelo quantizador para cada parâmetro. O cromossomo é, então, formado pela concatenação dos parâmetros quantizados e representados em forma binária. Ressalta-se que o número de bits por parâmetro é responsável pela resolução de representação do parâmetro em questão, ao passo que o número de bits por parâmetro e o número de parâmetros definem o tamanho do espaço de busca a ser explorado pelo AG. A Fig. 4.2 apresenta um exemplo, no qual um indivíduo é representado por um único cromossomo e esse codifica quatro parâmetros, cada um com 3 bits. Nesse caso, cada parâmetro pode assumir apenas 8 valores distintos. A Fig. 4.2 ainda mostra uma das maneiras como os parâmetros codificados em um cromossomo são calculados para posterior avaliação do valor de aptidão que será associado ao cromossomo em questão.

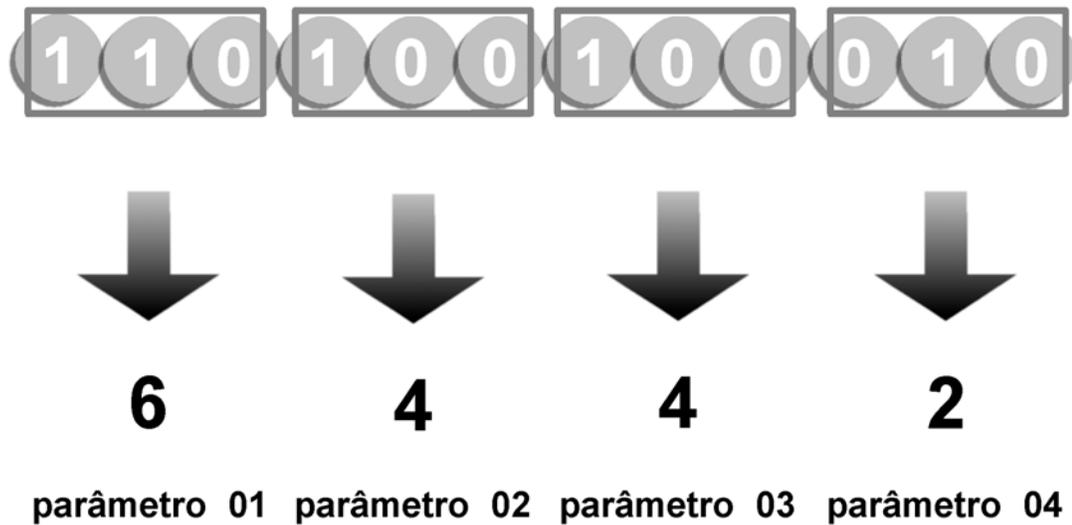


Fig. 4.2 – Cálculo de parâmetros de uma *função aptidão* a partir de um cromossomo de 12 bits, sendo que 3 bits são reservados para cada parâmetro. Cada parâmetro, portanto, pode assumir 8 valores distintos. Nesse exemplo, os parâmetros foram concatenados de forma seqüencial.

A primeira geração de um AG é iniciada aleatoriamente, com um número de indivíduos previamente definido, e as gerações sucessivas são produzidas a partir de quatro operadores básicos:

- a) *Seleção*: operador que define os indivíduos de uma geração que serão selecionados para compor os pares (indivíduos-pais) que darão origem aos indivíduos-filhos. Vários esquemas de seleção podem ser usados, tais como: *amostragem estocástica com reposição* (método da roleta); *amostragem determinística*; e *amostragem estocástica dos restos sem reposição* [83]. A probabilidade de que um determinado indivíduo seja selecionado é proporcional a sua aptidão, ou seja, quanto mais apto for um indivíduo, maior será o número de seus descendentes.
- b) *Cruzamento*: por este operador, que alguns autores chamam de recombinação, dois indivíduos selecionados permutam características através da troca de partes de seus respectivos cromossomos. Uma vez selecionados os pares de uma população, cada

um deles possui probabilidade P_c de que o cruzamento ocorra. A probabilidade de cruzamento P_c assume comumente valores que variam de 0,6 a 0,95. Essa faixa de valores para P_c tem relação com a grande importância atribuída ao cruzamento no processo de evolução da população. Dentre as estratégias de cruzamento existentes, destacam-se o *cruzamento simples*, o *cruzamento multi-ponto* e o *cruzamento uniforme*. No *cruzamento simples*, os cromossomos são seccionados em apenas um único ponto. No *cruzamento multi-ponto*, mais de um ponto de seção nos cromossomos é definido. E, no *cruzamento uniforme*, cada um dos genes dos filhos é definido a partir da escolha de um dos genes dos pais com igual probabilidade. Os pontos de quebra dos cromossomos, no caso do *cruzamento simples* e *multi-ponto*, são definidos aleatoriamente. A Fig. 4.3 mostra um cruzamento do tipo simples (apenas um ponto para seção dos cromossomos).

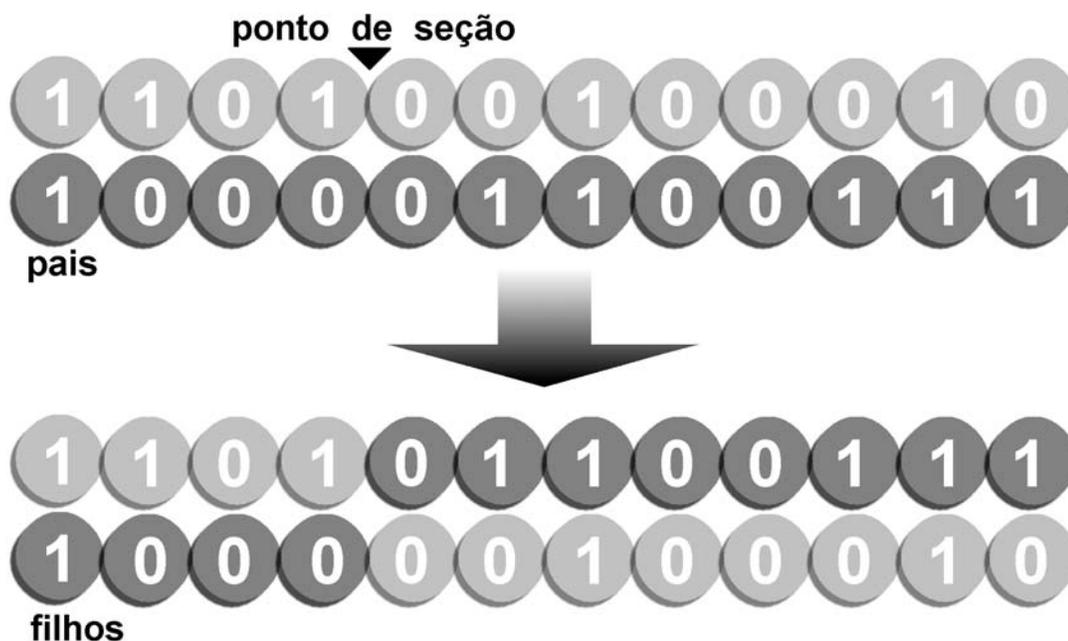


Fig. 4.3 – Cruzamento simples entre dois cromossomos.

- d) *Mutação*: fenômeno que na natureza ocorre quando, supostamente, há falha na replicação de um cromossomo. Em um AG, após a operação de cruzamento, cada bit dos cromossomos-filhos tem probabilidade P_m de que seu valor seja invertido (considerando genes de valor binário). A P_m tipicamente assume valores no

intervalo de 0,001 a 0,01. A mutação, nos AGs, é considerada um operador de menor importância do que o cruzamento, o que se reflete na faixa de valores que P_m normalmente assume. Seguindo esse raciocínio, a mutação tem como finalidade explorar pequenas variações nas soluções produzidas, exploração essa ainda não contemplada pela recombinação. A mutação também desempenha um papel decisivo na busca do ótimo global, principalmente, quando a diversidade genética diminui com a especialização da população no transcorrer das gerações. A Fig. 4.4 ilustra o funcionamento do operador de mutação na situação em que o teste de mutação para um determinado gene foi positivo.

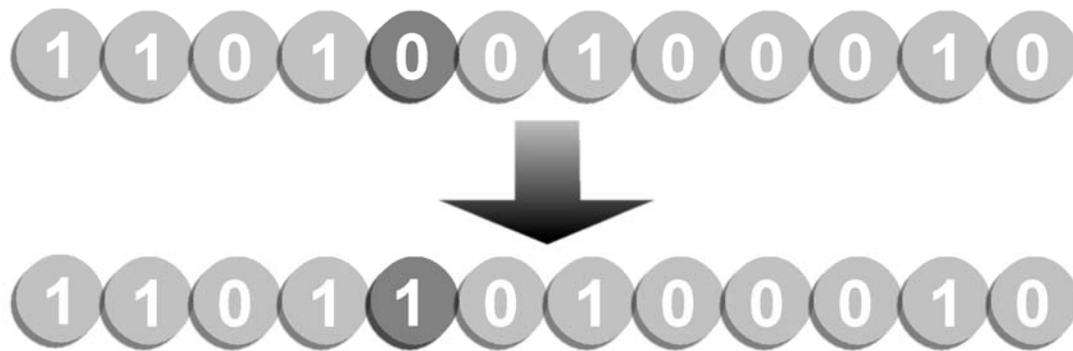


Fig. 4.4 – Exemplo de mutação em um cromossomo.

- e) *Reposição*: as estratégias de reposição definem quais os indivíduos, dentre pais e filhos, que serão preservados para a próxima geração e os que serão descartados. A reposição pode ser: *não-elitista* (toda a população de pais é substituída pela de filhos); *elitista* (os filhos substituem os pais, sendo que um determinado número dos melhores indivíduos é preservado, independentemente de pertencerem ao conjunto de pais ou filhos); ou *mista* (os piores pais são substituídos pelos melhores indivíduos da população de filhos).

Maiores detalhes sobre os operadores supracitados podem ser obtidos em [29], [31], [53] e [83].

O funcionamento de um AG se dá segundo um ciclo básico, ilustrado na Fig. 4.5. Esse ciclo é repetido até que seja satisfeito um determinado critério de parada que pode estar vinculado ao número de gerações, valor de aptidão do melhor indivíduo, dispersão de aptidão da população, manutenção do valor de aptidão do melhor indivíduo ao longo de certo número de gerações, etc.

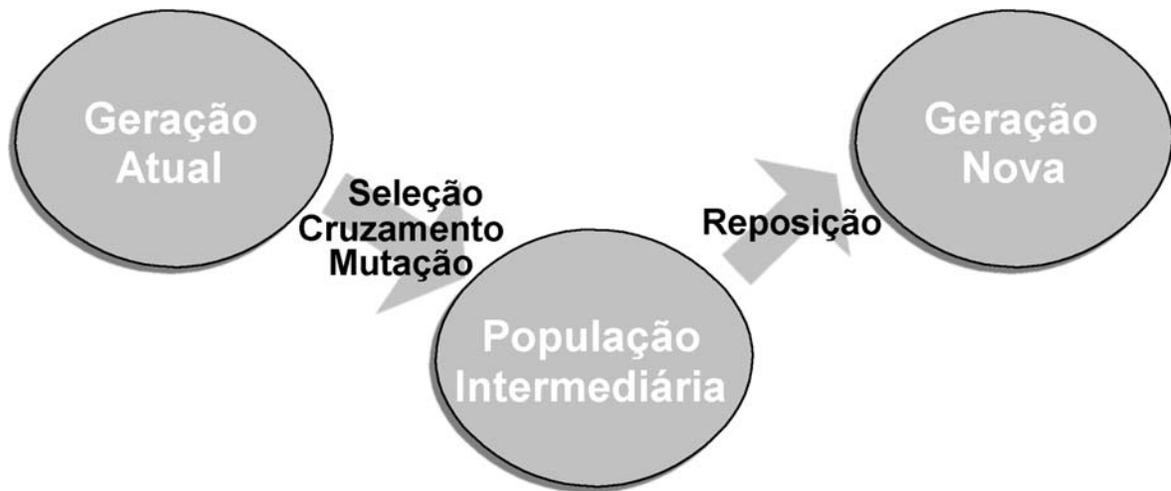


Fig. 4.5 – Ciclo básico de um algoritmo genético.

Os bons resultados dos AGs, bem como sua estabilidade e convergência, encontram-se parcialmente justificados na chamada *teoria dos blocos de construção* ou *teoria dos esquemas*. Contudo, é essa mesma teoria que mostra porque há casos nos quais o AG, mesmo quando seus parâmetros (P_c , P_m , número de indivíduos, estratégias de seleção, cruzamento, mutação e reposição) estão bem dimensionados, não possui um desempenho satisfatório. De maneira resumida, a teoria dos esquemas estabelece que alguns padrões cromossômicos (os esquemas ou blocos de construção) têm maior probabilidade de sobreviver do que outros. Essa probabilidade é determinada por fatores referentes ao AG em si (aptidão e estrutura dos esquemas) e à natureza do problema a ser resolvido pelo AG. No entanto, nos casos de *super-cromossomo* e *minimum deceptive problems*, por exemplo, a estrutura dos esquemas parece ter uma importância superior ao valor de aptidão, fazendo com que cromossomos de menor aptidão, e por isso sub-ótimos, prevaleçam sobre cromossomos de aptidão mais elevada. Uma estratégia usada para solucionar esse tipo de problema tem sido a utilização de operadores de *inversão* e *reordenamento de genes* nos

cromossomos [31], com controvertida eficácia [28]. Em decorrência da *teoria dos blocos de construção* e seu *paralelismo implícito*, argumenta-se que o bom desempenho de um AG está fortemente relacionado à necessidade de preservar esquemas. Essa concepção de bom desempenho associado à preservação de esquemas é o fator que resulta nos valores relativamente baixos da probabilidade de mutação P_m (pois mutação excessiva destrói esquemas) e na opção preferencial pelo *cruzamento simples* (quanto maior o número de pontos de seção, maior a probabilidade de destruição de esquemas). No entanto, há estudos mostrando que, com *cruzamento uniforme* e *multi-ponto*, bons resultados são obtidos, em alguns casos resultados melhores do que aqueles obtidos com *cruzamento simples* [27]. A teoria de esquemas, portanto, não é suficiente para orientar o ajuste adequado dos operadores de um AG.

Os parâmetros do AG influenciam decisivamente no seu desempenho. Entretanto, precisam ser definidos *a priori* e isso não se tem como fazer sem enveredar pelo empirismo. Acresce-se a isso que os parâmetros ideais de um AG, considerando um determinado momento do processo de evolução da população, modificam-se de geração para geração. Essa questão vem motivando propostas de AGs a parâmetros adaptáveis: AG com auto-adaptação, AG multi-camadas, etc. [31], [26].

4.3.2 Programação Evolucionária (PE)

A PE é uma abordagem que enfoca não mais o genótipo de um indivíduo, mas as relações entre pais e filhos em um cenário de competição estruturado segundo os valores de aptidão [6], [27]. As bases da PE remontam aos anos 60 [6], [28], sendo usada inicialmente na predição de seqüências de símbolos através de máquinas de estados finitos. Mantendo sua estrutura básica, a PE sofre algumas variações ao longo do tempo e passa a ser utilizada na otimização numérica de funções a parâmetros reais, para a qual mostrou-se bastante adequada [6], [7], [27], [28].

Assim como nos AGs, a PE caracteriza-se por ter uma população de indivíduos (conjunto de soluções candidatas) que evolui com o transcorrer das gerações, buscando o aprimoramento de seus elementos. No contexto da otimização de funções, esse aprimoramento traduz-se na perseguição ao ótimo global da função em avaliação. Ainda

no tocante às similaridades entre as duas estratégias citadas, os operadores de mutação e seleção também encontram-se presentes na PE.

Contudo, há duas principais diferenças entre o AG e a PE:

- a) os indivíduos não são codificados em cromossomos;
- b) o operador de cruzamento (recombinação) não existe.

Decorre dos dois aspectos supracitados que a geração de um determinado indivíduo-filho é devida exclusivamente à mutação de um único indivíduo-pai, uma vez que não há formação de pares para cruzamento.

A ausência de recombinação fez com que a PE ficasse relegada a segundo plano, no contexto das estratégias evolucionárias, por aproximadamente 30 anos, muito em função dos argumentos de pesquisadores adeptos do AG, os quais alegavam que a recombinação desempenha papel principal na evolução simulada e apenas a mutação não era suficiente para produzir bons resultados. O avanço das pesquisas em computação evolucionária, entretanto, veio demonstrar que o papel da recombinação era superestimado e o da mutação, por sua vez, subestimado [6]. Na atualidade, alguns autores [54] declaram que todas as estratégias existentes em computação evolucionária são equivalentes desde que bem ajustados os seus respectivos parâmetros.

Cada indivíduo i na PE é caracterizado pelo par (\mathbf{p}_i, σ_i) , onde \mathbf{p}_i é o vetor de parâmetros da função que se quer otimizar e σ_i denota a variável que controla a intensidade de perturbação do operador de mutação para os parâmetros do indivíduo i . Tanto os elementos de \mathbf{p}_i quanto σ_i assumem valores reais.

O ciclo básico da PE, ilustrado na Fig. 4.6, é semelhante ao ciclo básico do AG. A população da primeira geração é obtida aleatoriamente e as gerações posteriores são produzidas segundo os operadores de mutação e seleção.

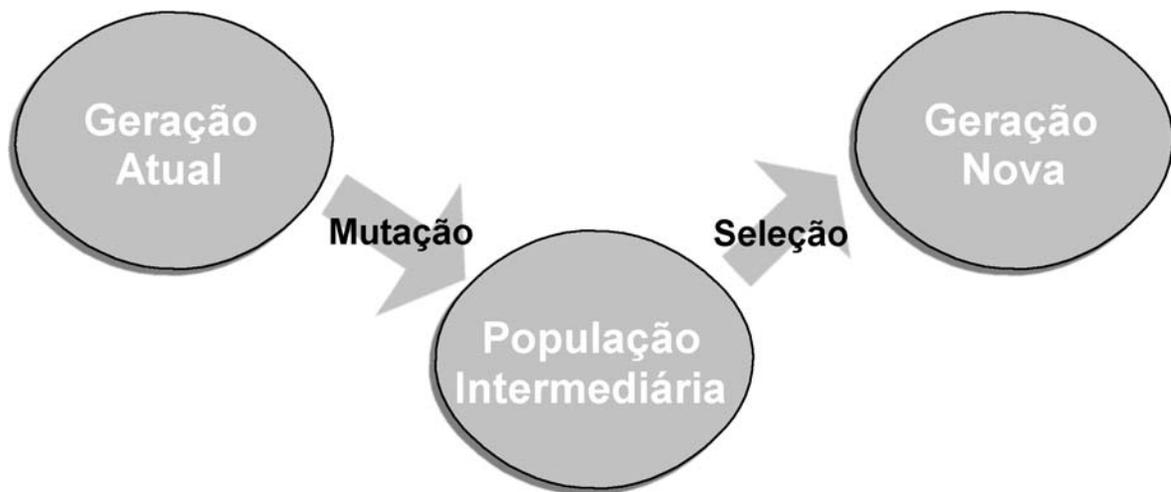


Fig. 4.6 – Ciclo básico da PE.

O algoritmo descrito na Tabela 4.1, que segue as indicações contidas em [6], possui um recurso importante: a *auto-adaptação* do parâmetro de controle do operador de mutação (o desvio padrão σ_i). A auto-adaptação de parâmetros em algoritmos evolucionários vem sendo apontada como decisiva no desempenho dessas estratégias, principalmente em ambientes não-estacionários. Isso porque os valores ideais para os parâmetros de um algoritmo evolucionário não são conhecidos a priori para um dado problema, requerendo, não raro, uma longa etapa de tentativa e erro para sintonizar o referido algoritmo. Além disso, os valores ideais para os referidos parâmetros, em geral, modificam-se à medida que as gerações se sucedem ao longo do processo de evolução da população. Na auto-adaptação, é deixada para o próprio algoritmo a tarefa de encontrar os melhores valores para seus parâmetros, através da associação de valores de aptidão não apenas aos indivíduos, mas também aos seus respectivos parâmetros de controle [82].

Também na Tabela 4.1, encontra-se descrito o procedimento de seleção na PE. Se, no AG, o operador de seleção é usado para definir os pares para cruzamento (cromossomos-pais), na PE, a seleção é usada para definir quais indivíduos, dentre pais e filhos, formarão a população da próxima geração. O procedimento de seleção é bastante simples: cada um dos pais e filhos é confrontado com um número q de oponentes, escolhidos aleatoriamente. Cada vez que o indivíduo testado possuir valor de aptidão superior ao seu oponente, aquele recebe uma *vitória*. Os pais e filhos são, então,

classificados de acordo com o número de *vitórias*. A metade mais vitoriosa sobrevive e a menos vitoriosa perece.

Um último comentário sobre a PE diz respeito aos aspectos de complexidade computacional e velocidade na obtenção do resultado final (taxa de convergência do algoritmo). Como, em outras estratégias evolucionárias, a capacidade de perseguir e encontrar o ótimo global de uma dada superfície de desempenho da PE advém da existência de um conjunto de soluções (população) e da maneira como essas soluções são atualizadas (operadores evolucionários), quanto maior o número de indivíduos de uma população, maior sua diversidade e maior as chances de se chegar a um resultado final (convergência do algoritmo) em um menor número de gerações. Entretanto, quanto maior o número de indivíduos por população, maior a complexidade computacional por geração. Em [82], é proposta uma maneira de aumentar a taxa de convergência da PE sem que seja necessário aumentar o número de indivíduos da população e conseqüentemente a complexidade computacional do sistema. A referida proposta consiste em modificar a expressão (a) do passo 3 na Tabela 4.1, substituindo-se a variável aleatória, que é do tipo Gaussiana, que realiza a mutação por uma variável aleatória do tipo Cauchy. Como a função densidade de probabilidade do tipo Cauchy tem um decaimento lateral menor do que a do tipo Gaussiana, a superfície de desempenho é mais explorada naquele caso do que neste para um determinado número de gerações. Portanto, consegue-se com a mutação do tipo Cauchy, para um dado número de indivíduos por população, o mesmo desempenho obtido com a mutação baseada na função de Gauss em um número menor de gerações. Em comparação à taxa de convergência do AG, há estudos que mostram que a PE converge mais rápido, não obstante o AG ser capaz de obter o mesmo resultado final desde que haja tempo de processamento disponível [27].

Tabela 4.1 – Programação evolucionária: algoritmo usado nas simulações do Capítulo 5

-
1. É gerada a população inicial de μ indivíduos e atribuído $l = 1$. Cada indivíduo i é representado pelo par (\mathbf{p}_i, σ_i) , no qual \mathbf{p}_i é o vetor de parâmetros a serem estimados e σ_i é o desvio padrão usado nas mutações do tipo Gaussiana. Essa é a população de pais.
 2. A aptidão de cada um dos pais (\mathbf{p}_i, σ_i) é avaliada, $\forall i \in \{1, \dots, \mu\}$.
 3. Cada pai (\mathbf{p}_i, σ_i) gera um filho $(\mathbf{p}'_i, \sigma'_i)$, de acordo com os passos seguintes:

Para $j = 1, K, P$,

 - a) $p'_i(j) = p_i(j) + N(0, \sigma_i)$
 - b) $\sigma'_i = \sigma_i \exp[\tau N(0, 1)]$

onde P representa o número total de parâmetros; $N(0, 1)$ é o número aleatório de distribuição Gaussiana de média zero e desvio padrão igual a 1; τ é uma constante.
 4. A aptidão de cada filho $(\mathbf{p}'_i, \sigma'_i)$ é calculada.
 5. Para cada indivíduo, considerando-se todos os pais e filhos, q oponentes são sorteados. Cada indivíduo é, então, comparado com seus q oponentes e sempre que a aptidão do indivíduo for maior ou igual à aptidão do seu oponente, o indivíduo ganha uma *vitória*.
 6. Dentre pais e filhos, μ indivíduos são selecionados, justamente aqueles que possuem maior número de vitórias, para formar a próxima geração de pais.
 7. Se o critério de parada adotado for satisfeito, o processamento se encerra, senão $l = l + 1$ e o algoritmo retorna ao passo (3).
-

4.4 Conclusões

Ao longo deste capítulo, foram abordadas as principais idéias que compreendem a computação evolucionária, tais como a presença de uma população de indivíduos (conjunto

de soluções candidatas) que se aprimora ao longo de gerações, visando a otimizar uma dada função, através de operadores inspirados nas idéias de adaptação e evolução naturais. As principais vantagens da computação evolucionária estão na grande probabilidade de encontrar o ótimo global e na possibilidade de se trabalhar com qualquer tipo de função (contínua, descontínua, discreta, unimodal, multimodal, etc.), e sua principal desvantagem reside no aumento de complexidade computacional em relação às estratégias mais tradicionais de otimização de funções.

Dois estratégias evolucionárias foram apresentados: *algoritmo genético* e *programação evolucionária*. As principais características dessas estratégias foram discutidas quanto aos seus efeitos e eficácia.

A *programação evolucionária* foi discutida mais amplamente, pois é a estratégia usada nas simulações do próximo capítulo, como ferramenta para otimização. Destacam-se, nesse particular, a descrição do algoritmo usado (Tabela 4.1) e algumas de suas características mais relevantes como a auto-adaptação do parâmetro de controle do operador de mutação, a não presença de operador de recombinação e a taxa de convergência maior do que a do AG.

5.1 Introdução

No presente capítulo, é apresentada uma das principais contribuições desta tese: uma crítica a favor da utilização de estratégias de otimização que sejam pouco sensíveis às condições iniciais, como por exemplo os algoritmos pertencentes à classe da computação evolucionária em sistemas de restauração de imagens sempre, que a função de controle da qualidade da estimação apresentar ótimos locais, apesar do aumento de complexidade computacional resultante de tal escolha.

Este procedimento considera o atual estado tecnológico e as perspectivas no desenvolvimento de microprocessadores como os elementos que permitem que estratégias de restauração cada vez mais elaboradas e complexas sejam, ou tornem-se, dentro em breve, exeqüíveis em termos de implementação.

As motivações que levaram à investigação que resulta na supracitada contribuição encontram-se na constatação de que, em geral, há algumas contradições entre a disponibilidade de um conjunto de ferramentas de otimização bastante amplo e a preferência pela adoção dos algoritmos mais simples e tradicionais, mesmo quando esses últimos são sabidamente inadequados para lidar com determinadas situações [4], [5], [51]. Essa contradição normalmente vem acompanhada do argumento de ser necessário buscar baixa complexidade computacional no processamento de imagens em função do volume de dados característico desse tipo de aplicação, bem como de procedimentos para tentar diminuir a referida contradição. Contudo, nesses procedimentos, algumas idéias elementares da heurística vêm sendo violadas [54], esquecendo-se, também, que modelos mais detalhados, justamente os que abrem a possibilidade de melhor qualidade no resultado do processamento, possuem uma contraparte que se expressa no aumento de

complexidade computacional. Ou seja, na busca do acréscimo de benefício, é natural aguardar também acréscimos de custo.

As discussões e simulações apresentadas a seguir têm por finalidade demonstrar que a utilização de estratégias de otimização sensíveis às condições iniciais em restauração de imagens não faz sentido, do ponto de vista teórico ou experimental, quando a função de controle do processo de otimização apresenta ótimos locais. A única justificativa seria a de razão tecnológica, mas, em virtude da atual relação entre custo e capacidade de processamento dos computadores, essa não se sustenta. Este capítulo encontra-se organizado como segue.

Na Seção 5.2, é apresentada uma discussão sobre as abordagens tradicionais na estimação paramétrica em sistemas de restauração de imagens, considerando as características do problema da restauração e dos algoritmos de otimização disponíveis.

Na Seção 5.3, são mostrados os resultados de dois experimentos: o primeiro compara restaurações obtidas a partir de um mesmo filtro, mas com duas estratégias de otimização diferentes; o segundo enfatiza a estabilidade dos resultados obtidos com algoritmos pouco sensíveis às condições iniciais quando da presença de ótimos locais na função a otimizar.

E, na Seção 5.4, são relacionadas as conclusões relevantes deste capítulo.

5.2 Considerações à abordagem tradicional de estimação em restauração de imagens

A restauração de imagens é considerada como um problema de difícil solução, caracterizado pelo mau-condicionamento, ou seja, um problema no qual pequenos desvios nos valores dos parâmetros do sistema acarretam grandes desvios no resultado do processamento [3]. Acrescente-se a isso o fato de que, na maior parte dos casos práticos, o *sistema de formação/degradação* da imagem que se deseja restaurar (Seção 2.2) é conhecido apenas de forma parcial, exigindo uma etapa, prévia ou concomitante à restauração propriamente dita, de estimação paramétrica [44]. Mesmo quando o conhecimento do sistema de formação/degradação é pleno, o processo de restauração em si é, na realidade, um procedimento de estimação, uma vez que seu objetivo é recuperar uma imagem original desconhecida a partir da sua versão degradada. Pelas razões apresentadas, em restauração de imagens, as etapas de estimação precisam ser cuidadosamente consideradas sob pena de se comprometer seriamente a qualidade do resultado do

processamento. Normalmente, os procedimentos de estimação resumem-se na otimização de certas funções, as quais quantificam a qualidade da estimação em questão.

No tocante à otimização de funções, há vários algoritmos desenvolvidos para tal tarefa [28], [54], [68]. Em cada um desses algoritmos, existe uma estratégia implícita de como encontrar os pontos ótimos em uma determinada superfície de desempenho, definida pela função a ser otimizada. Essa estratégia é elaborada, no mais das vezes, a partir de considerações sobre as características apresentadas pelas funções a otimizar. Como exemplo, pode-se citar os algoritmos baseados no gradiente das funções. Esses algoritmos só podem ser usados se:

- a) as funções a serem otimizadas forem contínuas;
- b) for possível derivar uma expressão para o gradiente da função.

Deve-se enfatizar assim que, em relação à otimização de funções, para cada tipo de função, deve ser escolhida a classe de algoritmos mais adequada, aquela para a qual se obtenha melhor relação custo-benefício. Dentre as possibilidades de classificação dos algoritmos de otimização, adotar-se-á nesta tese que os mesmos podem ser de dois tipos:

- a) *algoritmos muito sensíveis às condições iniciais*: aqueles que, uma vez estabelecidas suas estimativas iniciais, empreendem uma busca ao ponto ótimo localizado nas imediações daquelas estimativas (ótimo local). Esses algoritmos, quando encontram um ponto ótimo, devem ser interrompidos, pois não há possibilidade de que outro ponto ótimo seja estimado após convergência. Caso seja necessário explorar outras regiões da superfície de desempenho, definida pela função a ser otimizada, em busca de soluções mais satisfatórias do que aquelas estimadas até então, o algoritmo deve ser reinicializado com outras condições iniciais.
- b) *algoritmos poucos sensíveis às condições iniciais*: aqueles cuja capacidade de explorar a superfície de desempenho não está limitada à região localizada nas imediações das condições iniciais. Os *algoritmos pouco sensíveis*, portanto, são mais adequados do que os *muito sensíveis* quando as funções a serem otimizadas apresentam múltiplos ótimos locais.

Como exemplo de *algoritmos muito sensíveis*, pode-se citar todos aqueles baseados no gradiente da função a ser otimizada, bem como o clássico *Downhill Simplex Method* (DHSM) [68]. E, dentre os *pouco sensíveis*, destacam-se o *Arrefecimento Simulado*

(*Simulated Annealing* – SA) [68], os *Algoritmos Genéticos* (AG) [31] e a *Programação Evolucionária* (PE) [6], [7], [27], [28], [30].

Uma vez modelado o problema da restauração, em geral, o mesmo se reduz à otimização de uma função [4], [44], [41]. Portanto, a escolha da ferramenta usada nessa otimização deveria orientar-se segundo critérios de adequação da referida ferramenta às características da função a otimizar [54]. Contudo, há alguns conceitos e procedimentos relacionados à complexidade computacional em processamento de imagens que merecem ser reavaliados face ao estado científico e tecnológico atual.

A complexidade computacional sempre foi um aspecto de grande relevância em processamento de sinais, principalmente se os sinais em questão possuem mais de uma dimensão, como é o caso do sinal de imagem. Em restauração de imagens, como em outras áreas do processamento de imagem, a preferência tem sido por estratégias que tenham o menor custo computacional possível. Ocorre, todavia, que a preocupação e os sacrifícios em prol da menor complexidade parecem ter permanecido os mesmos ao longo de décadas de avanços tecnológicos. Certas posturas e decisões anteriormente corretas, pois faziam o equilíbrio entre o que seria bom do ponto de vista teórico e o realizável pelos processadores da época, mantêm-se na atualidade. Entretanto, modificada a relação *custo*×*poder de processamento* dos computadores atuais, a manutenção de certas concepções mostra-se anacrônica, dificultando a avaliação de desempenho e a obtenção de melhor qualidade em sistemas de restauração.

As considerações do restante deste capítulo têm por base a restauração de imagens via *Filtro de Kalman de Modelo de Ordem Reduzida* (*Reduced Order Model Kalman Filter* – ROMKF) (Seção 3.4.3) em um cenário quase autoditado (o conhecimento do sistema de formação/degradação não é pleno). Os parâmetros do filtro de restauração são estimados pela função (3.22), repetida a seguir para maior conveniência.

$$J = N \ln |R_{ee}| + \frac{1}{R_{ee}} \sum (\mathbf{v}_k - \mathbf{C}_k \hat{\mathbf{x}}_{k|k-1})^2, \quad (5.1)$$

onde N e R_{ee} representam o número de amostras da imagem degradada e a matriz de covariância do processo inovação, respectivamente; \mathbf{v}_k e \mathbf{C}_k são, respectivamente, o sinal

observado e a matriz de observação; e $\hat{\mathbf{x}}_{m|n}$ é a estimativa do vetor de estado em m , considerando os sinais observados de índice 0 a n (detalhes no Capítulo 3).

A função de estimação (5.1) é baseada no critério de *máxima verossimilhança* [60] e apresenta ótimos locais. Em [4] e [5], a ferramenta de otimização usada na restauração via ROMKF, em conjunção com (5.1), é do tipo *muito sensível às condições iniciais*. Mas, por que usar esse tipo de algoritmo se (5.1) sabidamente apresenta ótimos locais? A resposta parece ser *complexidade computacional*. Os autores em [4] e [5], cientes do conflito entre as características da função (5.1) e as do algoritmo de otimização, sugerem duas medidas para contornar o problema da convergência para ótimos locais usando:

- i) reduzir o número de parâmetros a ser estimado;
- ii) reinicializar o procedimento de restauração com diferentes condições iniciais, armazenando o resultado final de cada rodada e, ao término de um determinado número de reinícios, escolher a melhor imagem restaurada.

O item (i) é justificado na medida em que o número de ótimos locais mostra-se relacionado com o número de parâmetros a estimar. Essa almejada redução pode ser obtida adotando um modelo para a *Função de Espalhamento de Ponto (Point Spread Function – PSF)* [5].

O item (ii), contudo, é preciso ser considerado mais cuidadosamente. O sucesso esperado em obter o ótimo global, pretendido pela adoção do procedimento de reinicializar a restauração com diferentes condições iniciais, encontra-se alicerçado na *crença* de que, em determinado momento, um eventual sorteio resultará em uma estimativa inicial próxima o suficiente do ótimo global da função (5.1), de maneira que o procedimento de otimização seja capaz de encontrar aquele ponto ótimo.

Logo, em relação ao referido sorteio, o qual é decisivo para o procedimento (ii) sob análise, podem ocorrer duas situações: o sorteio que resulta em uma condição inicial próxima ao ótimo global não pode ocorrer em hipótese alguma; ou o referido sorteio ocorre em algum dos reinícios, sendo essa a situação esperada.

O sorteio desejado pode não ocorrer se a faixa de valores usada no sorteio das estimativas iniciais abranger uma região que não compreenda o ótimo global. A

dificuldade aqui reside em selecionar adequadamente a supracitada faixa, mas como fazer isso se os parâmetros são desconhecidos?

Supondo que o sorteio que resultará na convergência ao ótimo global ocorra em algum reinício (situação esperada), deve-se perguntar: *Quando, em qual reinício, é esperado esse sorteio bem-sucedido?* Esse questionamento é justo, pois é preciso interromper as restaurações em algum momento, mas quando? Será que 10, 100 ou 1000 restaurações são suficientes para que esse acreditado sorteio bem-sucedido ocorra? Se for considerado o número de parâmetros a estimar, a faixa de valores que esses parâmetros podem assumir e a resolução de suas representações, o conjunto de possibilidades pode ser extremamente grande para um dado número de ótimos locais. Na tentativa de contornar tal dificuldade, outro critério, centrado na qualidade subjetiva das restaurações, pode ser adotado: “quando uma restauração satisfatória, ou um conjunto delas, ocorrer, os reinícios são interrompidos e o melhor resultado é escolhido”. Nesse caso, é pertinente a seguinte pergunta: *essa imagem restaurada de qualidade satisfatória é o melhor que o sistema pode produzir?* As possibilidades decorrentes da incapacidade de se responder corretamente a essa última questão são duas: o sistema de restauração pode ser sub-utilizado; e o desempenho de bons sistemas de restauração pode ser mal avaliado, porque não se pôde verificar o quanto de melhoramento de qualidade os referidos sistemas conseguiram atingir. De qualquer forma, fica claro que, mesmo quando há possibilidade de que um sorteio bem sucedido das condições iniciais venha a se realizar, há grandes dificuldades a enfrentar. O fato de *ser possível obter* o ótimo global com reinícios não quer dizer que o mesmo *será obtido facilmente*.

As simulações da próxima seção apresentam resultados comprobatórios de que o procedimento descrito no item (ii) anteriormente citado (reinícios com diferentes condições iniciais a fim de perseguir o ótimo global) é ineficaz para contornar o problema da convergência aos ótimos locais da função (5.1) quando se usam estratégias muito sensíveis às condições iniciais.

5.3 Resultados experimentais

São apresentados os resultados para dois experimentos. O primeiro deles compara o desempenho do filtro ROMKF quando são usados, na etapa de estimação paramétrica,

algoritmos muito e pouco sensíveis às condições iniciais. Os resultados do segundo experimento reforçam as conclusões sobre a confiabilidade na avaliação da qualidade da restauração ROMKF com algoritmos pouco sensíveis às condições iniciais na etapa de estimação.

5.3.1 Primeiro experimento

O objetivo deste primeiro experimento é verificar a validade do procedimento (ii), sugerido em [4] e [5] e descrito na Seção 5.2. Para tal, esse experimento encontra-se definido da seguinte maneira:

- a) uma seção da imagem *cameraman* (Fig. 5.1) é degradada artificialmente por uma PSF conhecida, de dimensão 1×7 , do tipo movimento horizontal de câmera, descrita por (5.2). Ao resultado, é adicionado ruído do tipo Gaussiano, com variância ajustada para que a *Razão entre Sinal Degradado e Ruído (Blurred Signal to Noise Ratio – BSNR)* (5.3) [8] da imagem degradada seja igual a 40 dB (Fig. 5.2).



Fig. 5.1 – Seção da imagem *cameraman*, tomada neste experimento como imagem original.



Fig. 5.2 – Imagem degradada sinteticamente com PSF do tipo movimento horizontal de câmera de dimensão 1×7 e adição de ruído do tipo Gaussiano ($BSNR=40$ dB).

$$c(m) = \gamma^{-1} [1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1] , \quad (5.2)$$

onde $c(m)$ representa a PSF e γ é uma constante de normalização usada para que a condição de conservação de energia entre imagem original e imagem degradada, $\sum_{(m)} c(m) = 1$, seja satisfeita [3].

$$BSNR = 10 \cdot \log_{10} \left\{ \frac{\frac{1}{MN} \sum_{(m,n)} [v'(m,n) - \bar{v}]^2}{\sigma_{\eta}^2} \right\}, \quad (5.3)$$

onde $v'(m,n) = v(m,n) - \eta(m,n)$ e $\bar{v} = E[v'(m,n)]$. M e N são as dimensões da imagem $v'(m,n)$ e σ_{η}^2 é a variância do ruído de observação $\eta(m,n)$.

A $BSNR$ indica o quanto de ruído há na imagem degradada, de maneira que, quanto maior o valor de $BSNR$, menor a energia do ruído de degradação (maiores detalhes na Seção 6.2.1). A $BSNR$ de 40 dB é um valor típico, usado em experimentos de restauração, e traduz baixa energia de ruído presente na imagem degradada.

- b) É assumido que o modelo da PSF $c(m)$ (5.4) é conhecido, mas o seu parâmetro ρ , não. Além disso, é necessário que os parâmetros do *sistema de síntese da imagem* (detalhes na Seção 2.2) também sejam estimados. Considera-se, nesse conjunto de simulações, que os parâmetros relevantes do sistema de síntese da imagem são $a(1,1)$, $a(1,0)$, $a(1,-1)$ e $a(0,1)$, conforme a expressão (5.5). O suporte do vetor de estado reduzido é do tipo NSHP de dimensão $1 \times 6 \times 2$, ilustrado na Fig. 5.3. O processamento da imagem é feito da direita para a esquerda, de cima para baixo, as bordas da imagem original são usadas como condição de contorno para as transições entre linhas, e o elemento mais à direita do suporte do vetor de estado reduzido (em cinza na Fig. 5.3) é aproximado pelo método da *melhor estimativa* (detalhes na Seção 3.4.3). No caso em questão, a *melhor estimativa* é obtida do vetor de estado reduzido anterior. Os valores das covariâncias dos ruídos forma estimados usando os procedimentos descritos em [3], [4] e [5].

$$c(m) = \gamma^{-1} \begin{bmatrix} \rho^3 & \rho^2 & \rho^1 & \rho^0 & \rho^1 & \rho^2 & \rho^3 \end{bmatrix}, \quad (5.4)$$

$$x(m, n) = a(1,1)x(m-1, n-1) + a(1,0)x(m-1, n) + a(1,-1)x(m-1, n+1) + a(0,1)x(m, n-1) + \xi(m, n). \quad (5.5)$$

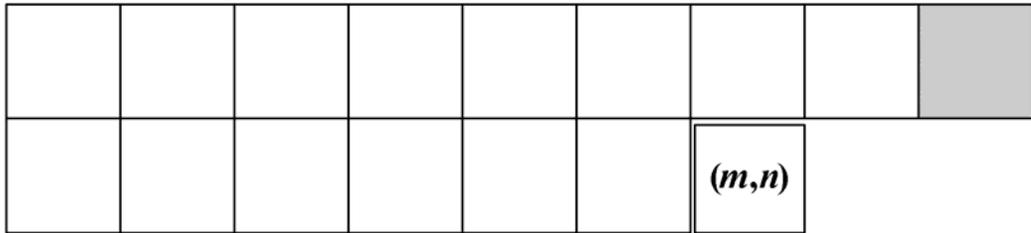


Fig. 5.3 – Suporte do tipo NSHP de dimensão $1 \times 6 \times 2$, usado nas simulações do primeiro experimento.

- c) São feitas 12 restaurações, usando, na etapa de estimação paramétrica, o DHSM [68]. Em cada uma das 12 restaurações, as condições iniciais são estabelecidas de maneira aleatória. As imagens e os dados numéricos resultantes são apresentados na Fig. 5.4 e Tabela 5.1, respectivamente. Na Tabela 5.1, os valores de J , expressão (5.1), são apresentados normalizados segundo (5.6), onde N representa o número de amostras processadas. A referida tabela mostra, também, a média e a variância dos parâmetros, bem como de J_N .

$$J_N = \frac{J}{N} \quad (5.6)$$



Fig. 5.4 – Imagens restauradas via ROMKF, usando DHSM, na etapa de estimação paramétrica, para condições iniciais aleatórias. A imagem da extrema esquerda na primeira linha é referente à

restauração de número 1. A imagem referente à restauração de número 2 é a imagem imediatamente à direita da número 1 e, assim, sucessivamente até a imagem da extrema direita na segunda linha que é referente à restauração de número 12.

Tabela 5.1 – Dados numéricos das restaurações via ROMKF, usando DHSM, na etapa de estimação paramétrica, para condições iniciais aleatórias

	$a(1,1)$	$a(1,0)$	$a(1,-1)$	$a(0,1)$	ρ	J_N
#01	0,31035	-0,69472	0,90250	0,21716	0,99046	4,743625
#02	0,23899	0,96636	0,52059	-0,51339	0,83044	5,245695
#03	0,67189	-0,64064	0,83805	-0,11378	0,86104	4,724094
#04	-0,45370	0,59559	-0,57010	0,84447	0,83828	5,354743
#05	-0,70228	0,45278	0,59557	0,46941	0,75180	5,155465
#06	-0,01136	0,52902	0,26073	0,09383	0,23852	5,501820
#07	-0,60733	0,32890	0,94333	0,34630	0,83795	4,158909
#08	-0,23030	-0,74834	0,98772	0,92737	0,39388	4,259856
#09	-0,98827	0,42075	0,82933	0,62908	0,38795	5,235955
#10	0,83470	0,06171	0,47259	-0,42171	0,77492	5,376441
#11	1,00000	-0,94995	0,57312	0,32174	0,51588	5,829082
#12	1,00000	0,37090	0,38281	-0,56548	0,44552	6,368608
Méd.	0,08855	0,05769	0,56131	0,18625	0,65555	5,162858
Var.	0,48229	0,41051	0,18232	0,25695	0,05934	0,390806

- d) São realizadas mais 12 restaurações, usando, na etapa de estimação paramétrica, a PE. É usado o algoritmo descrito na Tabela 4.1, com número de indivíduos por população igual a 20 ($\mu = 20$), número de oponentes igual a 10 ($q = 10$), número máximo de gerações por restauração é igual a 500 e $\tau = (\sqrt{2P})^{-1}$, onde P é o número de parâmetros a estimar ($P = 5$). A população inicial de cada uma das 12 restaurações é estabelecida de maneira aleatória. As imagens e os dados numéricos resultantes são apresentados na Fig. 5.5 e Tabela 5.2, respectivamente. A referida tabela mostra, também, a média e a variância dos parâmetros, bem como de J_N .



Fig. 5.5 – Imagens restauradas via ROMKF, usando PE, na etapa de estimação paramétrica, para condições iniciais aleatórias. A imagem da extrema esquerda na primeira linha é referente à restauração de número 1. A imagem referente à restauração de número 2 é a imediatamente à direita da número 1 e, assim, sucessivamente até a imagem da extrema direita na segunda linha que é referente à restauração de número 12.

Tabela 5.2 – Dados numéricos das restaurações via ROMKF, usando PE, na etapa de estimação paramétrica, para condições iniciais aleatórias

	$a(1,1)$	$a(1,0)$	$a(1,-1)$	$a(0,1)$	ρ	J_N
#01	-0,05908	0,21127	-0,11995	0,90271	1,00259	3,568225
#02	-0,10141	0,28611	-0,15303	0,90483	1,00324	3,569540
#03	-0,62967	0,24168	0,44305	0,87233	1,01195	3,549780
#04	0,08987	-0,09808	0,03766	0,90625	1,00346	3,567679
#05	0,19931	-0,37885	0,20616	0,90890	0,99939	3,573937
#06	-0,82696	0,56448	0,31436	0,88412	1,00982	3,550826
#07	-0,36165	0,14855	0,33030	0,79356	1,00509	3,562010
#08	-0,08734	-0,08179	0,24255	0,83889	1,01453	3,570651
#09	0,14332	-1,00349	0,88559	0,91839	1,00353	3,580147
#10	-0,06792	0,24199	-0,14315	0,90681	1,00387	3,568739
#11	-0,34373	-0,36336	0,75982	0,88452	1,01070	3,551167
#12	-0,25549	-0,45326	0,75533	0,88594	1,00965	3,552141
Méd.	-0,19173	-0,05706	0,29655	0,88394	1,00648	3,563737
Var.	0,09525	0,18631	0,13109	0,00126	$2,14 \times 10^5$	$1,065 \times 10^4$

Comentários:

Os dados numéricos (Tabelas 5.1 e 5.2) revelam que, quando se emprega a PE, na etapa de estimação paramétrica do sistema de restauração considerado, há como resultado estimativas de menor variância do que aquelas resultantes do DHSM.

As altas variâncias das estimativas no caso DHSM em relação ao caso PE devem-se à convergência daquele algoritmo aos ótimos locais do critério J_N e se traduzem nas diferenças marcantes apresentadas pelas imagens restauradas ilustradas na Fig. 5.4. Em contrapartida, as restaurações do caso PE (Fig. 5.5) apresentam diferenças tênues entre si, principalmente com relação à qualidade subjetiva.

Ressalta-se, também, que a melhor restauração usando DHSM, para os casos apresentados, tanto do ponto de vista numérico quanto subjetivo, é pior do que qualquer uma das restaurações obtidas usando PE.

Um fato a ser enfatizado é que o sistema de restauração (o modelo considerado, o número de parâmetros a estimar, a estratégia de estimação do elemento mais à direita do suporte do vetor de estado reduzido, a estratégia de transição entre linhas, etc.) é o mesmo para os dois casos considerados. As diferenças nos dois conjuntos de resultados devem-se, portanto, exclusivamente aos algoritmos usados na etapa de estimação paramétrica.

Se o sistema de restauração utilizado estivesse sob avaliação ou fosse usado em um caso prático de restauração, o conjunto de imagens obtido com DHSM não seria ilustrativo do quanto de melhoramento o referido sistema é capaz de produzir na imagem degradada. É fato que o uso da PE aumenta o custo computacional (em proporção direta ao número de indivíduos por população μ) em relação ao uso do DHSM. Entretanto, uma única realização do procedimento de restauração com PE é suficiente para produzir um resultado representativo daquilo que o sistema pode oferecer em termos de melhoria de qualidade. Em outras palavras, com PE, os reinícios podem ser descartados e, além disso, uma única realização gera uma restauração de qualidade equivalente à qualidade da melhor restauração que se pode obter com o sistema sob análise. Assim, de posse de uma restauração obtida com PE, pode-se avaliar adequadamente o sistema e proceder aos eventuais ajustes necessários no sentido de melhorar seu desempenho. Uma das principais

desvantagens de se usar DHSM, nesse caso, é que se pode ter um excelente sistema de restauração, bem modelado, mas cujo resultado do processamento tem sua qualidade dependente de um sorteio.

5.3.2 Segundo experimento

O objetivo deste experimento é verificar, através da observação da média e da variância de J_N das populações ao longo das gerações, que a qualidade dos resultados obtidos via ROMKF-PE é estável, ratificando a afirmação da seção anterior de que, neste caso, os reinícios podem ser descartados.

- a) A imagem *cameraman* (Fig. 5.6) é dividida em duas regiões de dimensões iguais: direita e esquerda. A região da esquerda é degradada artificialmente por uma PSF conhecida, de dimensão 1×7 , do tipo movimento horizontal de câmera, descrita em (5.2), enquanto a região da direita permanece inalterada. É adicionado ruído do tipo Gaussiano à imagem resultante. A variância do referido ruído é ajustada para que a *BSNR*, expressão (5.3), da imagem degradada seja igual a 40 dB (Fig. 5.7).



Fig. 5.6 – Imagem *cameraman*, tomada neste experimento como imagem original.



Fig. 5.7 – Imagem com lado esquerdo degradado sinteticamente com PSF do tipo movimento horizontal de câmera de dimensão 1×7 e lado direito inalterado. É adicionado ruído do tipo Gaussiano para $BSNR=40$ dB.

- b) São válidas as mesmas considerações do item (b) do *primeiro experimento* (ver Seção 5.3.1 (b)), repetidas aqui por conveniência. É assumido que o modelo da PSF $c(m)$ (5.4) seja conhecido, mas o seu parâmetro ρ , não. Além disso, é necessário que os parâmetros do *sistema de síntese da imagem* (detalhes na Seção 2.2) também sejam estimados. Considera-se, neste conjunto de simulações, que os parâmetros relevantes do filtro de síntese da imagem sejam $a(1,1)$, $a(1,0)$, $a(1,-1)$ e $a(0,1)$, conforme a expressão (5.5). O suporte do vetor de estado reduzido é do tipo NSHP de dimensão $1 \times 6 \times 2$, ilustrado na Fig. 5.3. O processamento da imagem é feito da direita para a esquerda, de cima para baixo, as bordas da imagem original são usadas como condição de contorno para as transições entre linhas, e o elemento mais à esquerda do suporte do vetor de estado reduzido é aproximado pelo método da *melhor estimativa* (detalhes na Seção 3.4.3).
- c) A imagem degradada é dividida em quatro regiões de dimensões iguais: Região I, acima e à esquerda; Região II, acima e à direita; Região III, embaixo e à esquerda; e Região IV, embaixo e à direita. A divisão da imagem degradada é necessária para que o sistema identifique e processe corretamente as seções degradadas e

não-degradadas. A divisão em quatro regiões é preferida em relação à divisão em duas regiões (esquerda e direita), porque resulta em restauração de melhor qualidade [84], [85], uma vez que, em regiões menores, o sistema de restauração consegue adaptar-se melhor às características locais da imagem. A divisão da imagem em regiões não pode ser, contudo, excessiva, sob pena de que regiões de dimensão muito reduzida não ofereçam riqueza estatística para estimativas de boa qualidade [4], [5], [60]. As quatro regiões são restauradas separadamente, sendo que a ordem de restauração é Região I, Região II, Região III e Região IV. São feitas 10 restaurações, usando, na etapa de estimação paramétrica, a PE, permanecendo as mesmas condições do *primeiro experimento*, repetidas a seguir: é usado o algoritmo descrito na Tabela 4.1, com número de indivíduos por população igual a 20 ($\mu = 20$), número de oponentes igual a 10 ($q = 10$), número máximo de gerações por restauração é igual a 500 e $\tau = (\sqrt{2P})^{-1}$, onde P é o número de parâmetros a estimar ($P = 5$). Ao início da restauração de cada região, uma nova população inicial é gerada de maneira aleatória. As Figs. 5.8, 5.9 e 5.10 mostram uma restauração típica; as curvas da média de J_N e valor de J_N do melhor indivíduo por população; a variância de J_N para cada geração, respectivamente.



Fig. 5.8 – Imagem restaurada típica, usando ROMKF-PE, dividindo a imagem degradada em 4 regiões para fins de processamento.

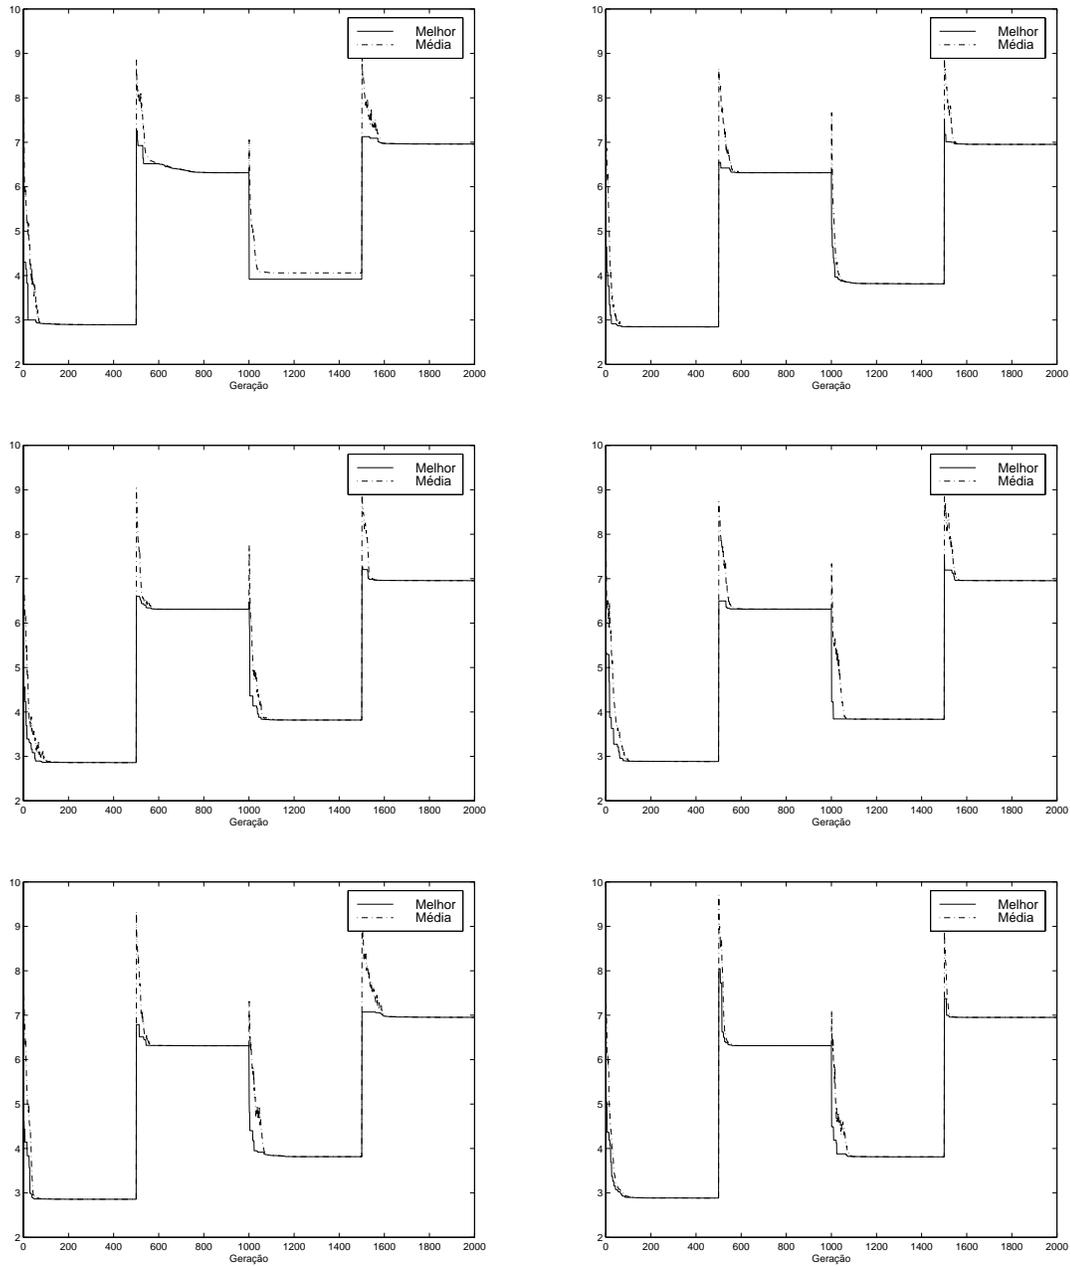


Fig. 5.9 (a) – Evolução da média de J_N da população por geração e valor de J_N do melhor indivíduo por geração. De cima para baixo, da esquerda para a direita, curvas correspondentes às restaurações de número 1 a 6, respectivamente.

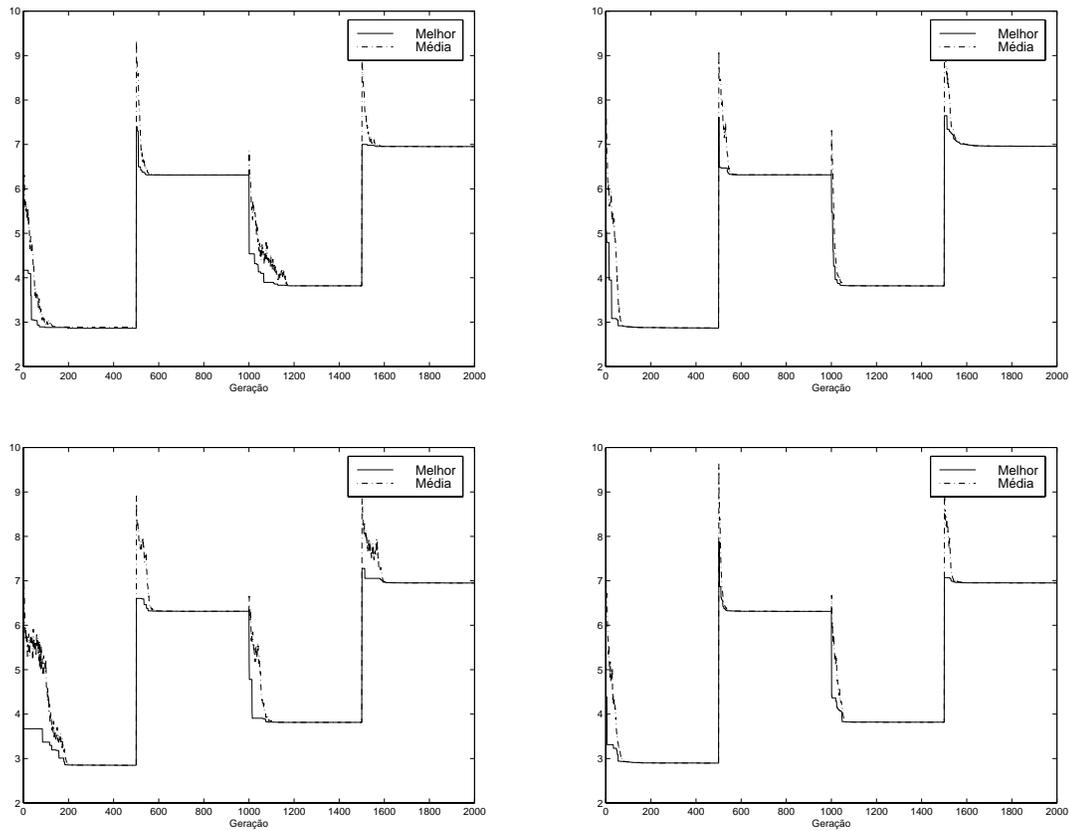


Fig. 5.9 (b) – Evolução da média de J_N da população por geração e valor de J_N do melhor indivíduo por geração. De cima para baixo, da esquerda para a direita, curvas correspondentes às restaurações de número 7 a 10, respectivamente.

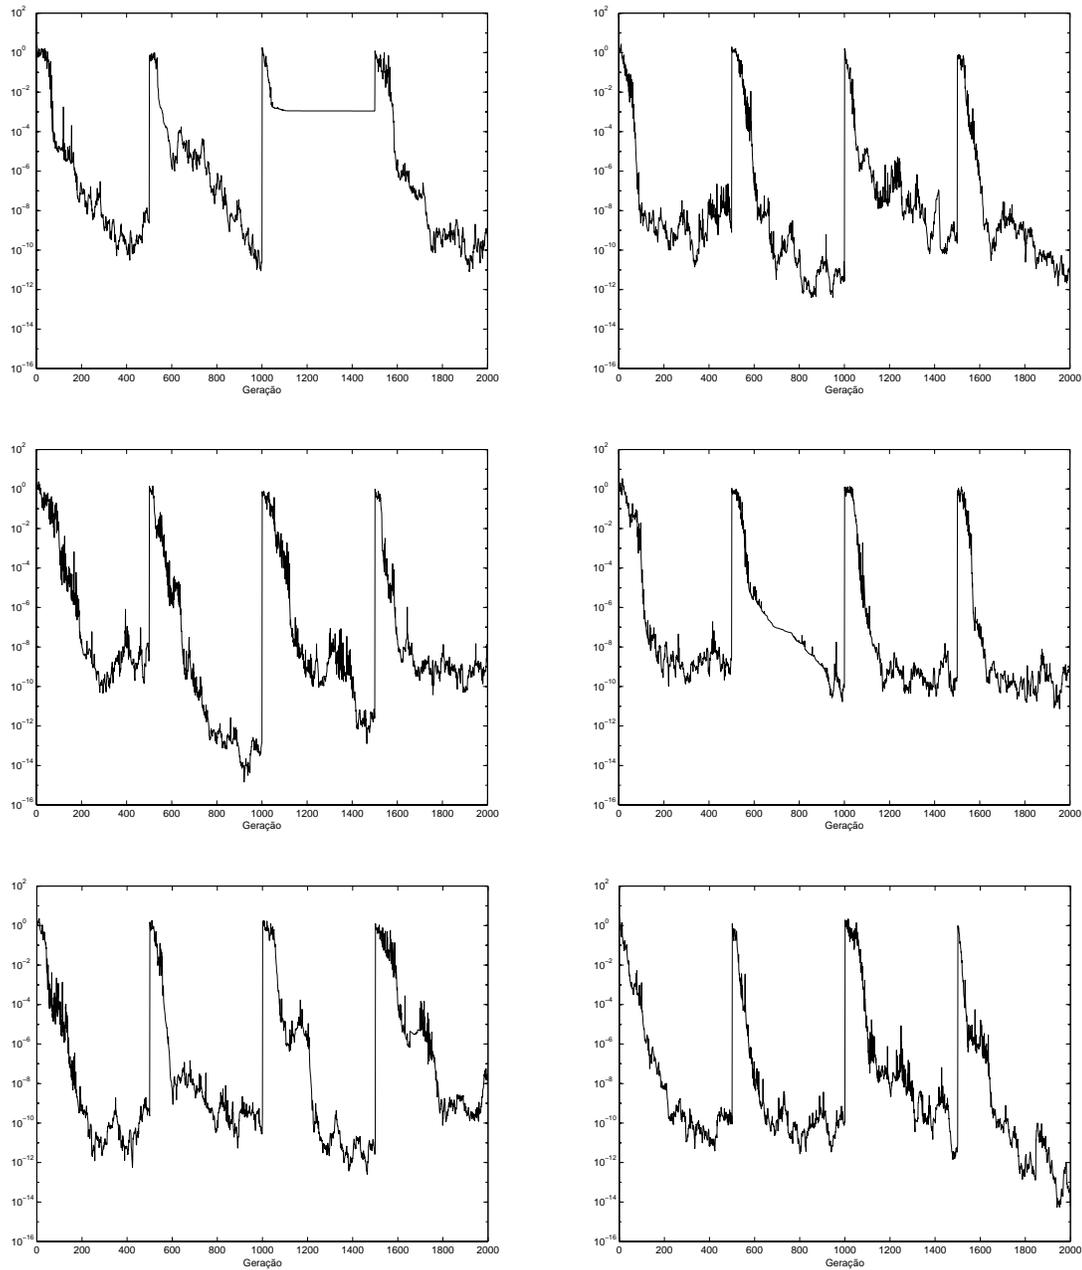


Fig. 5.10 (a) – Evolução da variância de J_N da população ao longo das gerações. De cima para baixo, da esquerda para a direita, curvas correspondentes às restaurações de número 1 a 6, respectivamente.

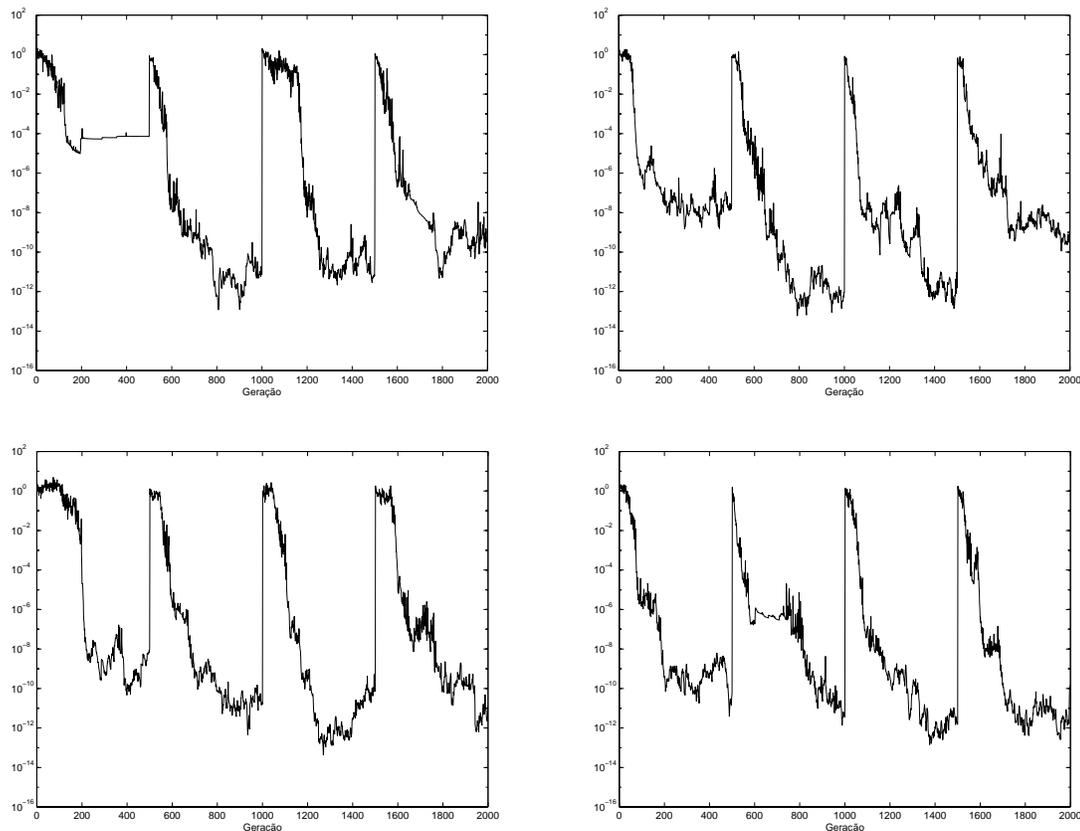


Fig. 5.10 (b) – Evolução da variância de J_N da população ao longo das gerações. De cima para baixo, da esquerda para a direita, curvas correspondentes às restaurações de número 7 a 10, respectivamente.

Comentários:

As curvas nas Figs. 5.9 e 5.10 retratam o comportamento da PE. As discontinuidades periódicas, presentes em todas as curvas, são devidas à mudança de uma região para outra da imagem a ser restaurada, quando há novo sorteio da população inicial.

Sobre a Fig. 5.9, deve-se notar o comportamento de especialização da população através da tendência da média de J_N em aproximar-se do valor de J_N do melhor indivíduo. Em outras palavras, a população evolui e tende para o melhor indivíduo. Outro aspecto relevante: os melhores indivíduos de cada região, em todas as 10 realizações, possuem valores de J_N muito próximos entre si, ratificando a confiabilidade, já comentada no

primeiro experimento, de que uma única restauração usando ROMKF-PE, na configuração definida, é representativa do melhor elemento do conjunto de possíveis resultados.

As curvas apresentadas na Fig. 5.10 também mostram a especialização da população ao longo das gerações. Essa especialização (população tendendo para o melhor indivíduo) é verificada pela diminuição da variância de J_N da população ao longo das gerações em uma mesma região da imagem degradada. A curva da variância de J_N não é tão suave quanto a da média de J_N devido às aleatoriedades dos operadores de mutação e seleção da PE, servindo, assim, para que, a despeito da especialização supracitada, a população mantenha um mínimo de diversidade que permita uma eventual transição na superfície de desempenho de J_N em busca do ótimo global.

5.4 Conclusões

Neste capítulo, foi apresentada uma discussão sobre o procedimento tradicional de utilizar estratégias de estimação *muito sensíveis às condições iniciais* em sistemas de restauração de imagens. A escolha desse tipo de estratégia de estimação é atribuída à necessidade de procurar diminuir ao máximo a complexidade computacional, principalmente em se tratando do processamento de sinais em duas dimensões, os quais apresentam grande volume de dados a serem tratados. Alguns autores sugerem, dentre outras medidas, que eventuais problemas com ótimos locais podem ser contornados, usando uma estratégia de *reinícios*, nos quais as condições iniciais são modificadas de maneira aleatória. Dentre as imagens obtidas, a melhor é tomada como restauração final.

As simulações apresentadas comparam restaurações obtidas via ROMKF-DHSM (*muito sensível às condições iniciais*) a ROMKF-PE (*pouco sensível às condições iniciais*). Essas simulações mostram que a estratégia de *reinícios* é inadequada para lidar com o problema de convergência aos ótimos locais, salvo em situações específicas, nas quais o número de ótimos locais é bastante reduzido. No caso geral, com o procedimento que usa *algoritmos muito sensíveis às condições iniciais e reinícios*, não se consegue saber quantos *reinícios* são necessários para se obter uma restauração satisfatória e nem se alguma das restaurações obtidas até então são representativas do melhor que o sistema pode oferecer em termos de melhoramento da qualidade. A utilização de *algoritmos pouco sensíveis às*

condições iniciais na etapa de estimação paramétrica confere ao sistema a confiabilidade de que uma única realização resulta em uma imagem restaurada representativa do melhor que o sistema de restauração pode oferecer. Dessa forma, o sistema de restauração pode ser melhor avaliado e ajustado. A desvantagem, nesse caso, está no aumento da complexidade computacional em relação à situação em que *algoritmos muito sensíveis* são usados. Entretanto, esse acréscimo de complexidade é compensado pela não-necessidade de *reinícios* no procedimento de otimização. Além disso, o resultado obtido através de *estratégias pouco sensíveis às condições iniciais* não é dúvida no que diz respeito a sua qualidade, que é representativa do melhor que se pode obter (ótimo global).

6.1 Introdução

Encontrar uma medida objetiva que represente a percepção humana da qualidade de uma imagem não é uma tarefa simples. Entram em cena as preferências pessoais, os aspectos culturais e orgânicos do observador, e as condições ambientais de visualização (iluminação, distância entre imagem e observador, tamanho e resolução do equipamento de visualização, etc.). Contudo, a busca de medidas coerentes com a percepção visual humana tem orientado os esforços de muitos pesquisadores, uma vez que os sistemas e algoritmos para tratamento de imagens para consumo humano necessitam ter seus desempenhos avaliados objetivamente. Áreas, como compressão/codificação, reforçamento, aquisição e, em particular, restauração de imagens, usam medidas de qualidade adaptadas às suas necessidades específicas.

Este capítulo apresenta as medidas de qualidade mais usadas na área de restauração de imagens, abrangendo as mais convencionais (baseadas em algum tipo de avaliação de energia dos sinais de interesse), bem como as mais recentes (que são desenvolvidas a partir de modelos do sistema visual humano).

Dentre as abordagens mais recentes, especial ênfase é dada à *medida de qualidade de ruído* (noise quality measure – *NQM*) e à *medida de distorção* (distortion measure – *DM*), métricas propostas em [23] em conjunto com uma nova metodologia de avaliação da qualidade de sistemas de restauração, na qual os efeitos de degradação referentes à distorção em frequência e injeção de ruído são considerados isoladamente. A fim de verificar se a *NQM* e a *DM* são de fato coerentes com a percepção visual humana, são realizados experimentos de avaliação subjetiva da qualidade de imagens.

Em função dos resultados obtidos para a *DM*, uma nova medida para avaliação de qualidade de imagens degradadas exclusivamente por distorção em frequência é proposta e validada experimentalmente: a *medida de qualidade de distorção (MQD)*.

Em seguida, é proposta uma nova métrica para avaliar a qualidade de uma imagem degradada pelos efeitos combinados de distorção em frequência e injeção de ruído. A referida métrica, denominada *medida de qualidade composta (MQC)*, é baseada na *NQM* e *MQD*, sendo seu modelo derivado a partir de avaliações subjetivas.

6.2 Medidas convencionais para avaliação da qualidade de uma imagem

As medidas convencionais para avaliação da qualidade de uma imagem são aquelas herdadas das áreas mais tradicionais do processamento de sinais e baseiam-se em alguma avaliação de energia dos sinais de interesse. A principal virtude desse tipo de medida está na baixa complexidade computacional envolvida em seu cálculo, prestando-se muito bem, portanto, às aplicações que exigem processamento veloz e, além disso, suas expressões são de fácil manipulação algébrica. A grande desvantagem dessa categoria de medidas reside na não representação adequada das características do sistema visual humano, bem como em não considerar as condições ambientais nas quais ocorre a visualização de uma imagem [23], [77].

As medidas convencionais mais usadas são apresentadas a seguir.

6.2.1 Razão entre Sinal e Ruído (Signal to Noise Ratio – SNR) [23], [67]

Bastante comum e conhecida também em outras aplicações, a *SNR* é calculada como sendo a razão entre a potência do sinal de interesse (sinal limpo, sem ruído) e a potência do ruído. A expressão da *SNR*, em dB, é apresentada em (6.1).

$$SNR = 10 \log_{10} \left\{ \frac{\sum_{(m,n)} s(m,n)^2}{\sum_{(m,n)} [s(m,n) - s_{\eta}(m,n)]^2} \right\}, \quad (6.1)$$

onde $s(m,n)$ e $s_{\eta}(m,n)$ representam a imagem sem ruído e contaminada, respectivamente.

6.2.2 Razão entre Pico do Sinal e Ruído (Peak Signal to Noise Ratio – PSNR) [23]

A *PSNR* é semelhante à *SNR*, mas, ao invés de usar a potência do sinal de interesse, usa o valor da máxima excursão do referido sinal. A *PSNR*, em dB, é dada por:

$$PSNR = 10 \log_{10} \left\{ \frac{P^2 MN}{\sum_{(m,n)} [s(m,n) - s_{\eta}(m,n)]^2} \right\}, \quad (6.2)$$

onde P , M e N denotam o valor da máxima excursão (pico-a-pico), a dimensão vertical e dimensão horizontal do sinal $s(m,n)$, respectivamente.

6.2.3 Razão entre Sinal Degradado e Ruído (Blurred Signal to Noise Ratio – BSNR) [8]

A *BSNR* quantifica a energia do ruído de degradação presente na imagem degradada. É definida, em dB, pela expressão (6.3).

$$BSNR = 10 \log_{10} \left\{ \frac{\frac{1}{MN} \sum_{(m,n)} [v'(m,n) - \bar{v}]^2}{\sigma_{\eta}^2}} \right\}, \quad (6.3)$$

onde $v'(m,n) = v(m,n) - \eta(m,n)$, sendo $v(m,n)$ e $\eta(m,n)$, a imagem degradada e o ruído aditivo presente em $v(m,n)$, respectivamente; $\bar{v} = E[v'(m,n)]$, sendo $E[\cdot]$ é o operador de expectativa; M e N são as dimensões vertical e horizontal da imagem $v'(m,n)$, respectivamente; σ_{η}^2 é a variância do ruído de observação $\eta(m,n)$.

A *BSNR* pressupõe a disponibilidade de uma versão da imagem degradada isenta da contaminação por ruído ou da sua variância, bem como da variância do ruído.

Quanto menor o valor da *BSNR*, maior a energia do ruído na imagem. Uma vez que o melhoramento da qualidade de uma imagem é dependente da energia do ruído na imagem degradada, a *BSNR*, em termos práticos, fornece um parâmetro sobre o que esperar do desempenho de um determinado sistema de restauração, bem como uma medida a partir da qual esse sistema possa ser avaliado.

6.2.4 Melhoria na Razão entre Sinal e Ruído (Improvement in Signal to Noise Ratio – ISNR) [8]

O *ISNR* tem por objetivo medir o quanto de melhoramento foi obtido no processo de restauração, usando para isso as imagens original, degradada e restaurada, como definido a seguir (em dB):

$$ISNR = 10 \log_{10} \left\{ \frac{\sum_{(m,n)} [x(m,n) - v(m,n)]^2}{\sum_{(m,n)} [x(m,n) - \hat{x}(m,n)]^2} \right\}, \quad (6.4)$$

onde $x(m,n)$ e $\hat{x}(m,n)$ representam a imagem original e a imagem restaurada (estimativa da imagem original), respectivamente.

Se for aplicado o operador de limite em (6.4), de maneira que a imagem restaurada tenda à imagem original ($\hat{x}(m,n) \rightarrow x(m,n)$), o *ISNR* tende ao infinito (6.5).

$$\lim_{\hat{x}(m,n) \rightarrow x(m,n)} ISNR = \infty. \quad (6.5)$$

Assim, quanto mais próxima a restauração estiver da imagem original, maior o valor de *ISNR*. Da mesma forma, se o *ISNR* for negativo, significa que a restauração está mais *distante* da imagem original em relação à imagem degradada e *ISNR* nulo indica que o filtro de restauração é equivalente ao filtro unitário, pois $\hat{x}(m,n) = v(m,n)$.

O *ISNR* pressupõe que a imagem original esteja disponível.

6.2.5 Discussão

Todas as medidas apresentadas nesta seção são baseadas em avaliações de energia e não incorporam as características do sistema visual humano, nem as condições do ambiente de visualização (tais como: iluminação, dimensão e resolução dos dispositivos de visualização, distância do observador, etc.). Portanto, é de se esperar que, sob certas circunstâncias, aliás freqüentes, essas métricas não representem adequadamente a percepção visual humana da qualidade de imagens.

A *BSNR* e o *ISNR* são usados para medir, respectivamente, ruído presente em imagens degradadas e desempenho de sistema de restauração, verificando, nesse último caso, o quanto a imagem restaurada está mais próxima da imagem original em relação à imagem

degradada. A *SNR* e a *PSNR*, diferentemente da *BSNR* e do *ISNR*, são medidas *genéricas*, podendo ser usadas tanto na avaliação de desempenho do sistema de restauração quanto na avaliação do nível de ruído presente na imagem degradada.

Todas as medidas para avaliação apresentadas pressupõem, contudo, a disponibilidade de sinais normalmente indisponíveis, tais como: imagem original, versão da imagem degradada sem ruído, etc. Resulta daí que essas métricas só podem ser usadas em condições ideais, em degradações sintéticas, para fins de avaliação de desempenho e descoberta de limitações nas estratégias de restauração.

6.3 Medidas da qualidade de uma imagem coerentes com a percepção humana

Há muito, sabe-se que as medidas baseadas somente na energia dos sinais de interesse não são adequadas para representar as não-linearidades e sensibilidades do sistema visual humano [67], [70], [77]. No entanto, a capacidade computacional dos processadores mais antigos e o elevado volume de dados inerente ao processamento de imagens estabeleciam grandes dificuldades à substituição das medidas de qualidade tradicionais por outras mais de acordo com a percepção humana.

A adoção destas novas métricas depende, contudo, de um outro fator: a pesquisa sobre a percepção humana, especificamente, sobre a percepção visual. Nesse particular, a elaboração de experimentos que quantifiquem as sutilezas do funcionamento do sistema neuro-óptico humano tem sido fundamental para a criação de modelos que possam ser eficazmente implementados e resultar em métricas viáveis [9], [10], [11], [15], [32], [40], [62], [63], [64], [71], [77], [78].

Os avanços, portanto, na pesquisa da percepção humana e na microeletrônica tornam cada vez mais comum o desenvolvimento de sistemas de processamento de imagens e, em particular, de restauração de imagens cada vez mais ajustados às características do sistema visual humano.

A seguir, são apresentadas algumas funções e métricas que modelam certos aspectos da percepção visual humana.

6.3.1 Função de Sensibilidade ao Contraste (Contrast Sensitivity Function – CSF) e Função de Limiar de Contraste (Contrast Threshold Function – CTF) [23]

Experimentos atestam que o sistema visual humano possui limiares de percepção dependentes da frequência espacial normalizada pelo ângulo de visualização [23]. A chamada *CTF* é uma função que modela esses limiares de percepção. Sua função inversa, denominada *CSF*, retrata, portanto, a sensibilidade do sistema visual às diferentes frequências espaciais angulares. Na literatura especializada, diversos modelos para a *CSF* e a *CTF* podem ser encontrados, provenientes de diferentes experimentos de avaliação da percepção visual [9], [10], [11]. Nas Figs. 6.1 e 6.2, são ilustradas, respectivamente, as curvas da *CSF* e *CTF* definidas a partir da expressão (6.6)¹.

$$CSF(f) = 2,6(0,0192 + 0,114f) \exp[-(0,114f)^{1,1}] , \quad (6.6)$$

onde f é a frequência espacial angular dada em ciclos/grau.

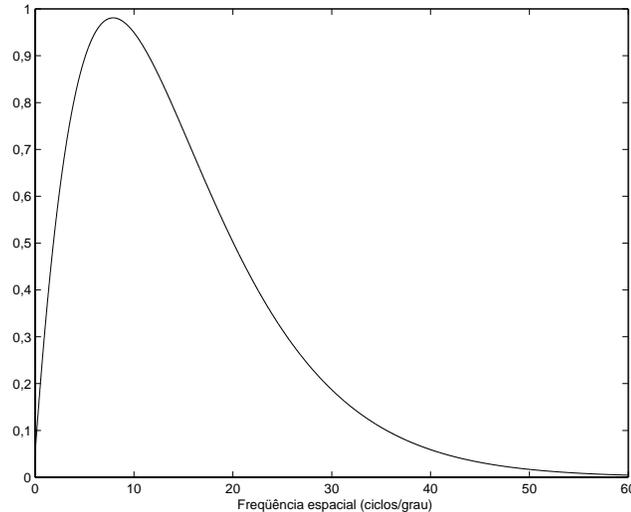


Fig. 6.1 – Curva da Função de Sensibilidade ao Contraste (Contrast Sensitivity Function – *CSF*).

¹ A expressão da *CSF*, tal qual apresentada em (6.6), tem amplitude máxima igual a 1 e mostra a sensibilidade ao contraste relativa, não a real. A curva da *CTF* real, apresentada na Fig. 6.2, tem expressão igual a $CTF(f) = [200 \cdot CSF(f)]^{-1}$

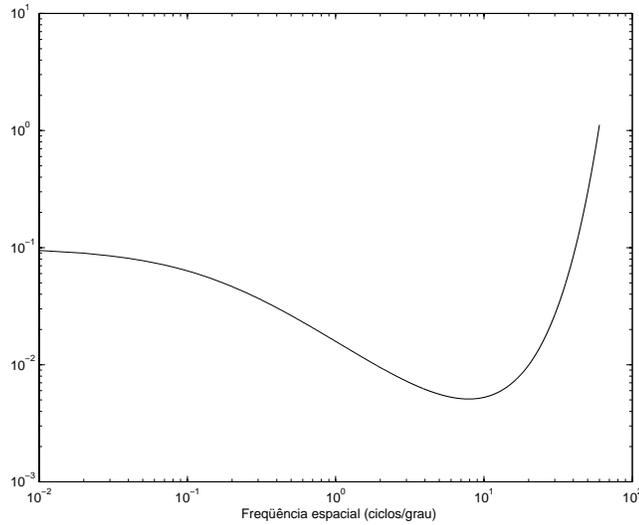


Fig. 6.2 – Curva da Função de Limiar de Contraste (Contrast Threshold Function – *CTF*) real.

A partir da *CTF* e da *CSF*, não apenas as características da percepção visual humana em si são modeladas, mas também outros elementos relativos ao ambiente de visualização podem ser considerados, como, por exemplo, distância entre imagem e observador, tamanho da imagem, resolução de monitores e impressoras, condições de iluminação, etc. Dessa forma, métricas de qualidade baseadas na *CTF* ou *CSF* tendem a refletir com maior fidelidade a qualidade visual percebida [9], [10], [11].

6.3.2 Razão entre Sinal e Ruído Ponderada (*Weighted Signal to Noise Ratio – WSNR*) [23]

A *WSNR* consiste na *SNR*, cujos sinais são ponderados no domínio da frequência pela *CSF*, tal como definido a seguir (em dB):

$$WSNR = 10 \log_{10} \left\{ \frac{\sum_{(\omega_1, \omega_2)} |CSF(\omega_1, \omega_2) \cdot S(\omega_1, \omega_2)|^2}{\sum_{(\omega_1, \omega_2)} |CSF(\omega_1, \omega_2) \cdot [S(\omega_1, \omega_2) - S_n(\omega_1, \omega_2)]|^2} \right\}, \quad (6.7)$$

onde ω_1 e ω_2 são as frequências espaciais; $S(\omega_1, \omega_2)$ e $S_\eta(\omega_1, \omega_2)$ são as transformadas de Fourier de $s(m, n)$ e $s_\eta(m, n)$ (ver Seção 6.2.1), respectivamente.

A *WSNR* enfatiza as frequências de maior importância segundo a *CSF*, mostrando-se, assim, mais adaptada do que a *SNR* para representar a percepção humana de qualidade. Através da *CSF*, a *WSNR* pode incorporar certas características do observador e do ambiente de observação, como já citado anteriormente (Seção 6.3.1). Um aspecto não atendido pela *WSNR* diz respeito ao *maskamento de contraste*, uma vez que o referido *maskamento* não é representado adequadamente pela *CSF*.

O *maskamento de contraste* é o fenômeno responsável pelo fato de, por exemplo, um mesmo sinal de ruído não ser percebido de maneira idêntica, quando a textura da imagem de fundo é modificada, considerando um mesmo observador.

A busca de maior fidelidade à percepção visual humana vem motivando a pesquisa no desenvolvimento de métricas que levem em conta as informações sobre o contraste de uma imagem.

6.3.3 Medidas de contraste

Contraste é um atributo essencial para percepção de qualidade de imagens. Entretanto, as métricas de contraste, quando comparadas entre si, geram resultados discordantes e quando comparadas com a percepção humana, em sua maioria, são incapazes de representá-la adequadamente [63].

As raízes destes problemas residem nas definições das medidas de contraste. Algumas dessas foram definidas a partir de padrões simples como, por exemplo, sinais periódicos ou pontos luminosos em fundos uniformes. Além disso, essas medidas associam um valor de contraste para toda a imagem. Como exemplos, pode-se citar a métrica de Michelson [23], [62] e Weber-Fechner [23], [62], expressas em (6.8) e (6.9), respectivamente.

$$C_M = \frac{L_{\max} - L_{\min}}{L_{\max} + L_{\min}}, \quad (6.8)$$

onde C_M , L_{\max} e L_{\min} representam o contraste de Michelson, a luminância máxima e a luminância mínima, respectivamente.

$$C_w = \frac{\Delta L}{L} , \quad (6.9)$$

onde C_w , ΔL e L indicam, respectivamente, o contraste de Weber-Fechner, a variação de luminância na imagem e a luminância do fundo uniforme.

A idéia básica das métricas mais simples (luminâncias que sobressaem em fundo uniforme) é aproveitada na elaboração de medidas mais consistentes para representar contraste em imagens complexas, como as métricas de Hess and Pointer e a de Peli (assim como as derivadas desta última), abordadas a seguir.

Hess e Pointer [23] definem contraste como sendo:

$$C_{HP}(\omega_1, \omega_2) = \frac{2 \cdot S(\omega_1, \omega_2)}{S(0, 0)} , \quad (6.10)$$

onde $C_{HP}(\omega_1, \omega_2)$ é a medida de contraste definida no espaço de frequências; $S(\omega_1, \omega_2)$ é a transformada de Fourier do sinal que se deseja analisar e $S(0, 0)$, sua componente DC.

O contraste de Hess and Pointer, contudo, não permite avaliar as variações de contraste entre diferentes posições espaciais de uma imagem sob análise.

Em [62], Peli sugere uma métrica que avalia localmente o contraste usando banco de filtros. Os filtros usados por Peli, chamados de filtros do tipo passa-banda log-cosseno, são definidos segundo (6.11).

$$G_i(f) = \frac{1}{2} \{1 + \cos[\pi \log_2(f) - \pi i]\} , \quad (6.11)$$

onde f é a frequência radial do filtro (dada em ciclos/imagem) e i é o índice de sintonia do filtro (sintonizado para frequências centradas em 2^i ciclos/imagem).

Para calcular o contraste, a imagem a ser analisada é decomposta pelos filtros $G_i(f)$, anteriormente descritos, sintonizados para diferentes valores de i , segundo (6.12):

$$S_i(\omega_1, \omega_2) = S(\omega_1, \omega_2) \cdot G_i(\omega_1, \omega_2) , \quad (6.12)$$

onde $S(\omega_1, \omega_2)$ e $S_i(\omega_1, \omega_2)$ são, respectivamente, a transformada de Fourier da imagem que se deseja calcular o contraste e a transformada de Fourier da imagem resultante da filtragem.

Em seguida, a imagem de saída de cada um dos filtros $G_i(f)$ é dividida pelo somatório das imagens de saída dos filtros $G_j(f)$, onde $j < i$. Ou seja:

$$c_i^p(m, n) = \frac{s_i(m, n)}{l_i(m, n)}, \quad (6.13)$$

onde $c_i^p(m, n)$ é o contraste na banda centrada em 2^i ; $s_i(m, n)$ é a transformada inversa de $S_i(\omega_1, \omega_2)$; $l_i(m, n)$ é dado por:

$$l_i(m, n) = l_0(m, n) + \sum_{k=1}^{i-1} s_k(m, n), \quad (6.14)$$

onde l_0 é a imagem resíduo de baixa frequência, resultante do procedimento de análise da imagem $s(n, m)$ pelo banco de filtros $G_i(\omega_1, \omega_2)$.

Os filtros $G_i(\omega_1, \omega_2)$ têm peculiaridades pelas quais foram escolhidos, a saber: largura de banda de uma oitava, simetria logarítmica no eixo das frequências e somatório de suas respostas igual à unidade (Fig. 6.3).

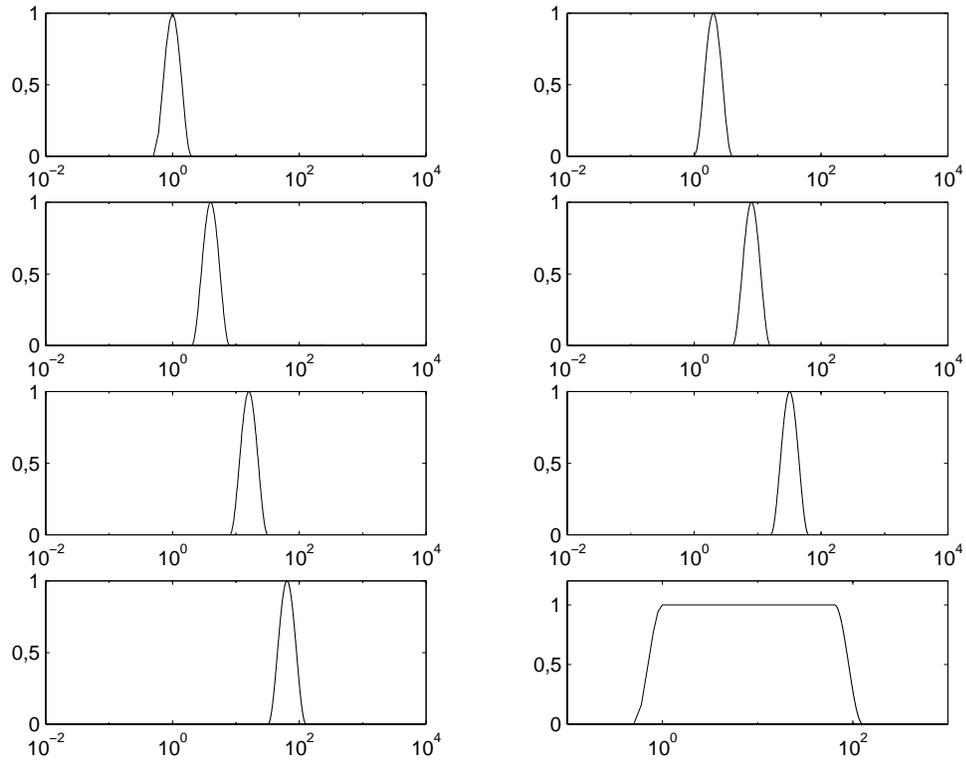


Fig. 6.3 – Resposta em frequência de filtros do tipo $G_i(f)$ para diferentes valores de i . Da esquerda para a direita, de cima para baixo: $i=0$, $i=1$, $i=2$, $i=3$, $i=4$, $i=5$ e $i=6$. Na última curva (embaixo, à direita), é mostrado o somatório das curvas anteriores.

Pelo exposto, pode-se observar que a medida de contraste de Peli reúne informação proveniente tanto do domínio da frequência quanto da seqüência. Além disso, diferente do que é feito nas medidas de contraste abordadas até então, o contraste de Peli não associa um valor de contraste para toda a imagem em avaliação, mas um valor de contraste para cada amostra da referida imagem, para cada banda centrada em 2^i ciclos/imagem.

Posteriormente, Lubin modifica a medida proposta por Peli (Contraste de Peli-Lubin) [63], a fim de que essa mesma medida ajuste-se melhor à percepção de contraste verificada em experimentos subjetivos. A modificação de Lubin consiste em calcular $l_i(m,n)$ não mais segundo (6.14), mas de acordo com (6.15):

$$l_i(m, n) = l_0(m, n) + \sum_{k=1}^{i-2} s_k(m, n) . \quad (6.15)$$

Outras modificações são propostas [63], incluindo um novo conjunto de imagens filtradas na tentativa de refinar ainda mais o casamento entre métrica e percepção do contraste. Esse novo conjunto de imagens é obtido pela filtragem das imagens contraste $c_i^{\text{PL}}(m, n)$ por filtros que implementam a transformação de Hilbert. É definida, então, uma nova métrica, denominada *energia de contraste*:

$$E_i(m, n) = \{c_i^{\text{PL}}(m, n)^2 + H[c_i^{\text{PL}}(m, n)]^2\}^{1/2} , \quad (6.16)$$

onde $E_i(m, n)$ é a energia de contraste para o filtro $G_i(u, v)$ sintonizado em 2^i ciclos/imagem; $c_i^{\text{PL}}(m, n)$ é a imagem contraste de Peli-Lubin para a mesma banda centrada em 2^i ciclos/imagem; $H[\cdot]$ representa a transformação de Hilbert.

Em [63], são realizados experimentos atestando que (6.16) é a métrica que melhor representa a percepção subjetiva do contraste, considerando, dentre outras medidas, as apresentadas neste capítulo.

6.3.4 Tratamento em separado dos efeitos da distorção em frequência e amplificação de ruído

Em [23], é proposta uma mudança metodológica na avaliação de sistemas de restauração de imagens. Essa mudança consiste em considerar, na restauração obtida, os efeitos de distorção em frequência e injeção de ruído de maneira isolada, o que não era feito até então pelas abordagens de avaliação de qualidade da restauração como, por exemplo, as que usam o *ISNR* e o *SNR*. As razões para essa mudança metodológica estão na impossibilidade, existente nas abordagens de avaliação até então usadas, de identificar de que maneira e em quais níveis o sistema de restauração afeta os componentes em frequência e a injeção de ruído na imagem restaurada, bem como de que forma esses fatores contribuem na percepção da qualidade. Assim, na metodologia proposta, são usadas duas medidas para avaliar um sistema de restauração: uma para quantificar a distorção em frequência entre restauração e imagem original; e outra para quantificar a injeção de ruído entre imagens restaurada e original. Essa dupla avaliação permite saber como a distorção

em frequência e a injeção de ruído são afetadas pela variação dos parâmetros de um sistema de restauração, auxiliando no ajuste desses parâmetros de maneira a maximizar a qualidade da restauração.

Essa metodologia de avaliação é ilustrada na Fig. 6.4.

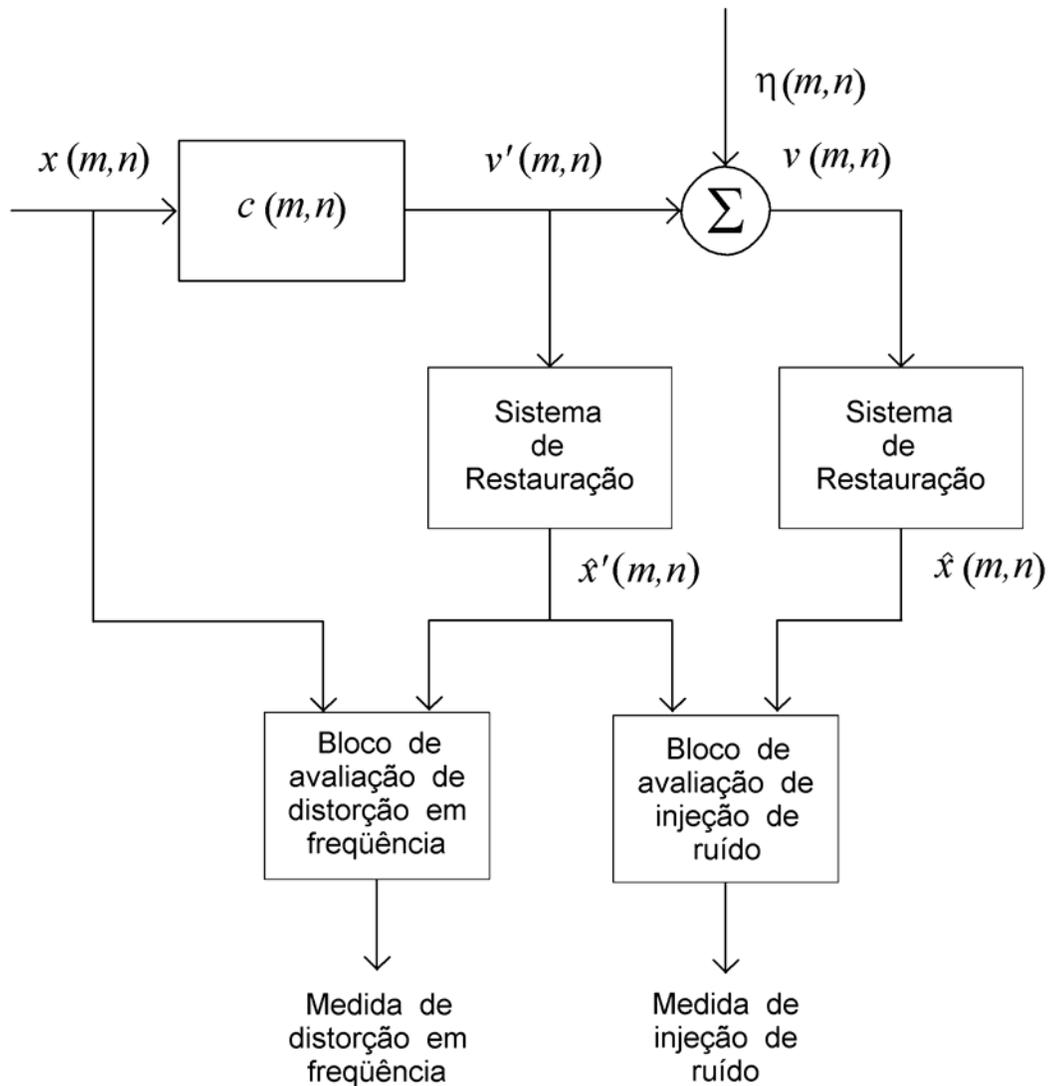


Fig. 6.4 – Estrutura de avaliação de um sistema de restauração de imagens em que os efeitos de distorção em frequência e injeção de ruído são considerados isoladamente.

Na Fig. 6.4, é observado que, para a avaliação de injeção de ruído, são usadas as imagens $\hat{x}(m,n)$ e $\hat{x}'(m,n)$, respectivamente, imagem restaurada e imagem modelo. Esta última é uma versão isenta de ruído da imagem restaurada e é definida como:

$$\hat{x}'(m,n) = R[x(m,n) * c(m,n)] , \quad (6.17)$$

onde $R[\cdot]$ e $c(m,n)$ denotam, respectivamente, a operação de restauração e a PSF do filtro de degradação. O símbolo $*$ representa a operação de convolução em duas dimensões.

O cálculo da distorção em frequência utiliza $x(m,n)$ e $\hat{x}'(m,n)$, imagem original e imagem modelo, respectivamente.

Pode-se notar que a metodologia em questão também requer sinais que, nos casos práticos de restauração, não se encontram disponíveis, assim como as outras estratégias já abordadas (Seções 6.2.1, 6.2.1, 6.2.2, 6.2.4 e 6.3.2).

6.3.5 Medida de Distorção (Distortion Measure – DM) e Medida de Qualidade de Ruído (Noise Quality Measure – NQM)

A *DM* e a *NQM* são duas medidas propostas em [23] para avaliação de distorção em frequência e injeção de ruído, respectivamente, e são obtidas segundo a metodologia apresentada na seção anterior.

A *DM* (em dB) é definida por:

$$DM = 20 \log_{10} \sum_{(\omega_1, \omega_2)} \left| \left[1 - \frac{\hat{X}'(\omega_1, \omega_2)}{X(\omega_1, \omega_2)} \right] CSF(\omega_1, \omega_2) \right| , \quad (6.18)$$

onde $\hat{X}'(u,v)$ e $X(u,v)$ indicam, respectivamente, a transformada de Fourier da imagem modelo e da imagem original.

A *DM* avalia a *distância* da função de transferência do sistema de aquisição/restauração, $\hat{X}'(u,v)/X(u,v)$, em relação ao filtro passa-tudo, ponderada pela *CSF*.

A *NQM*, em dB, é definida como:

$$NQM = 10 \log_{10} \left\{ \frac{\sum_{(m,n)} O_s^2(m,n)}{\sum_{(m,n)} [O_s(m,n) - I_s(m,n)]^2} \right\} , \quad (6.19)$$

onde $O_s(m,n)$ e $I_s(m,n)$ são denominadas versões sintetizadas da imagem modelo e imagem restaurada, respectivamente.

As versões sintetizadas são calculadas segundo (6.20) e (6.21):

$$O_s(m,n) = l_0^O(m,n) + \sum_{k=1}^K s_k^O(m,n), \quad (6.20)$$

$$I_s(m,n) = l_0^I(m,n) + \sum_{k=1}^K s_k^I(m,n), \quad (6.21)$$

onde $l_0^O(m,n)$ e $l_0^I(m,n)$ são as imagens residuais de baixas frequências das imagens modelo e restaurada, respectivamente; $s_k^O(m,n)$ e $s_k^I(m,n)$ representam as saídas modificadas dos filtros log-cosseno sintonizados em 2^k ciclos por imagem, tendo por entradas as imagens modelo e restaurada, respectivamente; K representa o índice do filtro de mais alta frequência usada na análise das imagens modelo e restaurada.

A fim de que a NQM possa caracterizar corretamente o mascaramento do ruído pelas regiões de diferente contraste da imagem, o cálculo de $s_k^O(m,n)$ e $s_k^I(m,n)$, tal como apresentado em [62], é modificado. Assim, após a obtenção dos $s_k^O(m,n)$ e $s_k^I(m,n)$ para as diferentes bandas definidas pelos valores de k , são calculados os valores de contraste $c_k^{PO}(m,n)$ e $c_k^{PI}(m,n)$, de acordo com (6.13). Em seguida, como o interesse é por regiões cujos contrastes estejam acima do limiar de percepção, ou seja, que possam ser discernidos, calcula-se o referido limiar para cada uma das frequências de sintonia dos filtros de análise, como mostrado em (6.22).

$$t_k = CTF\left(\frac{2^k}{\alpha}\right), \quad (6.22)$$

onde t_k é o limiar de percepção para a frequência de sintonia definida pelo índice k e α é o ângulo de visualização em graus.

O ângulo α , por sua vez, é definido como:

$$\alpha = 2\text{tg}^{-1}\left(\frac{w}{2d}\right), \quad (6.23)$$

onde w e d são, respectivamente, o comprimento da imagem e a distância entre o observador e a imagem. A expressão (6.23) pode ser aproximada para $\alpha \approx \frac{w}{d}$ quando $w \ll 2d$.

Os efeitos de mascaramento para contrastes acima do limiar são tratados como se segue:

a) calcula-se o limiar de discriminação de contraste, $T_k(m, n)$, segundo (6.24), [15], [23]:

$$T_k(m, n) = CTF(k) \left\{ 0,86 \left[\frac{c_k^P(m, n)}{CTF(k)} - 1 \right] + 0,3 \right\}; \quad (6.24)$$

b) ajustam-se os valores de $s_k^I(m, n)$ de acordo com (6.25):

$$s_k^I(m, n) = s_k^O(m, n), \quad \forall (m, n) \in D_k, \quad (6.25)$$

onde D_k é definido como:

$$D_k = \left\{ (m, n) : \left| c_k^{PI}(m, n) - c_k^{PO}(m, n) \right| - T_k(m, n) < 0 \right\}; \quad (6.26)$$

c) finalmente são aplicados os limiares globais segundo (6.27) e (6.28):

$$s_k^O(m, n) = 0, \quad \forall (m, n) \in V_k^O, \quad (6.27)$$

$$s_k^I(m, n) = 0, \quad \forall (m, n) \in V_k^I, \quad (6.28)$$

onde V_k^O e V_k^I são definidos como:

$$V_k^O = \left\{ (m, n) : \left| c_k^{PO}(m, n) \right| - t_k < 0 \right\}, \quad (6.29)$$

$$V_k^I = \left\{ (m, n) : \left| c_k^{PI}(m, n) \right| - t_k < 0 \right\}. \quad (6.30)$$

Realizados os ajustes em $s_k^O(m, n)$ e $s_k^I(m, n)$ de acordo com (6.22)–(6.30), retorna-se para (6.20) e (6.21), calculam-se as versões sintetizadas $O_s(m, n)$ e $I_s(m, n)$ e, então, procede-se ao cálculo de NQM em (6.19).

6.3.6 Discussão

A *WSNR* é uma métrica de avaliação de qualidade superior às convencionais, pois há ponderação no domínio da frequência de modo a enfatizar aqueles componentes relevantes para a percepção humana. A função de ponderação (*CSF*) pode incorporar não só características do sistema visual humano, mas também elementos referentes ao ambiente de visualização. A desvantagem da *WSNR* está na impossibilidade de representar os efeitos de contraste, fundamentais na percepção da qualidade.

Dentre as medidas usadas para mensurar o contraste de uma imagem, destacam-se as conhecidas como Contraste de Peli [62] e Contraste de Peli-Lubin [63], por serem as mais adequadas, segundo experimentos realizados [63] para representar a percepção subjetiva de imagens complexas.

Recentemente [23], uma nova metodologia de avaliação de qualidade foi proposta para aplicações em restauração de imagens, na qual, para cada restauração, são medidos os efeitos de distorção em frequência e injeção de ruído, separadamente. Ainda em [23], de acordo com a metodologia proposta, são apresentadas a *DM* e a *NQM*, sendo ambas baseadas em modelos do sistema visual humano. A *NQM* apresenta uma maior fidelidade com a percepção subjetiva da qualidade, relacionada com a injeção de ruído, do que a *WSNR*, pois é capaz de caracterizar o mascaramento do contraste em função das texturas presentes na imagem.

Uma questão que permanece em aberto nessa nova metodologia é a relação entre distorção em frequência e injeção de ruído na composição de uma métrica única.

6.4 Avaliação das medidas de qualidade *NQM* e *DM* em relação à qualidade subjetiva

Com o objetivo de verificar se uma determinada medida de qualidade de imagem representa adequadamente a percepção humana, são necessários testes, comparando medidas objetivas e avaliações subjetivas. Nesta seção, são avaliadas as medidas *NQM* e *DM*, propostas em [23]. O experimento de avaliação consiste em apresentar um conjunto de imagens a um grupo de voluntários, para que classifiquem as referidas imagens quanto à qualidade. Na definição do experimento, uma determinada imagem pode ser classificada como sendo de qualidade *excelente*, *boa*, *regular*, *ruim* ou *inadmissível*, correspondendo a cada uma dessas classes, respectivamente, os valores 4, 3, 2, 1 e 0. Cada imagem é

classificada por um determinado número de voluntários e a média das classificações daquela imagem é calculada. Essa média é, então, comparada com os valores de NQM e DM daquela imagem, verificando se há concordância ou não entre as medidas e as classificações subjetivas. As imagens usadas têm dimensão 256×256 e são apresentadas em um monitor 15", de resolução 800×600 pixels. A distância de visualização das imagens é de 60 cm. Os voluntários são de ambos os sexos, possuem idade variando entre 20 e 50 anos, e visão perfeita ou corrigida. A ordem de apresentação das imagens a serem avaliadas é aleatória, sendo as referidas imagens apresentadas ao avaliador antes da avaliação propriamente dita, de maneira breve, para que esse avaliador tenha um referencial da qualidade do conjunto. O procedimento de avaliação é dividido em duas etapas: avaliação da NQM e avaliação da DM .

6.4.1 Avaliação da NQM

A avaliação da validade de NQM é feita tomando-se uma imagem, considerada como a imagem original, e adiciona-se ruído a essa imagem. O ruído usado foi do tipo Gaussiano com média nula. As diferentes imagens do conjunto a ser avaliado foram obtidas modificando-se a variância do ruído injetado, sendo produzidas um total de nove imagens com diferentes valores de NQM . A variância do ruído injetado, na produção das referidas nove imagens, assume valores iguais a 1%, 2%, 4%, 8%, 16%, 32%, 64%, 128% e 256% da variância da imagem original. Como a NQM já tem sido devidamente avaliada em [23], inclusive sendo comparada com outras medidas: a SNR e a $WSNR$ para diversas tipos de ruído. Nesta seção, é verificado que a NQM concorda com a percepção humana de qualidade quando uma degradação pode ser modelada exclusivamente pela adição uniforme (em toda a imagem) de ruído do tipo Gaussiano. Além disso, os experimentos mostram que a percepção média de qualidade pode ser considerada diretamente proporcional à NQM .

A imagem escolhida como imagem original é apresentada na Fig. 6.5.



Fig. 6.5 – Imagem original do experimento de avaliação da NQM (Imagem “Lena”).

Participaram deste experimento 7 voluntários, cada um dos quais avaliou todas as imagens do conjunto produzido. A média das avaliações é apresentada na Fig. 6.6.

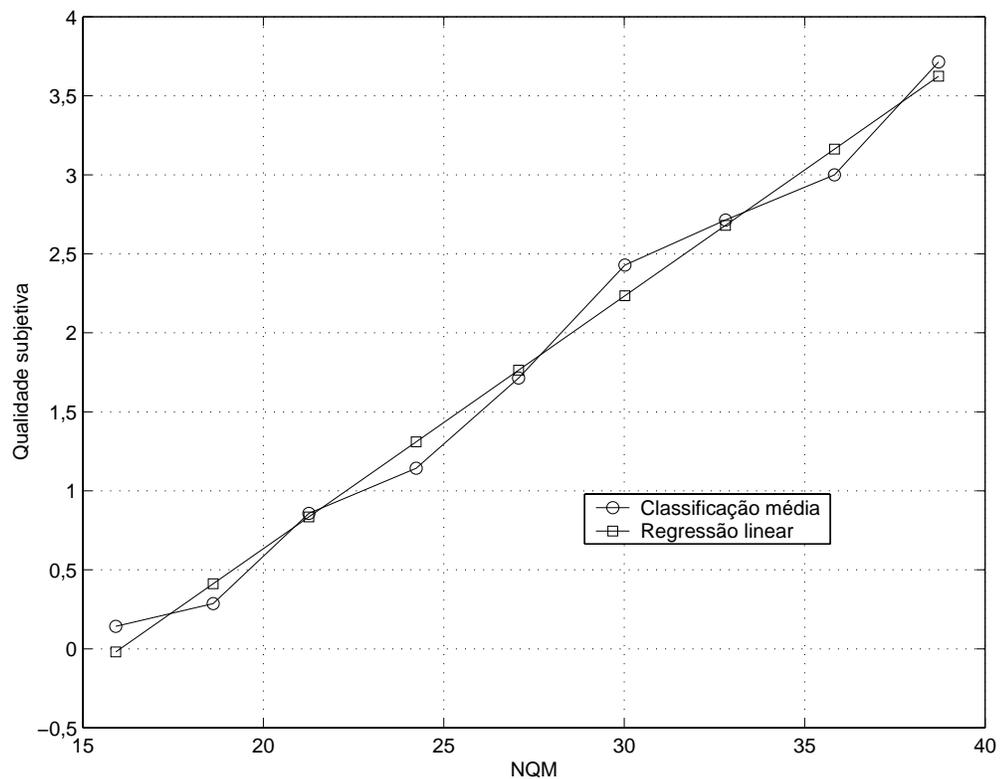


Fig. 6.6 – Avaliação da NQM .

Na Fig. 6.6, é também apresentada uma curva calculada por regressão linear, a partir dos dados obtidos experimentalmente. O coeficiente de correlação r [60] entre as curvas da Fig. 6.6 é $r = 0,9942118$, o que justifica dizer que a percepção média de qualidade de uma imagem contaminada exclusivamente por ruído uniforme, aditivo, do tipo Gaussiano varia linearmente com a NQM .

6.4.2 Avaliação da DM

A DM é proposta para quantificar a qualidade de uma imagem, cuja degradação é exclusivamente devida à distorção em frequência, mas a referida métrica não é validada experimentalmente em [23]. Nesta seção, são apresentados resultados atestando que a DM não se mostra adequada para representar a qualidade subjetiva de uma imagem com distorções em frequência.

Para tanto, foram produzidos 4 conjuntos de 9 imagens, a partir das imagens mostradas nas Figs. 6.7, 6.8, 6.9 e 6.10, consideradas com sendo as imagens originais do experimento. Cada conjunto é formado pela imagem resultante da filtragem de uma das imagens originais por 9 filtros diferentes, representados por $F_1(f)$, $F_2(f)$, $F_3(f)$, $F_4(f)$, $F_5(f)$, $F_6(f)$, $F_7(f)$, $F_8(f)$ e $F_9(f)$, e definidos como segue.

$$F_1(f) = \mathcal{G}_0^{\mathcal{O}}(f) + \sum_{i=0}^7 G_i(f), \quad (6.31)$$

$$F_2(f) = 1 - G_7(f), \quad (6.32)$$

$$F_3(f) = 1 - G_6(f), \quad (6.33)$$

$$F_4(f) = 1 - G_5(f), \quad (6.34)$$

$$F_5(f) = 1 - G_4(f), \quad (6.35)$$

$$F_6(f) = \mathcal{G}_0^{\mathcal{O}}(f) + \sum_{i=0}^6 G_i(f), \quad (6.36)$$

$$F_7(f) = \mathcal{G}_0^{\mathcal{O}}(f) + \sum_{i=0}^5 G_i(f), \quad (6.37)$$

$$F_8(f) = \mathcal{G}_0^{\mathcal{O}}(f) + \sum_{i=0}^4 G_i(f), \quad (6.38)$$

$$F_9(f) = \hat{G}_0^9(f) + \sum_{i=0}^3 G_i(f), \quad (6.39)$$

onde $G_i(f)$ denota os filtros log-cosseno definidos em (6.11) e $\hat{G}_0^9(f)$ é um filtro do tipo passa-baixas, definido segundo (6.40), a fim de que o somatório de sua resposta com a dos filtros log-cosseno permaneça igual à unidade (ver Seção 6.3.3).

$$\hat{G}_0^9(f) = \begin{cases} 1 - G_0(f), & 0 \leq f \leq 1 \\ 0, & \text{outro caso} \end{cases} \quad (6.40)$$

Cada uma das 36 imagens produzidas foi classificada 7 vezes por voluntários.



Fig. 6.7 – Imagem original #01 usada no experimento de avaliação da *DM* (Imagem “Lena”).

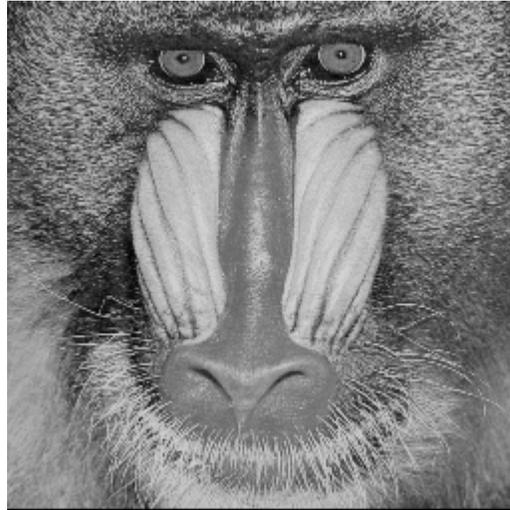


Fig. 6.8 – Imagem original #02 usada no experimento de avaliação da *DM* (Imagem “Baboon”).



Fig. 6.9 – Imagem original #03 usada no experimento de avaliação da *DM* (Imagem “Peppers”).



Fig. 6.10 – Imagem original #04 usada no experimento de avaliação da *DM* (Imagem “Bridge”).

As médias da classificação das imagens para os conjuntos avaliados são apresentadas, função da *DM*, na Fig. 6.11.

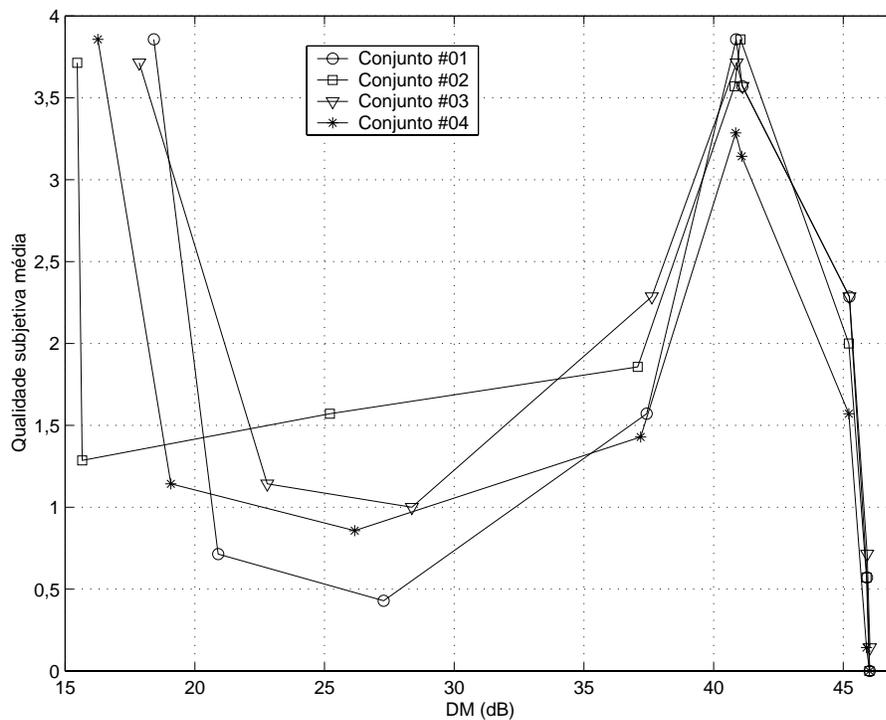


Fig. 6.11 – Avaliação da *DM*, para os conjuntos de imagens gerados a partir das imagens originais #01, #02, #03 e #04.

As curvas apresentadas na Fig. 6.11 mostram um padrão consistente de aumento e diminuição da qualidade percebida, função dos valores de DM . No entanto, de acordo com a definição da DM (6.18), as curvas na Fig. 6.11 mostram-se contraditórias com o esperado, ou seja, quanto menor a DM melhor a qualidade percebida. Pode-se notar que o padrão obtido experimentalmente revela que imagens com DM entre 100 e 120 são avaliadas como de melhor qualidade do que imagens com DM entre 20 e 80, por exemplo. Em outras palavras, em alguns casos, imagens com maior distorção, segundo a DM , apresentam melhor qualidade. A fim de que a DM pudesse ter utilidade prática, deveria ser observada uma relação monotônica entre a qualidade percebida e a referida medida sob avaliação.

A incoerência observada nos resultados de avaliação da DM é atribuída à própria definição de tal medida (6.18), a qual restringe-se ao domínio da frequência, deixando à parte os efeitos resultantes das distorções em frequência no domínio da seqüência (espacial), domínio no qual efetivamente as imagens são visualizadas e avaliadas. Na próxima seção, uma medida para avaliação de distorções em frequência que considera os efeitos resultantes no domínio da seqüência (domínio espacial) é apresentada, bem como os resultados experimentais que a validam.

6.5 Proposta e validação experimental de uma medida para distorção em frequência:

Medida de Qualidade para Distorção em Frequência (MQD)

Nesta seção, é apresentada uma métrica denominada *Medida de Qualidade para Distorção em Frequência (MQD)*, que avalia os efeitos resultantes no domínio da seqüência decorrentes da distorção nos componentes em frequência de uma imagem. A opção de definir a MQD no domínio espacial advém do interesse em incluir as medidas de contraste que apresentam melhor desempenho. Esse interesse é justificado pelo fato de que toda imagem degradada por distorção em frequência exhibe alterações de contraste em relação à imagem original. Inicialmente, pensou-se que talvez o contraste em si poderia ser a própria métrica almejada. Entretanto, os experimentos feitos com diversas medidas de contraste (Peli, Peli-Lubin, Peli+filtros de quadratura e Peli-Lubin+filtros de quadratura) mostram que o contraste sozinho não é, também, uma medida adequada. Todavia, os referidos experimentos reforçam a importância de se incluir o contraste em tal métrica. Até

o momento, a medida que mais se ajusta às avaliações subjetivas consiste em usar o mesmo procedimento para calcular a NQM (6.19)-(6.30), substituindo $\hat{x}(m,n)$ e $\hat{x}'(m,n)$ por $\hat{x}'(m,n)$ e $x(m,n)$, respectivamente (ver Fig. 6.4). As curvas apresentadas a seguir foram obtidas a partir das avaliações subjetivas de qualidade de distorção de frequência anteriormente usadas na avaliação da DM . No presente caso, para cada imagem, estão associados dois elementos: a MQD e a qualidade subjetiva média. Os resultados são ilustrados nas Figs. 6.12, 6.13, 6.14 e 6.15, nas quais estão os dados referentes aos conjuntos obtidos a partir das imagens originais #01, #02, #03 e #04, respectivamente.

Sobreposta aos dados de cada conjunto, foi traçada uma reta, obtida por regressão linear. Os coeficientes de correlação entre as retas e os dados são $r_1 = 0,9871579$, $r_2 = 0,9681562$, $r_3 = 0,9825474$ e $r_4 = 0,9688865$, respectivamente, para os conjuntos #01, #02, #03 e #04.

As Figs. 6.12, 6.13, 6.14 e 6.15 e os coeficientes de correlação supracitados mostram que a percepção humana média de qualidade de uma imagem degradada exclusivamente por distorção em frequência pode ser convenientemente aproximada por uma reta em função da MQD .

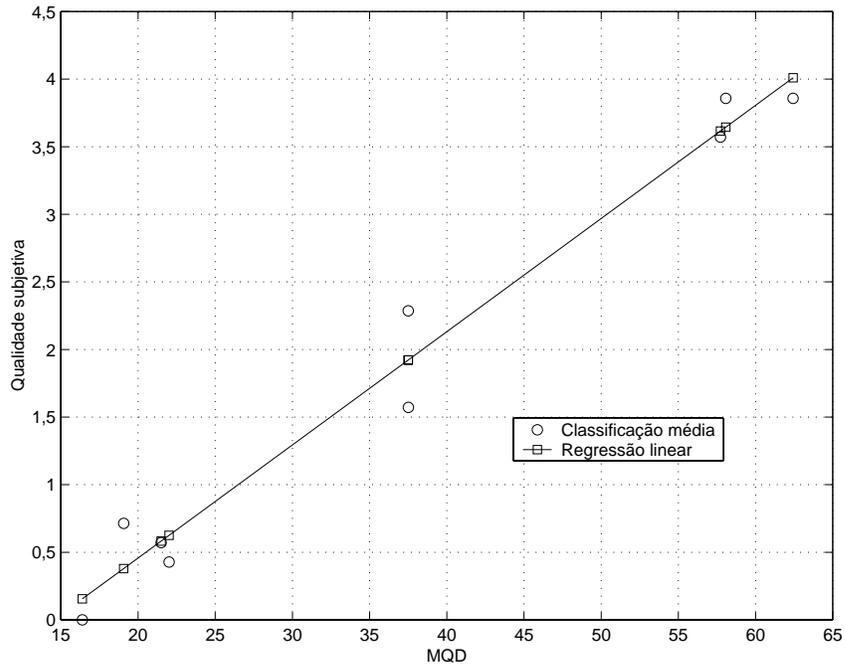


Fig. 6.12 – Avaliação da *MQD* para o conjunto obtido a partir da imagem original #01.

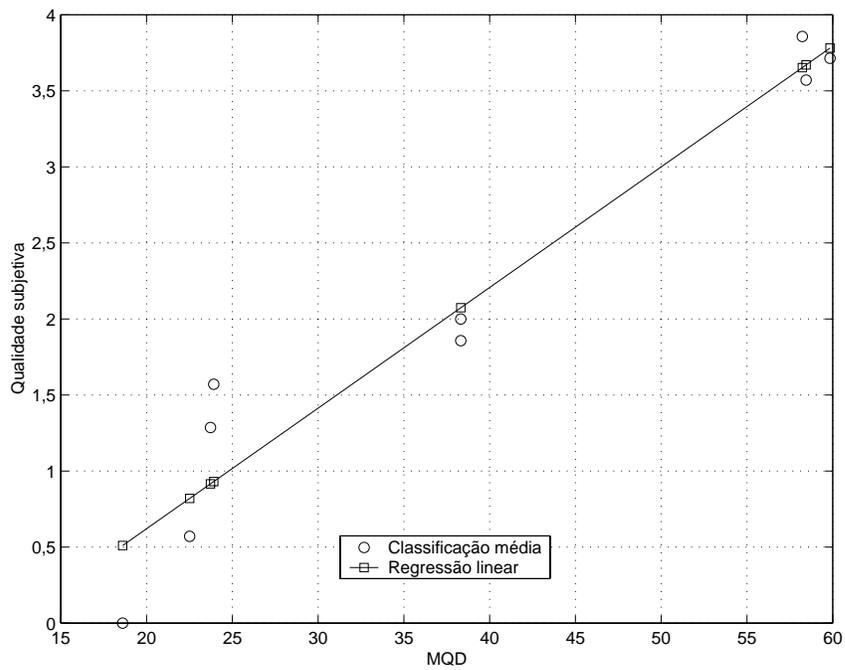


Fig. 6.13 – Avaliação da *MQD* para o conjunto obtido a partir da imagem original #02.

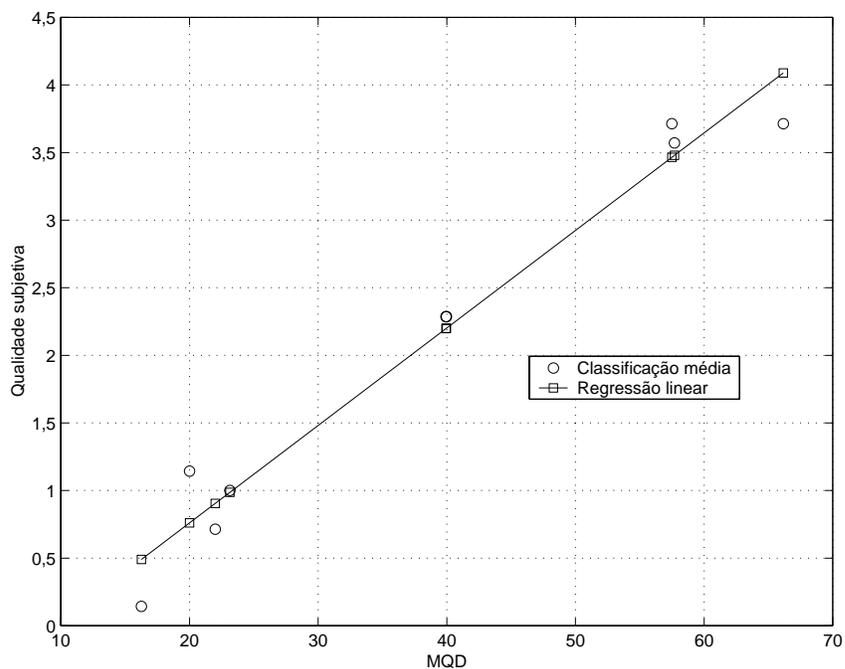


Fig. 6.14 – Avaliação da *MQD* para o conjunto obtido a partir da imagem original #03.

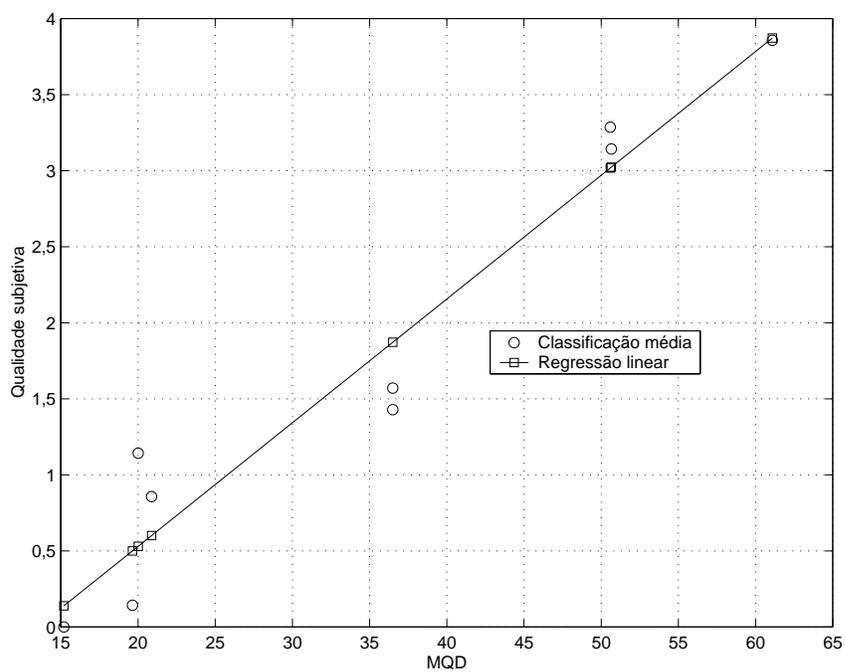


Fig. 6.15 – Avaliação da *MQD* para o conjunto obtido a partir da imagem original #04.

6.6 Proposta e validação experimental de uma medida de qualidade composta

Nas duas seções anteriores, as imagens usadas nas avaliações apresentavam degradações devidas ou à distorção em frequência ou à injeção de ruído. Entretanto, nas situações práticas, o mais comum é que as degradações de uma imagem sejam causadas por uma combinação dos dois fatores supracitados.

Em [23], é salientado o fato de não se ter disponível uma métrica de qualidade que combine os efeitos de distorção em frequência e injeção de ruído. Nesta seção, a partir de avaliações subjetivas, é proposta uma medida objetiva da qualidade de uma imagem, baseada na NQM e MQD , na qual os efeitos de distorção em frequência e injeção de ruído são combinados.

O experimento usado para obter os dados possui as mesmas características que os anteriores. Contudo, o conjunto de imagens avaliado foi produzido a partir da imagem ilustrada na Fig. 6.7 (Imagem “Lena”), a qual foi degradada por uma combinação de injeção de ruído em diferentes níveis e distorção em frequência, como descrito nas Seções 6.4.1 e 6.4.2, respectivamente.

Ao todo, 81 imagens foram usadas nessa avaliação e cada uma dessas imagens foi classificada 7 vezes por voluntários. As imagens eram apresentadas aleatoriamente para classificação. A média das classificações de cada imagem em função de métricas para distorção em frequência e injeção de ruído são ilustradas nas Fig. 6.16 e 6.17. Na Fig. 6.16, a média das classificações é apresentada em função da DM e da NQM , enquanto, na Fig. 6.17, em função da MQD e da NQM .

Na Fig. 6.16, pode-se observar novamente a inconsistência da DM como medida de qualidade, pois o mesmo comportamento verificado na Seção 6.4.2 se repete aqui, ou seja, pontos da superfície de avaliação possuindo determinados valores para DM têm qualidade inferior a outros pontos de menor DM .

Em contrapartida, a mesma avaliação apresentada em função da MQD e da NQM apresenta uma superfície mais coerente, na qual os valores mais baixos de MQD e NQM se traduzem em imagens de mais baixa qualidade e *vice-versa*.

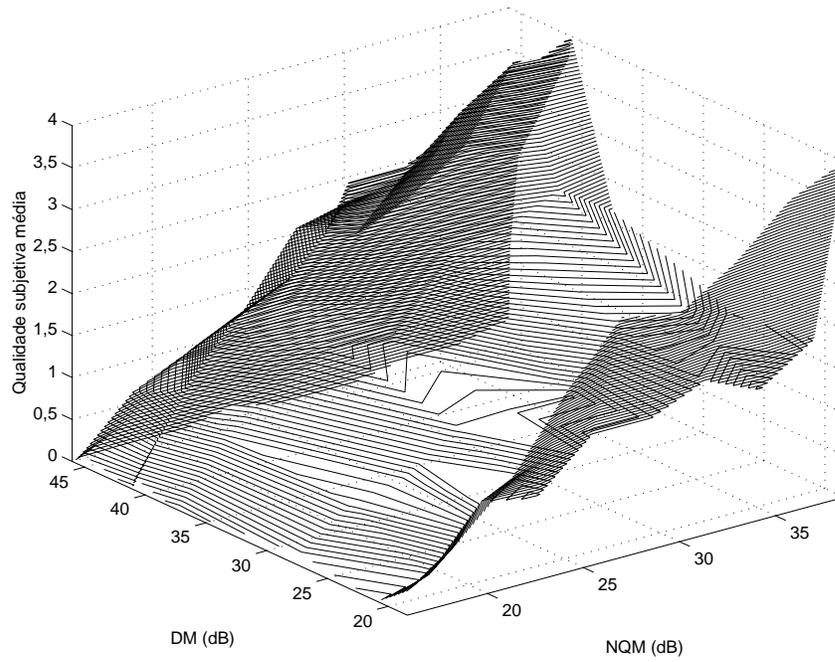


Fig. 6.16 – Classificação média em função da *DM* e da *NQM* para o conjunto de imagens degradadas por combinação entre distorção em frequência e injeção de ruído.

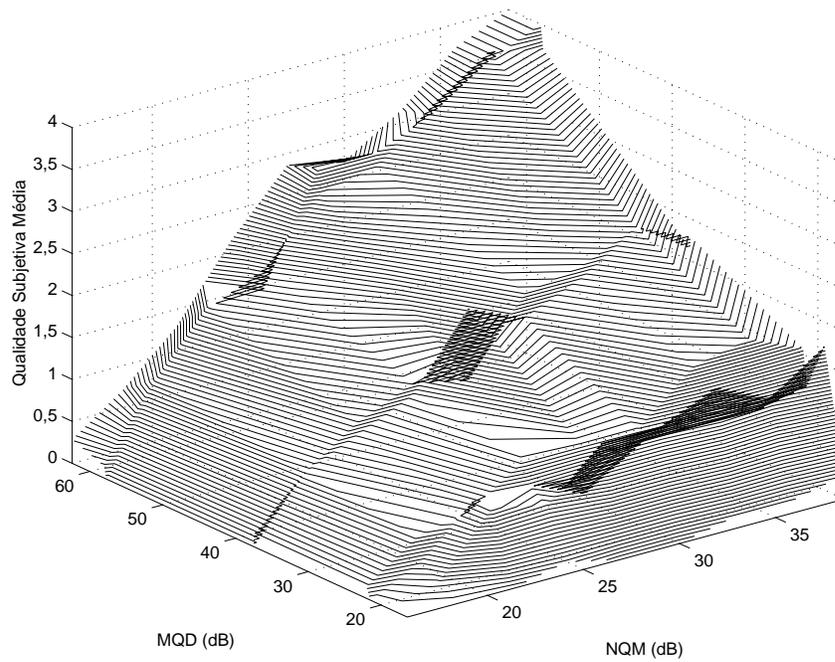


Fig. 6.17 – Classificação média em função da *MQD* e da *NQM* para o conjunto de imagens degradadas por combinação entre distorção em frequência e injeção de ruído.

Na tentativa de modelar a avaliação subjetiva obtida em função da MQD e da NQM , foram usadas as seguintes representações:

$$f_1 : aN + bD + c ,$$

$$f_2 : aN + bD + cN^2 + dD^2 + e ,$$

$$f_3 : aN + bD + cN^2 + dD^2 + eND + \\ + fN^2D + gND^2 + h(ND)^2 + i ,$$

$$f_4 : a + b(N - \mu_1) + c(D - \mu_2) + d(N - \mu_1)(D - \mu_2) + \\ + e(N - \mu_1)^2 + f(D - \mu_2)^2 + g(N - \mu_1)^2(D - \mu_2) + \\ + h(N - \mu_1)(D - \mu_2)^2 + i[(N - \mu_1)(D - \mu_2)]^2 ,$$

$$f_5 : k \exp \left[-\frac{(N - \mu_1)^2}{2\sigma_1^2} + \frac{C_{12}(N - \mu_1)(D - \mu_2)}{\sigma_1\sigma_2} - \frac{(D - \mu_2)^2}{2\sigma_2^2} \right] ,$$

$$f_6 : k \exp \left[-\frac{(N - \mu_1)^2}{2\sigma_1^2} - \frac{(D - \mu_2)^2}{2\sigma_2^2} \right] ,$$

onde N e D denotam, respectivamente, NQM e MQD ; $a, b, c, d, e, f, g, h, i, \mu_1, \mu_2, \sigma_1, \sigma_2$ e C_{12} são parâmetros das funções a determinar; k é uma constante de normalização usada para que os valores das funções f_5 e f_6 permaneçam no intervalo entre 0 (qualidade *inadmissível*) e 4 (qualidade *excelente*). As funções f_1, f_2, f_3, f_4, f_5 e f_6 são aqui denominadas, respectivamente, como função bidimensional de 1ª ordem; de 2ª ordem de variáveis não-correlacionadas; de 2ª ordem de variáveis correlacionadas; de 2ª ordem de variáveis correlacionadas e com deslocamento; Gaussiana de variáveis correlacionadas; Gaussiana de variáveis não-correlacionadas.

As funções relacionadas anteriormente foram escolhidas pela sua simplicidade e consistem em uma primeira tentativa de modelar a avaliação subjetiva da qualidade de imagens degradadas pelos efeitos combinados de distorção em frequência e injeção de ruído, os quais são representados pelo NQM e MQD , respectivamente. Otimizados os parâmetros de cada uma daquelas funções, para as avaliações obtidas experimentalmente, é realizada a escolha de uma daquelas funções como a que melhor representa a percepção de qualidade. O critério usado para a referida escolha foi o coeficiente de correlação entre os dados experimentais (avaliações subjetivas) e os valores previstos pelo modelo.

Os coeficientes de correlação para cada uma das funções testadas são, respectivamente, $r_1 = 0,869360$, $r_2 = 0,875984$, $r_3 = 0,919951$, $r_4 = 0,919855$, $r_5 = 0,935703$ e $r_6 = 0,935770$.

As funções f_5 e f_6 apresentaram os coeficientes de correlação de maior valor em relação às das outras funções testadas. Devido a isso, as funções f_1 a f_4 foram descartadas. A decisão sobre qual das funções restantes (f_5 ou f_6) será escolhida na composição da métrica composta requer uma análise um pouco mais detalhada, a qual é desenvolvida a seguir.

Os valores dos parâmetros encontrados no processo de otimização para f_5 foram: $\mu_1 = 39,412285$; $\mu_2 = 54,546430$; $\sigma_1 = 13,175263$, $\sigma_2 = 24,322603$ e $C_{12} = 0,018607$. A variância dos valores da função f_5 em relação às avaliações subjetivas é de 0,174315.

Para f_6 , os valores encontrados foram: $\mu_1 = 39,347887$; $\mu_2 = 54,813260$; $\sigma_1 = 13,044936$ e $\sigma_2 = 24,562926$. A variância dos valores preditos pelo modelo em relação às avaliações subjetivas é de 0,174635.

Pode-se notar que o parâmetro referente à covariância de NQM e MQD , C_{12} , é bem pequeno. Conseqüentemente, os valores do coeficiente de correlação e da variância dos valores de qualidade preditos pelas duas funções em relação às avaliações subjetivas são muito próximos. Em função disso, a escolha recai na função f_6 por sua maior simplicidade com relação a f_5 .

A medida de qualidade composta (MQC) é, então, definida por:

$$MQC = k \exp \left[-\frac{(NQM - \mu_1)^2}{2\sigma_1^2} - \frac{(MQD - \mu_2)^2}{2\sigma_2^2} \right], \quad (6.41)$$

onde MQC é a medida de qualidade composta. μ_1 , μ_2 denotam, respectivamente, as médias (em dB) associadas à NQM e MQD , bem como σ_1 e σ_2 denotam os desvios-padrão (em dB) associados à NQM e MQD , respectivamente. k é uma constante de normalização cuja finalidade é ajustar os valores de MQC para que os mesmos permaneçam no intervalo entre 0 (qualidade *inadmissível*) e 4 (qualidade *excelente*).

6.6.1 Discussão

A *MQC* é uma proposta de métrica para avaliação da qualidade de restaurações obtidas a partir de imagens que apresentem degradações resultantes da combinação de distorção em frequência e injeção de ruído. A principal virtude da *MQC* é a coerência entre o modelo proposto e a percepção humana de qualidade de uma imagem.

Como uma limitação mais relevante, a *MQC* requer que se tenha à disposição a imagem original e uma versão da imagem degradada isenta de ruído para que seja possível o cálculo da *MQD* e da *NQM*. Essa limitação (compartilhada por outras métricas de qualidade como a *SNR*, a *BSNR* e o *ISNR*) estabelece que a *MQC* somente pode ser aplicada *off-line* na avaliação e ajuste dos parâmetros de sistemas de restauração, usando imagens de referência.

6.7 Conclusões

Este capítulo tratou das métricas usadas nas avaliações objetivas da qualidade de uma imagem.

Primeiramente, as medidas convencionais foram abordadas. Essas medidas, herança das áreas mais tradicionais do processamento de sinais, são baseadas em algum tipo de avaliação da energia dos sinais de interesse. Suas definições são simples, resultando em expressões de fácil manipulação algébrica e implementação com baixa complexidade computacional. Contudo, não apresentam coerência entre seus resultados e a percepção humana de qualidade.

Em seguida, tratou-se das métricas que objetivam ser coerentes com a percepção visual humana. Dentre essas métricas, destacam-se a *DM* e a *NQM* desenvolvidas para avaliação de sistemas de restauração de imagens segundo uma nova metodologia, na qual os efeitos de distorção em frequência e injeção de ruído são considerados isoladamente.

São apresentados, então, resultados experimentais de verificação de coerência da *NQM* e da *DM* com a percepção visual humana. Os testes em relação à *NQM* mostram que, em imagens degradadas apenas por adição uniforme de ruído do tipo Gaussiano, a percepção da qualidade é proporcional à referida métrica, o que corrobora as conclusões apresentadas em [23].

Em relação à *DM*, a experimentação mostra que a mesma não é adequada para representar a percepção humana da qualidade de imagens degradadas exclusivamente por distorção em frequência. Esse resultado é atribuído ao fato da *DM* não levar em consideração os efeitos de mascaramento de contraste no domínio da seqüência.

É proposta uma métrica, baseada na *NQM* e denominada *MQD*, em substituição à *DM* na avaliação da qualidade de imagens degradadas por distorção em frequência. A *MQD* mostrou-se coerente com a percepção visual humana e qualidade percebida das imagens degradadas.

Em [23], os autores apontam uma lacuna na metodologia por eles proposta: a não existência de uma métrica que avaliasse a qualidade de um sistema de restauração que processe imagens degradadas pela combinação de distorção em frequência e injeção de ruído. No sentido de resolver esse problema, a *MQC* é proposta.

A principal virtude da *MQC* é a concordância entre os valores de qualidade preditos pelo modelo e as avaliações subjetivas obtidas experimentalmente. Sua principal limitação consiste na necessidade de se ter acesso à imagem original e a uma versão isenta de ruído da imagem degradada. Essa limitação estabelece que a *MQC* só pode ser usada *off-line* para ajuste e avaliação de sistemas de restauração usando imagens de referência.

7.1 Introdução

Neste capítulo, são apresentados dois experimentos que objetivam reunir em um único sistema a restauração via ROMKF em conjunção com Programação Evolucionária (PE) e a Medida de Qualidade Composta (*MQC*), ferramentas desenvolvidas nos Capítulos 5 e 6, respectivamente.

O primeiro experimento substitui a função objetivo usada no Capítulo 5 pela *MQC*, a fim de demonstrar a coerência existente entre a otimização numérica da *MQC* e a melhoria da qualidade percebida de uma imagem.

No segundo experimento, assume-se que os modelos e respectivos parâmetros dos sistemas de síntese da imagem e de degradação são conhecidos. Três medidas de qualidade (*MQC*, *ISNR* e *MSE*) são usadas para avaliar diferentes estratégias de restauração via ROMKF.

Tanto para o primeiro quanto para o segundo experimento são apresentados os resultados numéricos e imagens restauradas obtidas.

Na seção final, as conclusões do presente capítulo são apresentadas e discutidas.

7.2 Experimento 01

Esta simulação demonstra a viabilidade de se usar a *MQC* como função objetivo em procedimentos de estimação paramétrica em sistemas de restauração.

A imagem degradada (Fig. 7.1) foi obtida sinteticamente a partir da imagem “Lena” (tons de cinza, 256×256), caracterizando-se o sistema de degradação por uma PSF do tipo

movimento horizontal de câmera de dimensão 1×7 e ruído aditivo Gaussiano, cuja variância foi definida para que a $BSNR$ resultante na imagem degradada fosse de 40 dB.

Para a restauração foi usado o ROMKF-PE, como descrito no Capítulo 5, exceto pela substituição da função objetivo original (5.1) pela MQC (6.41).

Assim como no Capítulo 5, é assumido que se conhece o modelo de degradação e de síntese da imagem, mas não seus parâmetros.

A imagem restaurada obtida (Fig. 7.2) possui $MQC = 0,6608$ dB.

Os resultados apresentados revelam haver coerência entre a otimização paramétrica segundo a MQC e a melhoria da qualidade da imagem restaurada com relação à sua correspondente imagem degradada. Sendo assim, a MQC pode ser usada em sistemas de restauração para sintonia de seus parâmetros, na busca de restaurações de maior conformidade com a percepção humana da qualidade de imagens.

A limitação da técnica continua sendo a necessidade de se dispor da imagem original e de uma versão da imagem degradada isenta de ruído.



Fig. 7.1 – Imagem degradada sinteticamente com PSF do tipo movimento horizontal de câmera de dimensão 1×7 e adição de ruído do tipo Gaussiano ($BSNR = 40$ dB).



Fig. 7.2 – Imagem restaurada via ROMKF-PE e MQC como função objetivo na etapa de estimação paramétrica.

7.3 Experimento 02

Neste experimento, considera-se que o sistema de síntese da imagem, bem como o de degradação, seja conhecido. A imagem degradada usada é a mesma do Experimento 01 e a restauração é realizada via ROMKF sem etapa de estimação paramétrica. Contudo, são usadas três possibilidades para a restauração, relativamente ao termo que modela a variância do ruído de observação. A primeira possibilidade (Caso 01) consiste em usar o ROMKF sem alteração do valor original da variância do ruído de observação. Na segunda (Caso 02), altera-se o termo da variância do ruído de observação multiplicando por 10 o seu valor original. A terceira estratégia (Caso 03) usa uma máscara de ponderação para o termo da variância do ruído segundo estratégia apresentada em [70].

No filtro de Kalman original, bem como em suas aproximações, o termo que modela a variância do ruído de observação também controla a atenuação dada às altas frequências, de maneira similar ao que ocorre no filtro de Wiener com o espectro de potência do ruído de degradação. Essa característica tem sido usada para, através da variação de valor do referido termo, implementar uma restauração do tipo espacialmente variante, tratando de

maneira diferenciada regiões planas, de borda e de textura, em busca de melhores resultados sob o aspecto psicovisual [70].

Para cada restauração obtida, foi feita uma avaliação de acordo com as seguintes medidas de qualidade: MQC , $ISNR$ e MSE .

Tanto os resultados numéricos (Tabela 7.1) quanto as imagem restauradas (Figs. 7.4, 7.5 e 7.6) são apresentados. Na Tabela 7.1, os números em negrito indicam a melhor qualidade para cada métrica.

Tabela 7.1 – Medidas referentes às imagens restauradas do Experimento 02

	Caso 01	Caso 02	Caso 03
<i>MSE</i>	98,8081	98,5751	60,6250
<i>ISNR (dB)</i>	3,8159	3,8262	5,9373
<i>MQC (dB)</i>	0,7027	0,4598	0,6733



Fig. 7.3 – Imagem restaurada via ROMKF, sem máscara e sem ponderação ($k=1$) do parâmetro que modela a variância do ruído de observação.



Fig. 7.4 – Imagem restaurada via ROMKF, sem máscara e com ponderação ($k = 10$) do parâmetro que modela a variância do ruído de observação.



Fig. 7.5 – Imagem restaurada via ROMKF, com máscara de ponderação do parâmetro que modela a variância do ruído de observação [70].

7.4 Conclusões

Pelo que foi apresentado no Experimento 01, fica evidente que a MQC , ao ser usada como função-objetivo na etapa de estimação paramétrica do ROMKF-PE, resulta em melhoria de qualidade da imagem restaurada quando comparada com a imagem degradada.

No Experimento 02, a MQC é usada em conjunto com outras medidas de avaliação de qualidade para auxiliar na tomada de decisão entre diferentes estratégias de restauração. Os resultados obtidos revelam haver discordância entre as métricas usadas sobre qual seria a estratégia de melhor desempenho: MSE e $ISNR$ apontam a estratégia empregada no Caso 03, enquanto a MQC indica a estratégia do Caso 01. Essa discordância já era esperada, haja vista toda a discussão feita no Capítulo 6 sobre métricas inspiradas nas características do sistema visual humano e métricas baseadas no MSE.

Contudo, não deixa de ser intrigante que o MSE e a $ISNR$ sejam favoráveis ao Caso 03, da mesma forma que a MQC seja ao Caso 01. No Caso 03, a máscara de ponderação utilizada tem por finalidade original controlar as variações do termo que modela a variância do ruído de observação, a fim de resultar em melhor qualidade percebida em relação ao processamento sem ponderação. Portanto, o esperado era que a MQC indicasse o Caso 03. Por outro lado, o fato do MSE e da $ISNR$ apontarem o Caso 03 e não o Caso 01 como o de melhor desempenho parece contraditório com a afirmação de que o filtro de Kalman é ótimo no sentido do MSE . Isso porque, uma vez que o ruído é igualmente distribuído por todas as regiões da imagem, o processamento diferenciado dessas regiões, através da ponderação do termo referente à modelagem da variância do ruído, deveria resultar em um MSE ($ISNR$) maior (menor) do que a restauração sem ponderação. Deve-se ressaltar, contudo, que, ao se incluir a máscara de ponderação, o filtro resultante passa a ser não-linear e a condição de ótimo do filtro de Kalman original é restrita à classe dos filtros lineares [70].

8.1 Contribuições desta tese

Os resultados apresentados no Capítulo 5 atestam a superioridade na utilização de estratégias de baixa sensibilidade às condições iniciais na etapa de estimação do *filtro de Kalman de modelo de ordem reduzida* (reduced order model Kalman filter – ROMKF), usado para restauração de imagens. Assim, como é tradicionalmente feito em outros sistemas de restauração, em [4] e [5], são usadas estratégias sensíveis às condições iniciais na etapa de estimação do ROMKF, não obstante a função de estimação usada apresentar ótimos locais. São levantadas, para justificar tal contradição, razões relacionadas à necessidade de minimizar o custo computacional dos sistemas de restauração, face ao volume de dados a ser processado em aplicações bidimensionais. Para contornar a convergência a ótimos locais, é sugerido [4], [5] que o processo de restauração seja reiniciado várias vezes, formando assim um conjunto de imagens, do qual a imagem que apresenta melhor qualidade é escolhida como sendo a restauração final. Porém, o número de reinícios necessário é desconhecido e, além disso, não há garantias de que alguma das restaurações obtidas seja representativa da melhor restauração que o sistema pode produzir. Em contrapartida, quando se usa uma estratégia de otimização de baixa sensibilidade às condições iniciais na etapa de estimação do ROMKF, basta uma única restauração para se conseguir essa imagem que é representativa do máximo de melhoramento da qualidade oferecido pelo sistema de restauração. Essas afirmações são sustentadas pelos resultados apresentados, nos quais as restaurações obtidas com ROMKF–DHSM¹ (sensível às condições iniciais) apresentam uma dispersão muito maior do que as obtidas com ROMKF–PE² (baixa sensibilidade às condições iniciais). Além disso, a melhor restauração

¹ DHSM – downhill simplex method

² PE – programação evolucionária

via ROMKF–DHSM tem pior qualidade do que qualquer uma das que foram obtidas via ROMKF–PE, tanto do ponto de vista numérico, quanto perceptual. Se uma desvantagem pode ser apontada na utilização de estratégias de baixa sensibilidade às condições iniciais, em relação às de alta sensibilidade, é o aumento da complexidade computacional, em proporção direta, no caso da computação evolucionária, ao número de indivíduos da população.

Esta tese também propõe, no Capítulo 6, uma medida para avaliação da qualidade de uma imagem, na qual os efeitos de distorção em frequência e injeção de ruído são tratados isoladamente. Essa metodologia de isolamento dos efeitos é proposta em [23], na qual são apresentadas duas medidas baseadas nas características do sistema visual humano para quantificar a distorção em frequência e a injeção de ruído, respectivamente, a *medida de distorção* (distortion measure – *DM*) e a *medida de qualidade de ruído* (noise quality measure – *NQM*). Ainda em [23], é assinalada a inexistência de uma medida que combine distorção em frequência e injeção de ruído, recurso fundamental na avaliação da qualidade de imagens em situações práticas. É justamente a essa lacuna que a *medida de qualidade composta* (*MQC*), proposta nesta tese, procura atender. A *MQC* combina medidas de distorção em frequência e injeção de ruído na avaliação da qualidade de imagens que apresentam os dois efeitos. Como medida para injeção de ruído, é usada a *NQM*. Contudo, em função de testes realizados, nos quais se verifica que a *DM* não é representativa da percepção humana, uma nova medida para distorção em frequência, denominada medida de qualidade da distorção (*MQD*), é proposta e usada na *MQC*. A *MQC* requer que se tenha à disposição a imagem original e uma versão da imagem degradada isenta de ruído, servindo, portanto, para a avaliação e ajuste de algoritmos de restauração em situações controladas, pois, em situações práticas, não se consegue dispor das referidas imagens. Foram realizados experimentos de avaliação subjetiva em imagens para validar a *MQC*.

Ambas as contribuições podem ser usadas como ferramentas de avaliação da qualidade em sistemas de restauração de imagens. O emprego de estratégias de baixa sensibilidade às condições iniciais garante que os resultados obtidos na restauração, por mais complexa que seja a função a ser otimizada, são representativos do máximo de melhoramento que um determinado sistema pode oferecer. De posse dos melhores resultados possíveis, o ajuste e avaliação de algoritmos de restauração podem ser feitos através da *MQC*.

8.2 Sugestão para futuros trabalhos

Como sugestão para futuros trabalhos, relacionados aos assuntos aqui abordados, podem-se citar:

- a) a realização de experimentos de avaliação subjetiva mais amplos, combinando um número maior de tipos de degradações e de imagens, coletando mais dados com o objetivo de refinar o modelo *MQC*;
- b) adicionar ao algoritmo de restauração de imagens via filtragem de Kalman recursos para que o critério de estimação paramétrica seja adequado às características da percepção humana. Dois tipos de critérios podem ser investigados: um critério para o caso em que se dispõem da imagem original e de uma versão da imagem degradada isenta de ruído (quando a própria *MQC* pode ser usada); e outro critério, para situações de restauração reais, em que os referidos sinais não estão disponíveis.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ABOUTALIB, A. O.; SILVERMAN, L. M. Restoration of Motion Degraded Images. *IEEE Transactions on Circuits and Systems*, v. CAS-22, n. 3, p. 278-286, Mar. 1975.
- [2] ANDERSON, B. D. O.; MOORE, J. B. Optimal Filtering. 1. ed. USA: Prentice-Hall, 1979.
- [3] ANDREWS, H. C.; HUNT, B. R. Digital Image Restoration. 1. ed. USA: Prentice-Hall, 1977.
- [4] ANGWIN, D. L. Adaptive Image Restoration Using Reduced Order Model Based Kalman Filters. Troy, New York, 1989. Thesis (Ph.D. in Electrical Engineering) – Rensselaer Polytechnic Institute.
- [5] ANGWIN, D. L.; KAUFMAN, H. Nonhomogeneous Image Identifications and Restoration Procedures. In: KATSAGGELOS, A. K. Digital Image Restoration. New York: Springer-Verlag, 1991. p. 177-208.
- [6] BÄCK, T.; SCHWEFEL, H. – P. Evolutionary Computation : An Overview. In: IEEE INTERNATIONAL CONFERENCE ON EVOLUTIONARY COMPUTATION (20-22 May 1996: Nagoya, Japan). Proceedings. p. 20-29.
- [7] BÄCK, T.; HAMMEL, U.; SCHWEFEL, H. – P. Evolutionary Computation: Comments on the History and Current State. *IEEE Transactions on Evolutionary Computation*, USA, v. 1, n. 1, p. 3-17, Apr. 1997.
- [8] BANHAM, M. R.; KATSAGGELOS, A. K. Digital Image Restoration. *IEEE Signal Processing Magazine*, p. 24-41, Mar. 1997.
- [9] BARTEN, P. G. J. Effect of Picture Size and Definition on Perceived Image Quality. In: INTERNATIONAL DISPLAY RESEARCH CONFERENCE (Oct. 1988: San Diego, CA, USA). Conference Record. p. 142-145.

- [10] BARTEN, P. G. J. The Effects of Picture Size and Definition on Perceived Image Quality. *IEEE Transactions on Electron Devices*, USA, v. 36, n. 9, p. 1865-1869, Sept. 1989.
- [11] BARTEN, P. G. J. Effects of Quantization and Pixel Structure on the Image Quality of Color Matrix Displays. In: *INTERNATIONAL DISPLAY RESEARCH CONFERENCE* (Oct. 1991: San Siego, CA, USA). Conference Record. p. 167-170.
- [12] BEATTIE, R. S.; ELDER, S. C. Maximum Likelihood Image Identification and Restoration Using Genetic Algorithms. In: *IEE COLLOQUIUM ON GENETIC ALGORITHMS IN IMAGE PROCESSING AND VISION* (1994: London, UK) Proceedings. 1994. p. 10/1-10/6.
- [13] BIEMOND, J.; PUTTEN, F. G.; WOODS, J. W. Identification and Restoration of Images with Symmetric Noncausal Blurs. *IEEE Transactions on Circuits and Systems*, USA, v. 35, n. 4, p. 385-393, Apr. 1988.
- [14] BIEMOND, J.; LAGENDIJK, R. L.; MERSEREAU, R. M. Iterative Methods for Image Deblurring. *Proceedings of the IEEE*, USA, v. 78, n. 5, p. 856-883, May 1990.
- [15] BRADLEY, A.; OHZAWA, I. A Comparison of Contrast Detection and Discrimination. *Vision Research*, Great Britain, v. 26, n. 6, p. 991-997, June 1986.
- [16] CADZOW, J. A. Blind Deconvolution via Cumulant Extrema. *IEEE Signal Processing Magazine*, p. 24-42, May 1996.
- [17] CASTLEMAN, K. R. *Digital Image Processing*. 1. ed. USA: Prentice-Hall, 1979.
- [18] CHEN, B. H.; THOMOPOULOS, S. C. A. Image Restoration by Inhomogeneous G-M Field Modeling and Adaptive Kalman Filtering. In: *1993 IEEE INTERNATIONAL SYMPOSIUM ON CIRCUITS AND SYSTEMS* (May 1993: Chicago, IL, USA). Proceedings. 1993. p. 423-426.
- [19] CHEN, Y. -W.; NAKAO, Z.; FANG, X. A Parallel Genetic Algorithm Based on the Island Model for Image Restoration. In: *1996 IEEE SIGNAL PROCESSING SOCIETY WORKSHOP* (Sept. 1996: Kyoto, Japan). Proceedings. 1996. p. 109-118, 1996.

- [20] CHEN, Y. -W.; NAKAO, Z.; FANG, X. et al. A Parallel Genetic Algorithm for Image Restoration. In: INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION (13.: Aug. 1996: Vienna, Austria). Proceedings. v. 4. p. 694-698.
- [21] CHEN, Y. -W.; ENOKURA, T.; NAKAO, Z. A Fast Image Restoration Algorithm Based on Simulated Annealing. In: INTERNATIONAL CONFERENCE ON KNOWLEDGE-BASED INTELLIGENT INFORMATION ENGINEERING SYSTEMS (3.: Aug./Sept. 1999: Adelaide, Australia). Proceedings. p. 341-344.
- [22] CHUI, C. K.; CHEN, G. Kalman Filtering – with Real-Time Applications. 3. ed. Berlin: Springer-Verlag, 1999.
- [23] DAMERA-VENKATA, N.; KITE, T. D.; GEISLER, W. S. et al. Image Quality Assessment Based on a Degradation Model. IEEE Transactions on Image Processing, v. 9, n. 4, p. 636-650, Apr. 2000.
- [24] DARWIN, C. A Origem das Espécies. Rio de Janeiro: Ediouro,1991.
- [25] DUDGEON, D. E.; MERSEREAU, R. M. Multidimensional Digital Signal Processing. 1. ed. USA: Prentice-Hall, 1984.
- [26] EIBEN, Á. E.; HINTERDING, R.; MICHALEWICZ, Z. Parameter Control in Evolutionary Algorithms. IEEE Transactions on Evolutionary Computation, USA, v. 3, n. 2, p. 124-141, July 1999.
- [27] FOGEL, D. B. Evolutionary Optimization. In: ASILOMAR CONFERENCE ON SIGNALS, SYSTEMS AND COMPUTERS (26.: 26-28 Oct. 1992: Pacific Groove, CA, USA). Conference Record. p. 409-414.
- [28] FOGEL, D. B. An Introduction to Simulated Evolutionary Optimization. IEEE Transactions on Neural Networks, USA, v. 5, n. 1, p. 3-14, Jan. 1994.
- [29] FOGEL, D. B. Evolutionary Computing. IEEE Spectrum. USA, v. 37, n. 2, p. 26-32, Feb. 2000.
- [30] FOGEL, L. J.; OWENS, A. J.; WALSH, M. J. Artificial intelligence through simulated evolution. New York: John Wiley, 1966.
- [31] GOLDBERG, D. E. Genetic Algorithms: in search, optimization & machine learning.1. ed. USA: Addison Wesley, 1989.

- [32] HALLIDAY, T. Vision. In: _____. The Senses and Communication. 1. ed. Germany: Springer-Verlag, 1998. p. 77-146.
- [33] HAN, Y. -S.; SNYDER, W. E. New Applications of Mean Field Annealing to the Restorations of Medical Images. In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY (Oct./Nov. 1991: Orlando, FL, USA). Proceedings. 1991. v. 13. p. 97-98.
- [34] HATANAKA, T.; UOSAKI, K.; UETA, T. Optimal Smoothing of Binary Markov Sequences by Genetic Algorithm and its Application to Image Restoration. In: IEEE INTERNATIONAL CONFERENCE ON EVOLUTIONARY COMPUTATION (May 1996: Nagoya, Japan). Proceedings. 1996. P. 448-451.
- [35] HAYKIN, S. Adaptive Filter Theory. 3. ed. USA: Prentice-Hall, 1996.
- [36] HOLLAND, J. H. Adaptation in natural and artificial systems. The University of Michigan Press, Ann Arbor, 1975.
- [37] HUANG, T. S.; SCHREIBER, W. F.; TRETIAK, O. J. Image Processing. Proceedings of the IEEE, USA, v. 59, n. 11, p. 1586-1609, Nov. 1971.
- [38] HUNT, B. H. Digital Image Processing. In: OPPENHEIM, A. V. Applications of Digital Signal Processing. 1. ed. USA: Prentice-Hall, 1978.
- [39] JAIN. A. K. Advances in Mathematical Models for Image Processing. Proceedings of the IEEE, v. 69, n. 5, p.502-528, May 1981.
- [40] JANSSEN, T. J. W. M. Understanding Image Quality. In: 2001 IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING (8.: Oct. 2001: Thessaloniki, Greece). Proceedings. 2001. p. 7.
- [41] KALMAN, R. E. A New Approach to Linear Filtering and Prediction Problems. Transactions of the ASME – Journal of Basic Engineering, 82 (Series D), p. 35-45, 1960.
- [42] KAMEN, E. W.; SU, J. K. Introduction to Optimal Estimation. 1. ed. Great Britain: Springer-Verlag, 1999.
- [43] KATSAGGELOS, A. K. Introduction. In: _____. Digital Image Restoration. New York: Springer-Verlag, 1991. p. 177-208.

- [44] KAUFMAN, H.; TEKALP, A. M. Survey of Estimation Techniques in Image Restoration. *IEEE Control Systems*, p. 16-24, Jan. 1991.
- [45] KIM, J.; WOODS, J. W. A New Interpretation of ROMKF. *IEEE Transactions on Image Processing*, v. 6, n. 4, p. 599-601, Apr. 1997.
- [46] KOCH, S.; KAUFMAN, H. Boundary Value Selection Problem for Image Restoration Using the Reduced Order Model Based Kalman Filter. In: *INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH, AND SIGNAL PROCESSING* (Apr. 1991: Toronto, Ont., Canada). *Proceedings*. 1991. v. 4, p. 2941-2943.
- [47] KOCH, S.; KAUFMAN, H. Restoration of Spatially Varying Images Using Multiple Model Extended Kalman Filters. In: *CONFERENCE ON DECISION AND CONTROL* (32.: Dec. 1993: San Antonio, Texas). *Proceedings*. 1993. p. 1216-1221.
- [48] KOCH, S.; KAUFMAN, H.; BIEMOND, J. Restoration of Spatially Varying Blurred Images Using Multiple Model-Based Extended Kalman Filters. *IEEE Transactions on Image Processing*, v. 4, n. 4, p. 520-523, Apr. 1995.
- [49] KUNDUR, D. Blind Deconvolution of Still Images Using Recursive Inverse Filtering. Thesis (Master of Applied Science) – Department of Electrical and Computer Engineering, University of Toronto.
- [50] KUNDUR, D.; HATZINAKOS, D. Blind Image Deconvolution. *IEEE Signal Processing Magazine*, p. 43-64, May 1996.
- [51] LAGENDIJK, R. L.; BIEMOND, J.; BOEKEE, D. E. Identification and Restoration of Noisy Blurred Images Using the Expectation-Maximization Algorithm. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, v. 38, n.7, p. 1180-1191, July 1990.
- [52] MACOVSKI, A. *Medical Imaging Systems*. 1. ed. USA: Prentice-Hall, 1983.
- [53] MAN, K. F.; TANG, K. S.; KWONG, S. *Genetic Algorithms*. 1. ed. Great Britain: Springer-Verlag, 1999.
- [54] MICHALEWICZ, Z.; FOGEL, D. B. *How to Solve It: Modern Heuristics*. Germany: Springer-Verlag, 2000.

- [55] MITSA, T.; VARKUR, K. L. Evaluation of Contrast Sensitivity Functions for the Formulation of Quality Measures Incorporated in Halftoning Algorithms. In: 1993 IEEE ACOUSTICS, SPEECH, AND SIGNAL PROCESSING (Apr. 1993, Minneapolis, MN, USA). Proceedings. 1993. v. 5. p.301-304.
- [56] MOLINA, R.; NÚÑEZ, J.; CORTIJO, F. J. et. al. Image Restoration in Astronomy. IEEE Signal Processing Magazine, v. 18, n. 2, p. 11-29, Mar. 2001.
- [57] NASA Jet Propulsion Laboratory – www.nasa.jpl.gov
- [58] OPPENHEIM, A. V.; SCHAFER, R. W. Discrete-Time Signal Processing. 1. ed. USA: Prentice-Hall, 1989.
- [59] ÖZKAN, M. K.; TEKALP, A. M.; SEZAN, M. I. POCS-Based Restoration of Space-Varying Blurred Images. IEEE Transactions on Image Processing, v. 3, n. 4, p. 450-454, July 1994.
- [60] PAPOULIS, A. Probability, Random Variables, and Stochastic Processes. 3. ed. Singapore: McGraw-Hill, 1991.
- [61] PATTI, A. J.; ÖZKAN, M. K.; TEKALP, et. al. New Approaches for Space-Variant Image Restoration. In: 1993 IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH, AND SIGNAL PROCESSING (Apr. 1993: Minneapolis, MN., USA). Proceedings. 1993. v. 5, p. 261-264.
- [62] PELI, E. Contrast in Complex Images. Journal of Optical Society of America, v. 7, n. 10, p. 2032-2040, Oct. 1990.
- [63] PELI, E. In Search of a Contrast Metric: Matching the Perceived Contrast of Gabor Patches at Different Phases and Bandwidths. Vision Res., v. 37, n. 23, p. 3217-3224, Dec. 1997.
- [64] PELI, E. Feature Detection Algorithm Based on a Visual System Model. Proceedings of the IEEE, v. 90, n. 1, p. 78-93, Jan. 2002.
- [65] PETROU, M.; BOSDOGIANNI, P. Image Processing: the fundamentals. 1. ed. England: John Wiley & Sons, 1999.
- [66] PRASAD, K. V.; MAMMONE, R. J. Depth Restoration from Defocused Images Using Simulated Annealing. In: INTERNATIONAL CONFERENCE ON

- PATTERN RECOGNITION (10.: June 1990: Atlantic City, NJ, USA). Proceedings. v. 1. p. 227-229.
- [67] PRATT, W. K. Digital Image Processing. 3. ed. USA: John Wiley & Sons, 2001.
- [68] PRESS, W. H.; FLANNERY, B. P.; TEUKOLSKY, S. A. et al. Minimization or Maximization of Functions. In: _____. Numerical Recipes in Pascal: the art of scientific computing. 1. ed. USA: Cambridge, 1989. p. 309-374.
- [69] QURESHI, A. G.; MOUFTAH, H. T. Partially-Blind Image Restoration Using Constrained Kalman Filtering. In: 1991 IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH, AND SIGNAL PROCESSING (Apr. 1991: Toronto, ONT., Canada). Proceedings. 1991. v. 5, p. 3713-3716.
- [70] RAJALA, S. A.; FIGUEIREDO, R. J. P. Adaptive Nonlinear Image Restoration by a Modified Kalman Filtering Approach. IEEE Transaction on Acoustic, Speech, and Signal Processing, v. ASSP-29, n. 5, p. 1033-1042, Oct. 1981.
- [71] RIDDER, H. Image Processing and the Problem of Quantifying Image Quality. In: 2001 IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING (8.: Oct. 2001: Thessaloniki, Greece). Proceedings. 2001. p. 3-6.
- [72] SCHMITT, T.; GEBAUER, H. D.; FREYER, R. et. al. Restoration of Nuclear Medicine Images using a Kalman Filtering Approach. In: STEVENSON, R. L.; RAJALA, S. A. Image and Video Processing III – Proceedings SPIE, v. 2421, 1995, p. 64-69.
- [73] STARK, H. Image Recovery: theory and application. 1. ed. USA: Academic Press, 1987.
- [74] SURESH, B. R.; SHENOI, B. A. New Results in Two-Dimensional Kalman Filtering with Applications to Image Restoration. IEEE Transactions on Circuits and Systems, v. CAS-28, n.4, p. 307-319, Apr. 1981.
- [75] TEKALP, A. M. Identification and Restoration of Noisy and Blurred Images. Troy, New York, 1984. Thesis (Ph.D. in Computer and Systems Engineering) – Rensselaer Polytechnic Institute.

- [76] TEKALP, A. M.; KAUFMAN, H.; WOODS, J. W. Edge-Adaptative Kalman Filtering for Image Restoration with Ringing Suppression. *IEEE Transaction on Acoustics, Speech, and Signal Processing*, v. 37, n. 6, p. 892-899, June 1989.
- [77] TEO, P. C.; HEEGER, D. J. Perceptual Image Distortion. In: 1994 IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING (1.: Nov. 1994: Austin, TX, USA). Proceedings. 1994. v. 2, p. 982-986.
- [78] WEBSTER, M. A. Visual Adaptation and Relative Nature of Preception. In: 2001 IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING (8.: Oct. 2001: Thessaloniki, Greece). Proceedings. 2001. p. 8-11.
- [79] WONG, H. -S.; GUAN, L. Application of Evolutionary Programming to Adaptive Regularization in Image Restoration. *IEEE Transactions on Evolutionary Computation*, USA, v. 4, n. 4, p. 309-326, Nov. 2000.
- [80] WOODS, J. W.; RADEWAN, C. H. Kalman Filtering in Two Dimensions. *IEEE Transaction on Informatin Theory*, v. IT-23, n. 4, p. 473-482, July 1977.
- [81] WOODS, J. W.; INGLE, V. K. Kalman Filtering in Two Dimensions: Further Results. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, v. ASSP-29, n. 2, p. 188-197, Apr. 1981.
- [82] YAO, X.; LIU, Y.; LIN, G. Evolutionary Programing Made Faster. *IEEE Transactions on Evolutionary Computation*, USA, v. 3, n. 2, p. 82-102, July 1999.
- [83] ZAMPOLO, R. F. Restauração de Imagens via Algoritmo Genético. Florianópolis, 1998. Dissertação (Mestrado em Engenharia Elétrica) – Centro Tecnológico, Universidade Federal de Santa Catarina.
- [84] ZAMPOLO, R. F.; SEARA, R.; TOBIAS, O. J. Restauração de Imagens Através de Filtragem de Kalman Usando Programação Evolucionária. In: SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES (19.: setembro, 2001: Fortaleza, CE). Anais.
- [85] ZAMPOLO, R. F.; SEARA, R.; TOBIAS, O. J. Evolutionary Programming in Image Restoration via Reduced Order Model Kalman Filtering. In: IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING (8.: Oct. 2001: Thessaloniki, Greece). Proceedings. p. 221-224.