
Instituto de Computação
Universidade Estadual de Campinas

Super-Resolução de Imagens Baseada em Aprendizado Utilizando Descritores de Características

Ana Carolina Correia Rézio

Este exemplar corresponde à redação final da Dissertação devidamente corrigida e defendida por Ana Carolina Correia Rézio e aprovada pela Banca Examinadora.

Campinas, 24 de outubro de 2011.

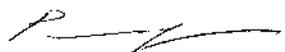
Prof. Dr. Hélio Pedrini (Orientador)

Dissertação apresentada ao Instituto de Computação, UNICAMP, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação.

ERRATA

Na folha i e ii - Onde se lê: Ana Carolina Correia Rézio Leia-se: Ana Carolina Correia Rezio

RR 271-


Prof. Dr. Paulo Licio de Geus
Coord. de Pós-Graduação
Instituto de Computação - Unicamp
Matrícula 10.326-8

Aut.

Unidade PPCL
T/UNICAMP
Cutter R339s
V. 1 Ed. 1
Tombo BC 94160
Proc. 16-112-12
C 1 D 1
Preço 11,00
Data 17/02/13
Cód. tit. 840903

FICHA CATALOGRÁFICA ELABORADA POR
MARIA FABIANA BEZERRA MÜLLER - CRB8/6162
BIBLIOTECA DO INSTITUTO DE MATEMÁTICA, ESTATÍSTICA E
COMPUTAÇÃO CIENTÍFICA - UNICAMP

R339s	<p> Rézio, Ana Carolina Correia, 1986- Super-resolução de imagens baseada em aprendizado utilizando descritores de características / Ana Carolina Correia Rézio. - Campinas, SP : [s.n.], 2011.</p> <p>Orientador: Hélio Pedrini. Dissertação (mestrado) - Universidade Estadual de Campinas, Instituto de Computação.</p> <p>1. Processamento de imagens. 2. Descritores. 3. Aprendizado do computador. I. Pedrini, Hélio, 1963- II. Universidade Estadual de Campinas. Instituto de Computação. III. Título.</p>
-------	-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Informações para Biblioteca Digital

Título em inglês: Images super-resolution based learning using feature descriptors

Palavras-chave em inglês:

Image processing

Descriptors

Machine learning

Área de concentração: Ciência da Computação

Titulação: Mestre em Ciência da Computação

Banca examinadora:

Hélio Pedrini [Orientador]

Edson José Rodrigues Justino

Neucimar Jerônimo Leite

Data da defesa: 25-08-2011

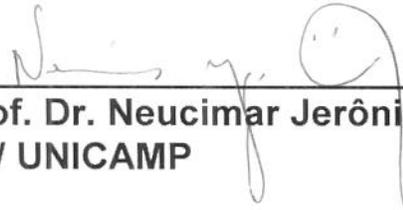
Programa de Pós-Graduação: Ciência da Computação

TERMO DE APROVAÇÃO

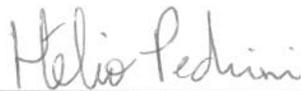
Dissertação Defendida e Aprovada em 25 de agosto de 2011, pela Banca examinadora composta pelos Professores Doutores:



Prof. Dr. Edson José Rodrigues Justino
PUC-PR



Prof. Dr. Neucimar Jerônimo Leite
IC / UNICAMP



Prof. Dr. Hélio Pedrini
IC / UNICAMP

Super-Resolução de Imagens Baseada em Aprendizado Utilizando Descritores de Características

Ana Carolina Correia Rézio¹

Julho de 2011

Banca Examinadora:

- Prof. Dr. Hélio Pedrini (Orientador)
- Prof. Dr. Edson José Rodrigues Justino
Pontifícia Universidade Católica do Paraná (PUC-PR)
- Prof. Dr. Neucimar Jerônimo Leite
Instituto de Computação (IC/UNICAMP)

¹Suporte Financeiro: Bolsa do Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (processo 573710/2008-2) 07/2009–02/2011.

Resumo

Atualmente, há uma crescente demanda por imagens de alta resolução em diversos domínios de conhecimento, como sensoriamento remoto, medicina, automação industrial, microscopia, entre outros. Imagens de alta resolução fornecem detalhes que são importantes para as tarefas de análise e visualização dos dados presentes nas imagens. Entretanto, devido ainda ao custo elevado dos sensores de alta precisão e às limitações existentes para redução do tamanho dos pixels das imagens encontradas no próprio sensor, as imagens de alta resolução têm sido adquiridas a partir de métodos de super-resolução. Este trabalho propõe um método para super-resolver uma imagem ou uma sequência de imagens a partir da compensação residual aprendida pelas características extraídas na imagem residual e no conjunto de treinamento. Resultados experimentais mostram que, na maioria dos casos, o método proposto provê menores erros quando comparado com outras abordagens do estado da arte. Medidas quantitativas e qualitativas são utilizadas na comparação dos resultados obtidos com as técnicas de super-resolução consideradas nos experimentos.

Abstract

There is currently a growing demand for high-resolution images in several domains of knowledge, such as remote sensing, medicine, industrial automation, microscopy, among others. High resolution images provide details that are important to tasks of analysis and visualization of data present in the images. However, due to the cost of high precision sensors and the limitations that exist for reducing the size of the image pixels in the sensor itself, high-resolution images have been acquired from super-resolution methods. This work proposes a method for super-resolving an image or a sequence of images from the compensation residual learned by the features extracted in the residual image and the training set. The results are compared with some methods available in the literature. Quantitative and qualitative measures are used to compare the results obtained with the super-resolution techniques considered in the experiments.

Agradecimentos

Eu gostaria de agradecer a Deus por ter me sustentado durante este período. Aos meus pais José Rézio e Ana Lúcia, meus irmãos Brauler e Ana Flávia, minha cunhada Camila e minha afilhada Beatriz, eu agradeço pelo amor, carinho, compreensão, paciência e suporte emocional, que me ajudaram a cumprir esta grande e difícil tarefa. Todos vocês são pessoas fundamentais na minha vida. Amo muito.

Também agradeço ao meu mestre, Prof. Dr. Hélio Pedrini, pela orientação dedicada, sugestões em todas as etapas desta pesquisa, motivação e amizade. Ao colega William Robson Schwartz, pelo significativo apoio nas discussões e grande suporte nas pesquisas.

Ao meu mestre e amigo, Prof. Alexandre Ribeiro, eu agradeço pelo apoio, confiança e incentivo, aliados à amizade, consideração e carinho, que foram imprescindíveis para o projeto e realização deste sonho. A ele, toda a minha admiração e respeito e a quem serei eternamente grata.

Aos meus amigos Aninha, Antônio, Ágatha, Thi, Loos (LML), Ana, Márcio, Nanissa, Patty, Thiago, Manu, grupo SPAEJ e outros, eu agradeço pelo companheirismo, consideração, apoio emocional, pelos bons momentos proporcionados e pela alegria de poder conviver com pessoas tão especiais. Vocês foram fundamentais na conquista desta vitória.

Também gostaria de agradecer a todos os amigos de Campinas. Amizades verdadeiras que surgiram em um curto período de tempo, mas que serão levadas por toda a vida. Pessoas que compartilhavam do mesmo sonho, das mesmas alegrias, desespos, dificuldades e lutas. Em especial agradeço ao Robinho, Guilherme e Isaura.

À Isaura e Júlia, duas pessoas especiais que fazem parte da minha família, eu agradeço pelo simples fato de existirem. Juntas compartilhamos muitos bons momentos! Obrigada, amo vocês.

À Universidade Estadual de Campinas, instituição que possibilitou a realização deste trabalho. Também agradeço aos professores e também amigos da Pontifícia Universidade Católica de Goiás que também foram importantes nesta caminhada.

Ao Instituto Nacional de Ciência e Tecnologia - Medicina Assistida por Computação Científica (INCT-MACC), pelo apoio financeiro (Processo 573710/2008-2 Edital MCT/CNPq N° 015/2008 - Institutos Nacionais de Ciência e Tecnologia).

E, por fim, mas sem menos importância, gostaria também de agradecer aos meus colegas, mais do que isso, amigos, do Laboratório de Informática Visual (LIV) com os quais pude sempre contar.

A todos vocês que, de uma forma ou de outra, contribuíram para que este trabalho se realizasse. Muito obrigada!

Sumário

Resumo	v
Abstract	vi
Agradecimentos	vii
1 Introdução	1
1.1 Apresentação	1
1.2 Motivações	2
1.3 Objetivos e Contribuições	3
1.4 Organização do Texto	3
2 Conceitos e Trabalhos Relacionados	5
2.1 Resolução de Imagens	5
2.2 Extração de Características	6
2.3 Detecção de Pontos de Interesse	7
2.4 Mapeamento Localmente Linear	9
2.5 Super-Resolução de Imagens	10
2.5.1 Métodos Baseados em Realce de Detalhes	10
2.5.2 Métodos Baseados em Reconstrução	11
2.5.3 Métodos Baseados em Aprendizado	14
3 Métodos Propostos	17
3.1 Super-Resolução de Única Imagem	17
3.2 Super-Resolução de Múltiplas Imagens	22
4 Resultados Experimentais	27
4.1 Configuração do Ambiente	27
4.2 Amostras de Dados	27
4.3 Métricas de Avaliação	29

4.4	Experimentos para Única Imagem	30
4.5	Experimentos para Múltiplas Imagens	37
4.6	Discussão	42
5	Conclusões e Trabalhos Futuros	44
	Bibliografia	46

Lista de Tabelas

4.1	Média do resultados da avaliação entre 20 amostras obtidas com os métodos de super-resolução.	34
4.2	Resultados do RMSE para os métodos super-resolução com fator de ampliação igual a 2.	35
4.3	Média dos resultados da avaliação entre 5 amostras obtidas com os métodos testados.	35
4.4	Valor de RMSE para 5 amostras de imagens de mamografia obtidas com os métodos testados.	37
4.5	Resultados obtidos com os métodos de super-resolução de múltiplas imagens, fator de ampliação igual a 2.	40
4.6	Resultados obtidos com os métodos de super-resolução de múltiplas imagens, fator de ampliação igual a 4.	41
4.7	Resultados obtidos com os métodos de super-resolução de múltiplas imagens, fator de ampliação igual a 4.	42

Lista de Figuras

1.1	Exemplos de imagem (a) em baixa resolução e (b) em alta resolução. Imagens extraídas de [47].	2
2.1	Diagrama HOG.	7
2.2	Diagrama HSC. Adaptado de [43].	8
2.3	Passos do algoritmo LLE. Adaptado de [38].	9
3.1	Processamento nas imagens do conjunto de treinamento.	18
3.2	Fluxograma básico do método proposto para imagens. Adaptado de Yu et al. [52].	19
3.3	Método proposto para super-resolução de única imagem.	20
3.4	Processamento no conjunto de treinamento gerado pela sequência de imagens.	23
3.5	Fluxograma básico do método proposto para múltiplas imagens.	25
3.6	Método proposto para super-resolução de sequência de imagens.	26
4.1	Algumas amostras da base FERET utilizadas para teste [37].	28
4.2	Algumas imagens de mamografia [11].	28
4.3	Exemplos de quadros da sequência de vídeo de táxi utilizada [30].	29
4.4	Exemplos de quadros da sequência de vídeo de pessoa utilizada [5].	29
4.5	Processo de reamostragem. (a) imagem de baixa resolução; (b) imagem de alta resolução com o método GPP.	31
4.6	Descritores HOG e HSC.	32
4.7	Número de vizinhos.	33
4.8	Número de iterações \times valor da variável α	34
4.9	Alguns resultados obtidos a partir das técnicas avaliadas com fator de ampliação igual a 2.	36
4.10	Alguns resultados obtidos a partir das técnicas avaliadas com fator de ampliação igual a 2.	38
4.11	Correspondência entre duas imagens para realização do processo de fusão.	39
4.12	Estimação do número de iterações em função do RMSE. Parâmetros α e número de iterações.	40

4.13	Resultados obtidos para fator de ampliação 2 e 4 e para sequências com 6 e 12 quadros.	41
4.14	Resultados obtidos a partir das técnicas avaliadas com fator de ampliação de 4×. (a) imagem original; (b) IBP; (c) POCS; (d) método proposto. . . .	42

Lista de Abreviaturas e Siglas

GPP	<i>Gradient Profile Prior</i>	
HOG	<i>Histogram of Oriented Gradients</i>	Histograma de Gradientes Orientados
HR	<i>High Resolution</i>	Alta Resolução
HSC	<i>Histogram of Shearlet Coefficients</i>	Histograma de Coeficientes da Transformada Shearlet
IBP	<i>Iterative Back-Projection</i>	Retroprojeção Iterativa
LLE	<i>Locally-Linear Embedding</i>	Mapeamento Localmente Linear
LR	<i>Low Resolution</i>	Baixa Resolução
POCS	<i>Projection Onto Convex Sets</i>	Projeções em Conjuntos Convexos
RMSE	<i>Root Mean Square Error</i>	Raiz do Erro Médio Quadrático
SIFT	<i>Scale Invariant Feature Transform</i>	Transformada de Características Invariante à Escala
SR	<i>Super-Resolution</i>	Super-Resolução
SSIM	<i>Structural SIMilarity</i>	Índice de Similaridade Estrutural

Capítulo 1

Introdução

Este capítulo apresenta uma introdução sobre super-resolução, os problemas relacionados e suas aplicações. É incluída uma breve descrição das motivações que levaram ao desenvolvimento deste trabalho, seguida de seus principais objetivos e de suas contribuições. Finalmente, a organização da dissertação é apresentada.

1.1 Apresentação

A resolução digital de uma imagem está diretamente relacionada à sua qualidade. Essa resolução refere-se ao nível de detalhe de sua representação visual, ou seja, quanto maior a resolução, maior é a sua precisão ao representá-la em relação à imagem real [7, 55].

Algumas imagens sofrem um processo de degradação de sua qualidade (imagens em baixa resolução) devido a alguns fatores, tais como aberrações das lentes, focalização incorreta, deslocamento do sensor durante a aquisição, deslocamento do objeto, deficiência ou excesso de iluminação [12]. Estes fatores dificultam a segmentação de regiões e a visualização precisa de detalhes presentes nas imagens.

Em diversos domínios de conhecimento, tais como medicina, biologia, geologia, automação industrial, vigilância, sensoriamento remoto, há uma grande demanda de imagens com alta resolução espacial [8, 12, 35, 40, 49, 56].

Em virtude de fatores associados ao custo e às limitações dos dispositivos de aquisição, uma alternativa é aumentar a resolução e melhorar a qualidade psicovisual das imagens por meio da aplicação de técnicas conhecidas como super-resolução (SR).

Técnicas de SR têm recebido crescente interesse nos últimos anos [3, 9, 23, 26, 48], cujo objetivo principal é aumentar a resolução espacial das imagens, removendo distorções causadas na aquisição, realçando detalhes, como bordas, ou recuperando informações importantes a partir do conjunto de imagens capturadas [55].

As técnicas de SR podem ser aplicadas em uma única imagem, em uma sequência

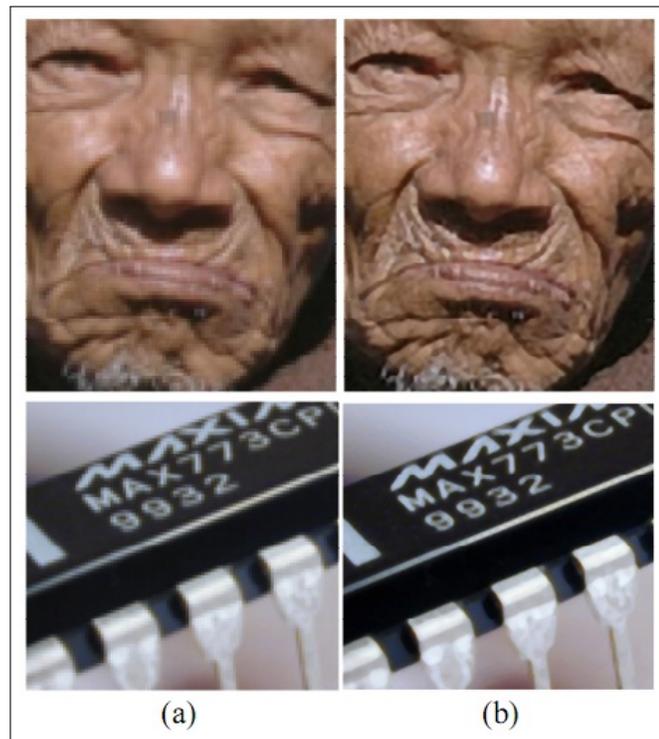


Figura 1.1: Exemplos de imagem (a) em baixa resolução e (b) em alta resolução. Imagens extraídas de [47].

de imagens ou ainda em vídeos [42]. Métodos de super-resolução em uma única imagem visam aumentar a resolução da imagem a partir do realce de suas informações mais relevantes, sem a introdução de borramento. A Figura 1.1 ilustra duas imagens em baixa e alta resolução. Métodos de super-resolução em múltiplas imagens procuram criar uma imagem com mais alta resolução (HR, do inglês, *High Resolution*) a partir da fusão de informações presentes em múltiplas imagens de baixa resolução (LR, do inglês, *Low Resolution*). Métodos de super-resolução em vídeos visam criar um vídeo de alta resolução a partir dos quadros de baixa resolução.

1.2 Motivações

Em muitas aplicações, uma imagem ou uma sequência de imagens apresenta baixa qualidade devido, em geral, às várias limitações físicas dos sensores, tais como resolução espacial limitada, distorções ópticas, presença de ruído e alcance dinâmico limitado. Além disso, podem existir manchas (regiões de borramento) de movimento que introduzem degradação significativa na imagem [2].

De modo geral, essas degradações comprometem seriamente o processo de análise de

imagens. Em sistemas de vigilância, por exemplo, imagens capturadas a partir de câmeras de baixo custo podem dificultar o reconhecimento de indivíduos ou a identificação de placa de veículo em uma determinada cena [22]. Além disso, uma pessoa ou objeto normalmente ocupa uma região pequena no campo de visão da câmera, tal que a porção de pixels de interesse na imagem é geralmente bem pequena.

Outra aplicação importante é a área médica. O uso de imagens em alta resolução pode auxiliar o diagnóstico de doenças em estágio inicial, por exemplo, a identificação precisa de um tumor em imagens médicas [31, 54, 55].

Em sensoriamento remoto, imagens multiespectrais de alta resolução espacial são cruciais para fornecer informações detalhadas relativas ao uso e mapeamento da terra, taxas de erosão, desmatamento e cobertura do solo, monitoração de áreas de plantio, entre outras aplicações [12].

Outros exemplos de demanda de dados em alta resolução incluem a recuperação de imagens e vídeos antigos, a remoção de distorções e ruídos gerados durante a compressão de imagens e vídeos, a geração de fotografias panorâmicas a partir de imagens com menor resolução.

Dessa forma, o desenvolvimento de técnicas para aumentar a nitidez dos detalhes das imagens torna-se importante para melhorar as etapas subsequentes de análise e interpretação dos dados presentes nas imagens.

1.3 **Objetivos e Contribuições**

Este trabalho apresenta um método baseado em aprendizado para geração de imagens em alta resolução a partir de versões correspondentes em baixa resolução. Dois métodos são propostos, um para super-resolução de única imagem e uma adaptação deste método para super-resolver múltiplas imagens de baixa resolução em uma imagem de alta resolução, combinando aprendizado e reconstrução de imagens.

Técnicas existentes na literatura correlatas ao tema sob investigação são estudadas e comparadas com o método proposto. Experimentos realizados em conjuntos de imagens são utilizados para demonstrar a eficácia do método baseada em medidas quantitativas e qualitativas.

1.4 **Organização do Texto**

O presente trabalho está organizado como segue. O Capítulo 2 apresenta um resumo de algumas das principais técnicas de super-resolução encontradas na literatura aplicadas a imagens e vídeos. O Capítulo 3 descreve os métodos propostos neste trabalho. O

Capítulo 4 apresenta e discute os resultados experimentais obtidos a partir da aplicação do método em única imagem e em sequências de imagens, bem como uma comparação com outros métodos de super-resolução. As conclusões obtidas com esta investigação e propostas para trabalhos futuros são descritas no Capítulo 5.

Capítulo 2

Conceitos e Trabalhos Relacionados

Este capítulo apresenta conceitos e trabalhos relacionados à super-resolução relevantes para os métodos propostos no Capítulo 3. Inicialmente, alguns fundamentos relativos aos processos de aquisição e melhoramento de imagens são descritos. Em seguida, o processo de extração de características é descrito, bem como dois métodos utilizados neste trabalho. Então, apresenta-se um método para detecção de pontos de interesse e um método de aprendizado, ambos utilizados nos experimentos descritos no Capítulo 4. Finalmente, trabalhos relevantes existentes na literatura para abordar o problema de super-resolução em imagens e vídeos são apresentados e discutidos.

2.1 Resolução de Imagens

Uma imagem pode ser definida como uma função de intensidade luminosa, $\mathbf{I}(x, y)$, tal que o valor em suas coordenadas espaciais (x, y) provê a intensidade ou o brilho da imagem no ponto (*pixel*). Uma imagem digital pode ser obtida a partir de um processo chamado digitalização que consiste em dois passos, a amostragem e a quantização [36].

A amostragem é responsável por discretizar o domínio da imagem nas direções x e y , formando uma matriz de $M \times N$ amostras, respectivamente. A quantização é responsável por definir um número inteiro L de níveis de cinza ou cores possíveis para cada ponto da imagem. A adequada determinação do número de amostras e de níveis para gerar uma imagem de boa qualidade depende essencialmente da quantidade de informação presente na imagem e do grau de detalhe perceptível ao sistema visual humano. A qualidade de uma imagem digital normalmente está associada a dois tipos de resolução, espacial e radiométrica.

A resolução espacial está relacionada com a dimensão dos menores detalhes visíveis na imagem. Quanto menor for o intervalo de amostragem entre os pontos da imagem, isto é, quanto maior a densidade de pontos na imagem, maior será a resolução espacial

da imagem. Isto não significa que uma imagem contendo um grande número de pixel necessariamente possui maior resolução espacial do que outra com menor número de pixel.

A resolução radiométrica consiste na quantificação de radiação eletromagnética empregada para amostrar a luminosidade refletida pela cena. O número de níveis de quantização da imagem normalmente é uma potência de 2, ou seja, $L = 2^b$, em que b corresponde ao número de bits necessários (profundidade) para representar os níveis de quantização.

Em conjunto com o processo de digitalização, alguns fatores que contribuem para a degradação da qualidade de uma imagem digital [3] incluem a aberração de lentes dos sensores, o foco incorreto, o deslocamento do sensor ou do objeto durante a aquisição da imagem e o excesso ou insuficiência de iluminação na cena.

2.2 Extração de Características

Características são propriedades relevantes que podem ser mensuradas em imagens ou objetos presentes nas imagens, tais como cor, forma e textura. Tais características normalmente são extraídas por meio de descritores (de características) e organizadas como elementos de um vetor, denominado vetor de características. O conjunto de todos os possíveis vetores de características forma um espaço de características.

Uma função de distância é associada aos vetores de características para indicar o grau de similaridade dos objetos das imagens com base em suas propriedades. Assim, objetos da imagem com características similares podem ser classificadas como pertencentes a uma classe específica. Descritores de características devem idealmente ser invariantes a transformações afins, tal que objetos em imagens possam ser reconhecidos independentemente de escala, translação ou rotação.

Características podem ser extraídas de maneira global ou local para formar descritores de imagens. Um descritor global considera a informação extraída de toda a imagem, o que normalmente constitui uma representação compacta da imagem. Os métodos de extração de características globais são tipicamente rápidos, entretanto, nem sempre adequados para discriminar detalhes ou robustos a variações nas imagens. Por outro lado, características locais são extraídas de porções específicas da imagem, tais como regiões, fronteiras entre objetos ou pontos de interesse.

Vários descritores locais e globais têm sido apresentados na literatura [1, 16, 19, 36, 44]. Este trabalho utiliza dois descritores no processo de super-resolução de imagens, os quais são apresentados a seguir.

HOG O histograma de gradientes orientados (HOG, do inglês, *Histogram of Oriented Gradients*) [10] é um descritor que mede a distribuição da orientação de gradientes ou das direções das bordas em porções da imagem.

No trabalho que primeiramente descreve o histograma [10], o método foi utilizado na detecção de pedestres em imagens estáticas, entretanto, seu uso se difundiu em diversas aplicações de visão computacional e processamento de imagens.

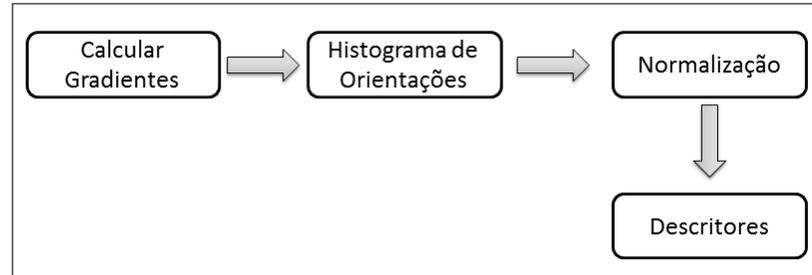


Figura 2.1: Diagrama HOG.

A extração do HOG dá-se da seguinte maneira, conforme apresentado no diagrama 2.1. A imagem é dividida em pequenas regiões e, para cada região, constrói-se um histograma de orientações dos gradientes para cada pixel no interior da região. O descritor é representado pela combinação desses histogramas [10, 32]. Uma medida de intensidade em uma região maior da imagem pode ser utilizada para normalizar todos os valores do histograma, o que pode resultar em melhor invariância quanto a mudanças em iluminação.

HSC O histograma de coeficientes da transformada shearlet (HSC, do inglês, *Histogram of Shearlet Coefficients*) [43] é um descritor que captura informação de bordas em múltiplas escalas e orientações por meio da transformada shearlet [21, 51].

As transformadas shearlets apresentam certas vantagens com relação às transformadas wavelets, particularmente no que diz respeito à limitada sensibilidade direcional das bordas presentes nas imagens. Em cada nível de decomposição da transformada shearlet, o descritor estima um histograma formado pelas intensidades das bordas em diferentes orientações. Todos os histogramas são então concatenados e normalizados para compor o vetor de características, conforme diagrama 2.2.

2.3 Detecção de Pontos de Interesse

A transformada de características invariante à escala (SIFT, do inglês, *Scale Invariant Feature Transform*), desenvolvida por Lowe [25, 24], é um método para extração de pontos de interesse em imagens. O algoritmo é executado através de quatro etapas principais. O primeiro passo consiste na detecção de pontos extremos, o segundo na localização de pontos-chave, o terceiro na atribuição da orientação do gradiente e, por último, a descrição dos pontos-chave.

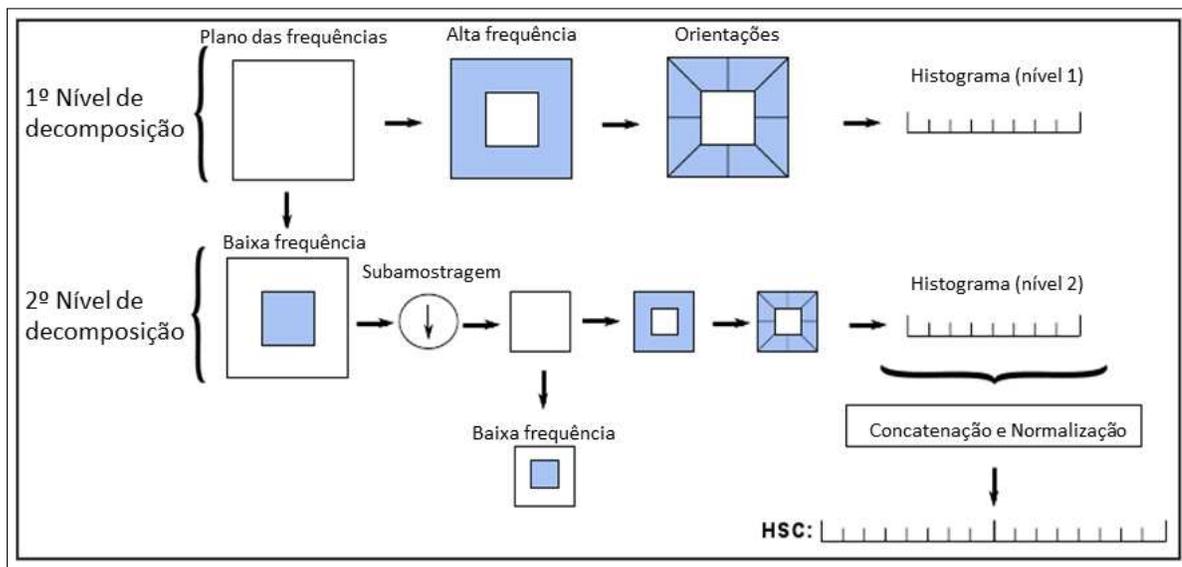


Figura 2.2: Diagrama HSC. Adaptado de [43].

Na detecção de pontos extremos, o algoritmo procura características estáveis em diferentes escalas por meio de uma função de espaço-escala Gaussiana. O objetivo é procurar pontos que sejam invariantes a mudanças de escala. Todos os pontos detectados como extremos, nesta primeira etapa, são candidatos a pontos-chave.

Na segunda etapa, deseja-se calcular a localização exata dos pontos-chave. Esta etapa consiste em ajustar uma função quadrática 3D do ponto de amostragem local de modo a determinar uma localização interpolada do máximo.

Na terceira etapa, a cada ponto-chave é atribuído uma orientação baseando-se em propriedades locais da imagem. Nesta etapa, um histograma de orientações é formado a partir do gradiente de orientações de pontos amostrais em uma região em torno do ponto chave localizado. Este histograma cobre uma região de 360 graus de orientações e, para cada amostra adicionada ao histograma, a mesma é mensurada pelo seu gradiente de magnitude e por uma janela Gaussiana.

A última etapa consiste na atribuição, para cada ponto-chave, de um descritor invariante à iluminação e ao ponto de vista 3D. Para cada imagem, diversos descritores são gerados, cada um referente a um ponto chave. Nesta fase, o resultado refere-se a um conjunto de descritores robustos que podem ser utilizados para realizar a correspondência entre duas imagens, inclusive em condições de ruído e oclusão.

2.4 Mapeamento Localmente Linear

O método de mapeamento localmente linear (LLE, do inglês, *Locally-Linear Embedding*), proposto por Roweis e Saul [38], consiste na projeção multidimensional de dados detectando-se as características locais em uma variedade topológica (*manifold*). A variedade possui aproximada linearidade local em todos os pontos, assumindo que os dados estão sobre ela ou muito próximos dela, a mesma é tratada como uma união de vários retalhos [29].

Considera-se que cada ponto $X_i \in R^m$ possui um número de vizinhos mais próximos e que $Y_i \in R^n$ seja sua representação na baixa dimensão. A ideia consiste em expressar cada X_i como uma combinação linear de seus vizinhos e, em seguida, construir os Y_i expressos pela mesma combinação linear dos seus correspondentes vizinhos.

O método LLE possui três fases, como ilustra a Figura 2.3. Na primeira fase, calcula-se para cada ponto X_i a distância para os outros pontos X_j . Em seguida, encontra-se os k melhores coeficientes possíveis que aproximam cada ponto X_i por uma combinação linear ponderada dos pontos que se encontram na sua vizinhança. O conjunto desses coeficientes constitui os pesos de reconstrução, para cada ponto X_i , na segunda fase do algoritmo.

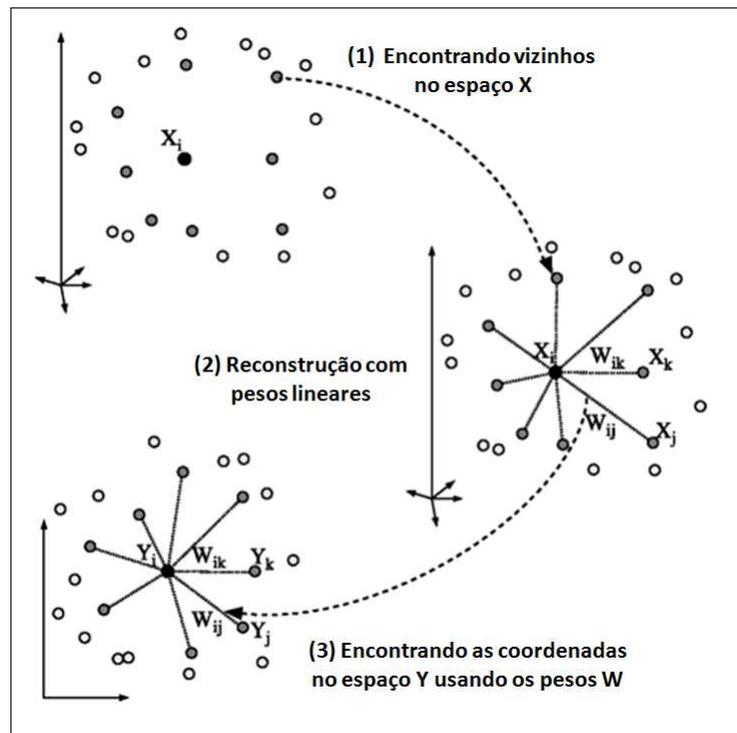


Figura 2.3: Passos do algoritmo LLE. Adaptado de [38].

Na última fase, fixando-se os pesos obtidos a partir dos pontos em alta dimensão, o

método busca um conjunto de pontos Y_i de baixa dimensionalidade que possa ser linearmente aproximado, ou seja, reconstruído pela combinação dos pontos vizinhos ponderados pelos coeficientes já fixados na primeira fase.

2.5 Super-Resolução de Imagens

Vários métodos de super-resolução têm sido propostos na literatura para melhorar a resolução espacial das imagens, de modo a realçar detalhes, sem a adição de artefatos na imagem resultante. O objetivo principal desses métodos é estimar uma imagem de alta resolução (HR, do inglês *High-Resolution*) a partir de uma ou mais imagens de baixa resolução (LR, do inglês *Low-Resolution*).

As principais abordagens existentes podem ser classificadas em três categorias: métodos baseados em realce de detalhes, métodos baseados em reconstrução e métodos baseados em aprendizado. Essas abordagens são descritas a seguir.

2.5.1 Métodos Baseados em Realce de Detalhes

Nos métodos baseados em realce de detalhes, a estimação dos valores dos pixel na imagem de alta resolução é realizada pela interpolação da intensidade ou cor dos pixel já existentes na imagem de entrada. Posteriormente, aplica-se um processo para reduzir os artefatos inseridos nas imagens interpoladas.

Há vários métodos de interpolação existentes na literatura [18, 27, 36], os mais comumente utilizados são a interpolação por vizinho mais próximo, a bilinear e a bicúbica.

No interpolador por vizinho mais próximo, o valor original do pixel $f(x, y)$ é atribuído ao pixel $f'(x', y')$ mais próximo na imagem reamostrada. O método é simples e apresenta baixo custo computacional. O valor reamostrado é seguramente um dos valores originais e o desempenho depende da preservação de contraste. Suas principais desvantagens consistem na geração de distorções em detalhes finos ou criação de bordas serrilhadas na imagem.

O interpolador bilinear calcula a intensidade do valor de cada pixel $f'(x', y')$ por meio da média ponderada de distância dos quatro pixels vizinhos mais próximos. A imagem resultante apresenta uma suavização nas bordas e distorção de fase, causando o efeito de borramento da imagem.

A interpolação bicúbica procura obter uma estimativa suave do nível de cinza ou cor em cada pixel $f'(x', y')$ a partir de um número maior de pontos vizinhos da imagem original, os quais formam um polinômio de baixo grau. Na imagem resultante, os detalhes finos são preservados, bordas são suavizadas e as distorções são minimizadas.

Uma análise comparativa de métodos de reamostragem para super-resolução em vídeos foi realizada em trabalho anterior desta autora [40], em que quadros do vídeo são super-resolvidos utilizando-se o método POCS (descrito posteriormente). A grade de alta resolução é gerada pela interpolação por vizinho mais próximo, bilinear, bicúbica e *sinc*. A interpolação *sinc* é um método para representar sinais com um decaimento monotônico do espectro de suas amostras [50], em que um sinal contínuo $f(x)$ é restaurado a partir de suas amostras f_n que são tomadas com um intervalo de amostragem Δx pela interpolação com a função $\text{sinc}(x) = \frac{\text{sen}(\pi x)}{\pi x}$.

O método de super-resolução *Gradient Profile Prior* (GPP) é uma distribuição paramétrica que descreve a forma e a nitidez dos perfis de gradiente na imagem natural. Uma das observações apresentadas em [46, 47] é que a forma estatística desses perfis é estável e invariante na resolução da imagem. A partir dessa informação, pode-se aprender a relação estatística de nitidez do perfil de gradiente entre a imagem HR e a imagem LR.

Utilizando-se relacionamento e o perfil de gradiente aprendido, é possível fornecer uma restrição sobre o gradiente de campo da imagem HR. Combinando com a restrição de reconstrução pode-se então recuperar uma imagem de HR de alta qualidade. As vantagens do GPP citadas em [46, 47] incluem: (a) o perfil de gradiente não é uma restrição de suavidade, assim, tanto em pequena escala quanto em grande escala, as bordas podem ser bem recuperadas na imagem HR; (b) os artefatos comuns em super-resolução, tais como serrilhamento de bordas, podem ser evitados com o trabalho no domínio do gradiente.

A imagem de alta resolução na técnica GPP pode ser obtida da seguinte equação

$$\text{HR}^{t+1} = \text{HR}^t - \tau \frac{\partial \text{E}(\text{HR})}{\partial \text{HR}} \quad (2.1)$$

em que $\frac{\partial \text{E}(\text{HR})}{\partial \text{HR}} = ((\text{HR} * G) \downarrow - \text{LR}) \uparrow * G - \beta(\nabla^2 \text{HR} - \nabla^2 \text{HR}^T)$, $\nabla^2 \text{HR}^T(x) = r(d(x, x_0)) \nabla^2 \text{LR}^u$, G representa o filtro espacial Gaussiano, $*$ é o operador de convolução, \downarrow é o operador *down-sampling* $\nabla^2 \text{HR}^T$ representa o gradiente de campo transformado da imagem HR, $\nabla^2 \text{LR}^u$ representa o gradiente de campo da imagem LR e \uparrow é o operador *up-sampling*. O termo $\nabla^2 \text{HR}^T$ transforma o gradiente de campo observado para o gradiente de campo alvo por meio do mapeamento da forma e da nitidez do perfil de gradiente observado.

2.5.2 Métodos Baseados em Reconstrução

Métodos baseados em reconstrução consistem na síntese de uma única imagem de alta resolução a partir de uma sequência de imagens de baixa resolução [4, 39]. Nestes métodos, assume-se que as imagens capturadas de baixa resolução (LR) têm grande similaridade

entre si. São poucas as informações que as diferenciam, o que permite a geração de novas informações para a recuperação dos detalhes da imagem em alta resolução (HR) [35, 56].

No entanto, a utilização de uma sequência de imagens com movimento pode trazer algumas dificuldades. Isto ocorre devido aos erros que podem ser gerados na estimativa de movimento ou aos objetos que aparecem em uma imagem e desaparecem em outras. Nestes casos, para que se possa aproveitar a informação do movimento de *subpixel*, é necessário que o algoritmo utilizado para a super-resolução seja robusto aos erros gerados na representação do movimento [56].

Os métodos baseados em reconstrução recuperam detalhes das sequências e adiciona-os na imagem estimada de alta resolução. Geralmente possuem três fases distintas: i) registro das imagens; ii) geração da grade de alta resolução, onde seus valores são interpolados a partir das imagens registradas; iii) remoção dos ruídos [34].

Irani e Peleg [20] desenvolveram uma técnica, denominada retroprojeção iterativa (IBP, do inglês, *Iterative Back-Projection*), similar ao método de *back-projection* desenvolvido para reconstrução de imagens tomográficas. Cada pixel de baixa resolução é modelado como a projeção de uma determinada região na imagem de alta resolução que será estimada. O método apresentou resultados satisfatórios considerando, para análise, apenas movimentos de translações e rotações.

O processo inicia-se com uma primeira estimativa de alta resolução, a partir do modelo de formação apresentado na Equação 2.2, para simular as imagens de baixa resolução. Iterativamente, adiciona-se informações a esta imagem estimada, a partir de uma nova imagem gradiente, com base no erro entre as imagens simuladas e as imagens observadas [28]. Essa imagem gradiente corresponde à soma de todos os erros entre a imagem de baixa resolução e a imagem de alta resolução estimada pelo processo de transformação dado pela estimativa de movimento entre as imagens de baixa resolução.

$$\text{LR}_k(m, n) = \sigma_k(h(\text{HR}(x, y)) + \eta_k(x, y)), \quad (2.2)$$

em que LR_k é o k -ésimo quadro observado; HR é a cena original, h é o operador de borramento, η_k é o ruído adicionado, σ_k é uma função não linear que digitaliza e decima a imagem em pixels e quantifica os valores dos pixels resultantes das intensidades em níveis de cinza e (x, y) é o centro da área receptiva em HR do detector cuja saída é $\text{LR}_k(m, n)$.

O método utiliza um procedimento iterativo para minimização do erro entre os dados originais e a saída do modelo [55], conforme equação

$$\text{HR}_k^{n+1} = \text{HR}_k^n + \sum_{j=1}^L \text{H}_{k,j}^{BP}(\text{LR}_j - \text{C}_{j,k} \text{HR}_k^n) \quad (2.3)$$

em que HR_k^{n+1} é uma imagem de alta resolução no instante k , $\text{H}_{k,j}^{BP}$ é o operador de *back-projection*, n é a iteração corrente, L é o número de imagens de baixa resolução

(representadas por LR) e $C_{j,k}$ é a matriz de transformação conjunta de movimento e aquisição.

O método IBP é muito similar aos métodos iterativos para solução de mínimos quadrados, como o Jacobi [41]. Uma de suas vantagens é a velocidade de convergência, a qual está associada ao operador *back-projection* [55]. Quando o algoritmo é aplicado em uma única imagem, o algoritmo reduz o borramento da imagem. Para sequências de imagens, é necessário o conhecimento exato dos deslocamentos nas cenas.

Projeções em conjuntos convexos, (POCS, do inglês, *Projection Onto Convex Sets*), também conhecido como método de projeções convexas, utiliza a imagem de baixa resolução para produzir, através de deslocamentos *subpixel* nas linhas e colunas, uma outra imagem. O deslocamento tem como objetivo minimizar os efeitos de *aliasing* e possibilitar a recuperação de novas informações para a imagem de alta resolução.

O método POCS tenta solucionar o problema a partir de informações a priori descritas sob a forma de conjuntos de restrições convexas [45]. A busca dessa solução consiste em encontrar um valor que pertence à intersecção entre os conjuntos. Este é um método iterativo, que produz, para um número finito de passos, soluções intermediárias. A iteração termina quando ocorre a convergência ou o processo é interrompido por um critério previamente estabelecido [33].

A imagem LR é tratada como um vetor em um espaço de Hilbert e as restrições conhecidas são descritas na forma de conjuntos convexas sobre esse espaço. Assume-se, dessa forma, que há um total de m conjuntos C_1, C_2, \dots, C_m avaliados. A intersecção desses conjuntos (Equação 2.4) conterá todas as possíveis soluções do problema, pois cada uma delas satisfaz a uma das informações desconhecidas.

$$C_0 = \bigcap_{i=1}^m C_i \quad (2.4)$$

Admitindo o ponto x_0 como uma estimativa inicial, o algoritmo POCS é representado pela equação

$$x_{k+1} = P_{C_m} \dots P_{C_2} P_{C_1} x_k, \quad \text{para } k = 0, 1, 2, \dots \quad (2.5)$$

Algumas melhorias nos métodos de reconstrução por super-resolução baseado no método POCS foram propostas por Patti e Altunbasak [35]. Primeiro, a discretização do modelo de formação de imagens contínuas é melhorada para permitir o uso de métodos de interpolação de alta ordem. Segundo, os conjuntos de restrição são modificados para reduzir a quantidade de bordas presentes na imagem de alta resolução estimada.

O método de super-resolução utilizado em [48, 49] é baseado no método das projeções em conjuntos convexas (POCS), modificado para utilizar um interpolador *sinc*, ao invés dos interpoladores tradicionalmente utilizados como vizinho mais próximo, bilinear, convolução cúbica e deslocamentos *subpixel*. A interpolação *sinc* é utilizada para produzir a

grade de alta resolução no algoritmo POCS. Este método utiliza a imagem de baixa resolução para produzir, através de deslocamentos *subpixel* nas linhas e colunas, uma outra imagem. O deslocamento tem como objetivo minimizar os efeitos de *aliasing* e possibilitar a recuperação de novas informações para a imagem de alta resolução. O método proposto apresenta boa super-resolução das imagens preservando a informação na maior parte dos casos.

Reconstrução por super-resolução produz uma imagem ou um conjunto de imagens de alta resolução a partir de um conjunto de imagens de baixa resolução. Nas últimas duas décadas, vários métodos de super-resolução têm sido propostos, alguns deles apresentados em [4, 14]. Estes métodos são frequentemente muito sensíveis ao seu modelo presumido de dados e ruídos, o que limita sua utilidade. Em [15] foi proposta uma abordagem alternativa usando normas de minimização e regularização robusta antes de lidar com diferentes modelos de dados e ruídos.

Devido à baixa qualidade e a degradação significativa das imagens, um desafio interessante é fundir muitas imagens em uma de alta qualidade. Este foi o método proposto em [2]. Primeiro, um objeto de interesse é rastreado através da sequência de imagens. Depois, a degradação das imagens é modelada em termo de pixels amostrados, manchas (ou regiões de borramento) de desfoco e de movimento. A magnitude e a direção das regiões de movimento são estimadas através do monitoramento dos deslocamentos. Finalmente, a imagem em alta resolução sem mancha é reconstruída.

Schultz et al. [42] apresentam uma abordagem de como usar as informações temporais e espaciais em uma pequena sequência de imagens para criar um quadro único de vídeo de alta resolução. Sua abordagem propõe um modelo de observação com base na subamostragem de movimento compensado.

2.5.3 Métodos Baseados em Aprendizado

Nos métodos de super-resolução baseados em aprendizado o objetivo consiste em estimar informações, que não estão presentes na imagem original de baixa resolução, a partir de um conjunto de amostras de treinamento.

O método proposto por Yu et al. [52] para super-resolução de imagens de faces utiliza o método de projeção de conjuntos convexos (POCS) e compensação de resíduo. Primeiramente, a imagem de alta resolução inicial é estimada pelo método POCS e em seguida a compensação do resíduo é efetuada. As informações de alta frequência na imagem são reconstruídas a partir do aprendizado entre os dois conjuntos de bases de treinamento de resíduos de imagens de baixa e alta resolução correspondentes. A imagem de super-resolução é gerada a partir da soma entre a imagem inicialmente estimada e a imagem reconstruída pelos pesos dos resíduos aprendidos. O método utiliza o algoritmo de apren-

dizado de máquina chamado *Locally-Linear Embedding* (LLE) [6].

Primeiramente, o método reconstrói a imagem de alta resolução inicial estimada pelo método POCS (Seção 2.5.2), similar à imagem de alta resolução original. Em seguida, ele estima a compensação de resíduos e as informações de alta frequência são reconstruídas pelo aprendizado entre as correspondências dos conjuntos de imagens residuais de alta e baixa resolução. Supondo um conjunto de N vetores, com dimensão D [52], então

$$x = [x_1, x_2, \dots, x_i, \dots, x_N] \quad (2.6)$$

Para um novo vetor x_0 , a distância Euclidiana d_i entre todos os outros vetores de x é calculada como

$$d_i = \sqrt{(x_0 - x_i)^T(x_0 - x_i)} \quad (2.7)$$

Os K vizinhos mais próximos de x_0 são definidos pela distância Euclidiana e, com isso, os melhores pesos w para reconstruir x_0 a partir dos K vizinhos são determinados ($w = [w_1, w_2, \dots, w_i, \dots, w_N]$), em que w_i representa a contribuição de x_i para reconstrução de x_0 . Se x_i não está entre os K vizinhos mais próximos de x_0 , então $w_i = 0$, senão $0 < w_i < 1$ e $\sum_i w_i = 1$.

O peso w_i ótimo é estimado utilizando-se o algoritmo de mínimos quadrados

$$w_i = \frac{\sum_j P_{i,j}}{\sum_i \sum_j P_{i,j}} \quad (2.8)$$

em que $P = G^{-1}$ e G é a matriz de covariância definida como

$$G_{i,j} = (x_0 - x_i)^T(x_0 - x_j) \quad (2.9)$$

Dado que G é uma matriz singular, ou seja, não possui inversa, a solução ótima pode não ser encontrada pela Equação 2.9. Uma solução relativamente simples é carregar a diagonal de G utilizando um α pequeno

$$G = G + \alpha \times I \quad (2.10)$$

em que I é uma matriz unitária.

O método de aprendizado proposto em [52] considera uma imagem inicial de baixa resolução g obtida pela degradação de f ($g = Hf$) e uma estimativa inicial de super-resolução \hat{f} obtido pelo método POCS. Com o modelo de degradação conhecido H , o resíduo de baixa resolução é calculado como

$$\hat{g} = H\hat{f}r = g - \hat{g} \quad (2.11)$$

Utilizando o algoritmo LLE para aprender os pesos da reconstrução a partir do resíduo de baixa resolução r e da base de imagens residuais, reconstrói-se o resíduo de alta resolução \hat{s} a partir dos pesos encontrados e a base de dados correspondente em alta resolução. A partir do resíduo de alta resolução a imagem de super-resolução \hat{f}_{n+1} é obtida por

$$\hat{f}_{n+1} = \hat{f}_n + \alpha \hat{s} \in (0, 1] \quad (2.12)$$

Destobbeleire [13] propõe um método de super-resolução dividido em dois passos: preparação do conjunto de treinamento e a construção da banda de alta frequência que falta na imagem de entrada. Destobbeleire aplicou o algoritmo de único passo proposto em [17]. A técnica gerou bons resultados, principalmente no que se refere à textura. No entanto, em alguns casos, artefatos foram produzidos e ampliados quando se aumenta a imagem por um fator 4.

Rubert et al. [39] apresentam um algoritmo de super-resolução baseado em amostras de treinamento para estimar detalhes em altas frequências nas imagens reamostradas. O algoritmo é uma adaptação do método proposto por Freeman et al. [17] para operar apenas na componente de luminância Y do espaço de cores YUV, a fim de estimar as altas frequências perdidas no processo de reamostragem das imagens.

No algoritmo [39], as informações de detalhes das imagens são aprendidas a partir da relação existente entre os blocos de baixa e alta frequência. A estimativa de alta frequência é feita com base na imagem inicial de baixa resolução. Os resultados são comparados com a abordagem que utiliza o espaço de cores RGB. Com a redução de dimensionalidade do conjunto de amostras de treinamento diminuiu, conseqüentemente, o tempo computacional da aplicação.

O método proposto em [6] tem o objetivo de resolver o problema de super-resolução de uma única imagem. Dada uma imagem de baixa resolução como entrada, o método a recupera uma representação em alta resolução usando um conjunto de modelos de treinamento. Esta formulação se assemelha a outros métodos baseado em aprendizado, no entanto, o método apresentado foi inspirado no LLE. Os experimentos realizados mostram bons resultados.

Silva [9] apresenta uma técnica de super-resolução não Bayesiana, inspirada em Freeman et al. [17], que utiliza quadros chave em seqüências de vídeo de resolução mista. Na resolução mista, alguns quadros, os chamados quadros-chave, possuem resolução normal e os outros possuem resolução reduzida e precisam ser super-resolvidos. Na técnica descrita, a informação apresentada nos quadros-chave é processada para super-resolver os quadros não-chave que foram previamente subamostrados, desconsiderando treinamentos, distribuições de probabilidade e envio de informações adicionais do codificador ao decodificador por se tratar de uma técnica não-Bayesiana.

Capítulo 3

Métodos Propostos

Este capítulo apresenta os métodos a serem empregados neste trabalho para super-resolução (SR) de uma única imagem e de múltiplas imagens. Conforme descrito no capítulo anterior, há três abordagens principais para melhorar a resolução aparente de uma imagem: métodos baseados em realce de detalhes, métodos baseados em reconstrução e métodos baseados em aprendizado. Os métodos propostos neste trabalho baseiam-se em aprendizado, em que se busca estimar a informação de detalhes que não está presente nas imagens originais de baixa resolução por meio de amostras de treinamento. A técnica de super-resolução por aprendizado foi inspirada no trabalho de Yu et al. [52], que utiliza compensação residual.

Foram desenvolvidos dois métodos. Um método foi desenvolvido para super-resolver uma única imagem e uma adaptação do mesmo para super-resolver uma sequência de imagens que serão combinadas em uma única imagem de alta resolução. Para melhor explicar, este capítulo foi dividido em duas seções. A Seção 3.1 apresenta o algoritmo proposto para super-resolução de imagens. A Seção 3.2 apresenta o algoritmo proposto para super-resolução de uma sequência de imagens.

3.1 Super-Resolução de Única Imagem

Como mencionado anteriormente, o método proposto é baseado em aprendizado. Para uma única imagem, considera-se um conjunto de treinamento contendo pares de imagens de alta e baixa resolução.

Para super-resolver uma imagem, utiliza-se a compensação residual iterativa [52] ampliada por um dado fator de escala. O resíduo da imagem super-resolvida é obtido com a utilização de um conjunto de treinamento e o método de aprendizado LLE, descrito na Seção 2.4. O conjunto de treinamento possui imagens em alta resolução (HR), a partir das quais são estimadas imagens residuais em baixa e alta resoluções.

O LLE é aplicado para estimação de pesos associados com imagens residuais em baixa resolução (LR), que serão utilizados para estimar os resíduos da imagem de alta resolução, por meio de uma soma ponderada de imagens residuais em alta resolução.

Anteriormente à execução do método proposto, as imagens de treinamento são pré-processadas, conforme ilustra o diagrama mostrado na Figura 3.1. Tal processamento se faz necessário a fim de que se torne possível o cálculo do resíduo pela soma ponderada entre vários resíduos de alta resolução encontrados a partir de seus correspondentes em baixa resolução.

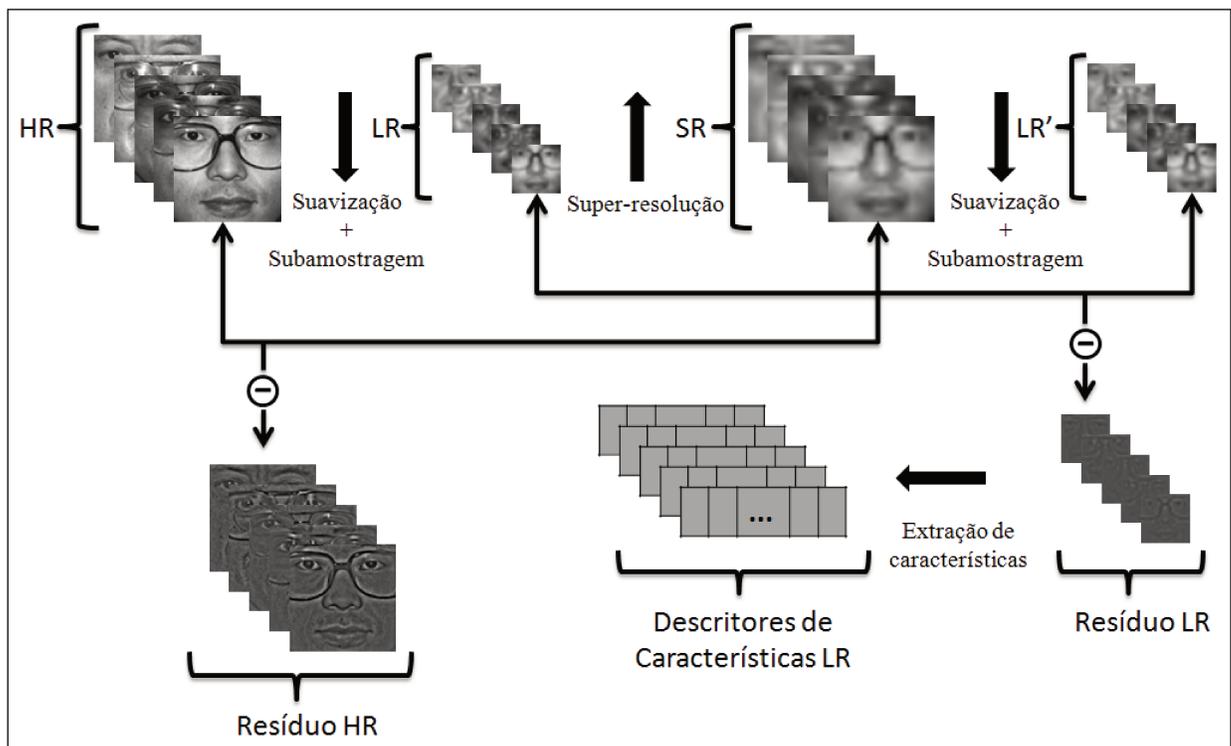


Figura 3.1: Processamento nas imagens do conjunto de treinamento.

Como as imagens de testes estão em baixa resolução, é necessário determinar, no conjunto de treinamento, os resíduos de baixa e de alta resolução correspondentes. Conforme o diagrama, as imagens de treinamento em alta resolução são suavizadas e subamostradas gerando as imagens em baixa resolução.

As imagens da base de treinamento e as imagens de teste devem pertencer a um mesmo contexto (categoria de imagens), ou seja, apresentarem razoável índice de similaridade.

Para se obter os resíduos de alta resolução, as imagens LR são reamostradas para a mesma resolução da imagem original, gerando-se as imagens SR. Assim, os resíduos de alta resolução são determinados pela diferença entre as imagens HR e SR. Este resíduo será utilizado na compensação residual na imagem SR resultante. No entanto, os resíduos

de alta resolução são determinados a partir de seus correspondentes em baixa resolução, ou seja, na mesma resolução das imagens de teste.

Por outro lado, para se obter os resíduos de baixa resolução, as imagens SR são novamente suavizadas e subamostradas, gerando novas imagens de baixa resolução LR' . Os resíduos de LR são determinados pela diferença entre as imagens LR e LR' , conforme ilustrado no diagrama da Figura 3.1.

Finalmente, uma vez determinados os resíduos de HR e LR, os descritores de características para os resíduos de baixa resolução (LR) devem ser extraídos, pois serão utilizados no processo de aprendizado baseado no LLE para a reconstrução residual das imagens de teste.

Após realizado o pré-processamento no conjunto de treinamento, pode-se iniciar o processo de super-resolução proposto no fluxograma apresentado na Figura 3.2. O método proposto foi inspirado no trabalho de Yu et al. [52].

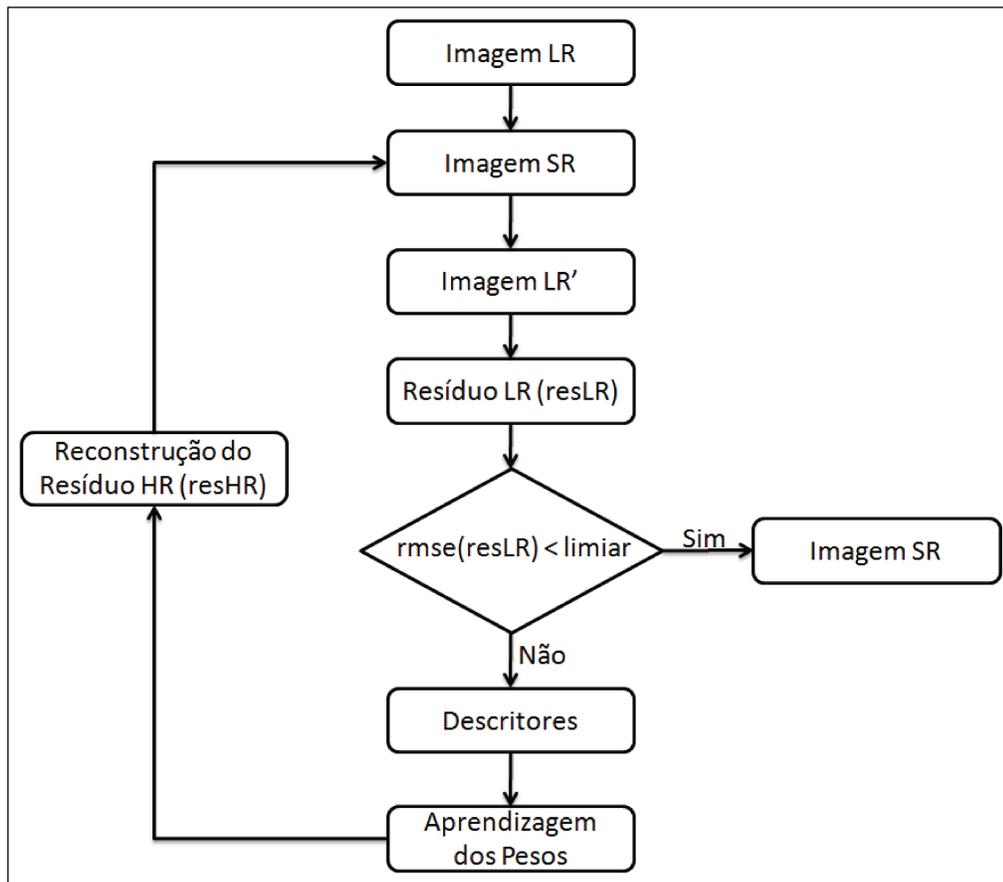


Figura 3.2: Fluxograma básico do método proposto para imagens. Adaptado de Yu et al. [52].

O método inicia-se a partir de uma imagem de baixa resolução (imagem LR), a qual

se deseja super-resolver. Esta imagem é reamostrada para a resolução desejada (a mesma resolução presente no conjunto de treinamento) a partir de um método de reamostragem tradicional (tal como interpolação bicúbica, bilinear ou por vizinho mais próximo) ou por um método de super-resolução existente na literatura (GPP, POCS, IBP), de modo a gerar uma estimativa inicial, denominada imagem SR. O método de reamostragem utilizado na imagem de teste deve ser o mesmo utilizado nas imagens SR de treinamento.

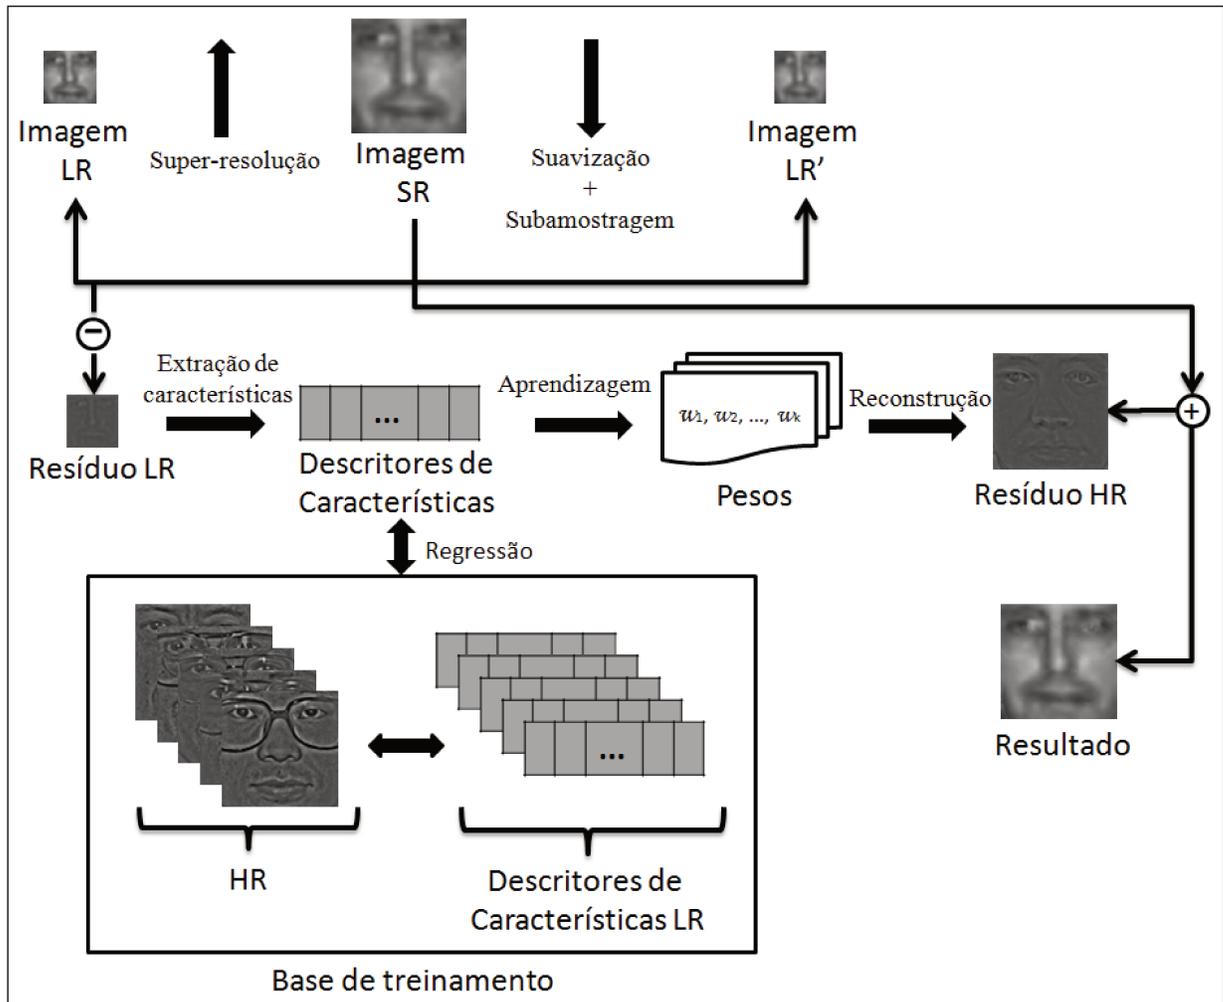


Figura 3.3: Método proposto para super-resolução de única imagem.

A imagem inicialmente estimada (SR) pode ser a imagem resultante, desde que ela satisfaça um limiar de dissimilaridade previamente estabelecido. Para realizar essa verificação, a imagem SR é suavizada e subamostrada para a mesma resolução inicial (imagem LR), gerando a imagem LR'.

Em seguida, o resíduo de baixa resolução é estimado pela diferença entre as imagens LR e LR' e a raiz do erro médio quadrático (RMSE, do inglês *root mean square error*)

do resíduo de baixa resolução ($resLR$) é calculada. Caso o RMSE seja menor do que o limiar estabelecido, obtém-se a imagem super-resolvida e o processo é interrompido. Caso contrário, a imagem super-resolvida, inicialmente estimada, será modificada.

Para modificar a imagem de alta resolução, as informações são adicionadas pela compensação residual, ou seja, é adicionado à imagem SR um resíduo de alta resolução, conforme Equação 3.1 a seguir. Como mencionado, este resíduo é reconstruído a partir da soma ponderada de várias amostras residuais de alta resolução presentes no conjunto de treinamento.

$$SR_{n+1} = SR_n + \alpha \text{resHR} \quad (3.1)$$

Para encontrar as amostras residuais utilizadas na reconstrução, inicialmente extrai-se do resíduo de baixa resolução ($resLR$) o seu vetor de características (*descritores* no Algoritmo 1). A partir desse vetor, os pesos de k vizinhos mais próximos são estimados, ou seja, levando-se em conta os k vetores de características correspondentes aos resíduos de baixa resolução presentes no conjunto de treinamento mais próximos do vetor de características do resíduo $resLR$. Conhecendo os k vetores e seus pesos, em que cada vetor está associado ao seu respectivo resíduo de baixa resolução, encontram-se os resíduos de alta resolução correspondentes.

Algoritmo 1 Método de super-resolução para única imagem.

Entrada: *teste*: imagem de teste, *zoom*: fator de ampliação, *treinamento*: conjunto de treinamento, *maxIter*: número máximo de iterações, *limiar*: RMSE satisfatório, α : variável para suavização do resíduo, k : número de vizinhos mais próximos.

Saída: imagem SR super-resolvida.

```

1:  $SR = \text{amostragem}(\text{teste}, \text{zoom})$ 
2: para todo  $iter = 1$  to  $\text{maxIter}$  faça
3:    $LR = \text{suavização}(SR)$ 
4:    $LR = \text{amostragem}(LR, 1/\text{zoom})$ 
5:    $resLR = \text{teste} - LR$ 
6:   se  $\text{RMSE}(resLR) < \text{limiar}$  então
7:     retorne  $SR$ 
8:   fim se
9:    $descritores = \text{extraiDescritores}(resLR)$ 
10:   $(viz, \mathbf{w}) = \text{LLE}(descritores, \text{treinamento}, k)$ 
11:   $resHR = w_1 viz_1 + w_2 viz_2 + \dots + w_k viz_k$ 
12:   $SR = SR + \alpha resHR$ 
13: fim para
14: retorne  $SR$ 

```

Depois de estimados os pesos e seus respectivos k vizinhos (resíduos de alta resolução), a imagem de resíduo de alta resolução é reconstruída por uma soma ponderada, gerando

a imagem $resHR$. Conforme Equação 3.1, este resíduo é suavizado por uma variável α , $\alpha \in (0, 1]$, e em seguida adicionado à imagem SR.

O processo é repetido até que a imagem atinja o índice de similaridade desejado ou até que um número máximo de iterações seja alcançado. Os principais passos correspondentes ao método proposto de super-resolução para uma única imagem são apresentados no Algoritmo 1.

3.2 Super-Resolução de Múltiplas Imagens

O método proposto na seção anterior foi adaptado para super-resolver uma sequência de imagens. Neste caso, as imagens da sequência são combinadas em uma única imagem. A proposta aqui apresentada consiste na combinação da técnica de super-resolução baseada em reconstrução juntamente com a técnica desenvolvida na seção anterior que se baseia em aprendizado.

Diferentemente do método de super-resolução para única imagem, no qual se considera um conjunto de treinamento com amostras similares às imagens de teste, no método proposto de super-resolução para múltiplas imagens, o conjunto de treinamento é gerado a partir da própria sequência. Isso porque há uma certa dificuldade em se encontrar sequências com as mesmas características da sequência de teste. No entanto, imagens da própria sequência de teste possuem um certo grau de similaridade entre si.

O conjunto de treinamento também necessita ser pré-processado antes da execução do método de super-resolução, como ilustrado na Figura 3.4. De maneira geral, os passos para o pré-processamento do conjunto de treinamento são os mesmos apresentados para o método de super-resolução para única imagem. A diferença consiste apenas em que as imagens utilizadas para a base de dados são a própria sequência.

As imagens no conjunto de treinamento são consideradas como as imagens HR, que serão então suavizadas e subamostradas para gerar as imagens LR. As imagens LR são super-resolvidas, gerando as imagens SR que, em seguida, são suavizadas e subamostradas para gerar as imagens LR'. Os resíduos de baixa resolução consistem na diferença entre as imagens LR e LR', enquanto os resíduos de alta resolução correspondentes consistem na diferença entre as imagens HR e SR. Assim como o pré-processamento apresentado na Figura 3.1, para cada resíduo de baixa resolução é extraído o vetor de características.

Após realizado o pré-processamento no conjunto de treinamento, pode-se executar o método de super-resolução proposto para múltiplas imagens, apresentado no fluxograma da Figura 3.5.

O processo inicia-se com a sequência original, denominada sequência HR. Como o objetivo é a super-resolução da sequência em uma única imagem, a sequência original é degradada a partir de uma suavização e, em seguida, subamostrada, gerando uma

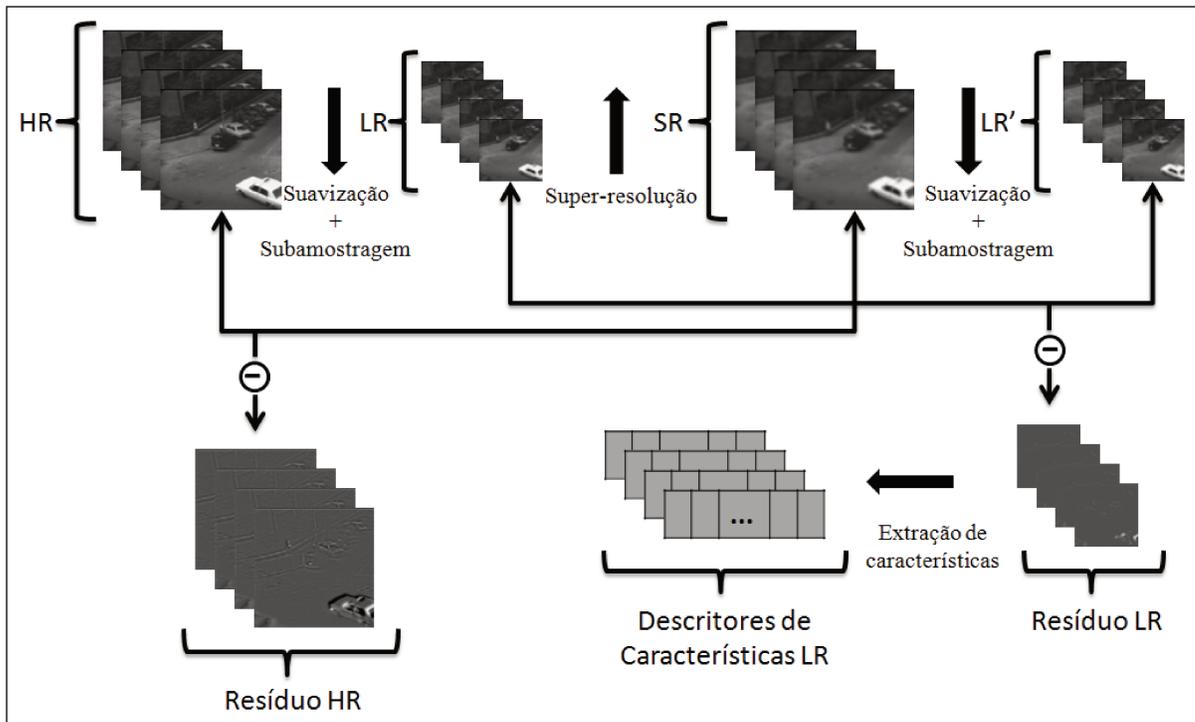


Figura 3.4: Processamento no conjunto de treinamento gerado pela sequência de imagens.

sequência LR, sobre a qual será aplicado o método proposto. Esse processo é necessário para que a sequência original sirva como referência para a avaliação dos resultados.

O segundo passo consiste em super-resolver as imagens da sequência LR, gerando uma nova sequência SR com a mesma resolução da sequência original. O próximo passo consiste na fusão das imagens duas a duas, em que uma delas é a primeira imagem da sequência, considerada imagem de referência, como ilustra a Figura 3.6(a).

O processo inicia-se com N imagens. Após a fusão, o resultado consiste em $N = N - 1$. Se o tamanho da sequência de imagens for igual a 1, obtém-se a imagem super-resolvida e o processo é interrompido. Caso contrário, a sequência resultante da fusão é suavizada e subamostrada, gerando uma nova sequência LR', em que cada imagem será super-resolvida a partir do método proposto para única imagem descrito na Seção 3.1.

Este processo se repete até que ao final seja obtida uma única imagem resultante das fusões, conforme ilustrado na Figura 3.6(b). O Algoritmo 2 apresenta os principais passos do método descrito nesta seção.

No algoritmo 2, a primeira iteração consiste no processo de fusão inicial, em que a primeira imagem da sequência é fundida com as outras $n - 1$ imagens restantes. Na segunda iteração ocorre um pós-processamento em cada imagem da sequência resultante. Em seguida, na mesma iteração, a fusão da sequência resultante ocorre novamente em

Algoritmo 2 Método de super-resolução para múltiplas imagens.

Entrada: *img*: lista original das imagens da sequência, *n*: número de imagens na sequência, *zoom*: fator de ampliação.

Saída: *listSR*: imagens super-resolvidas.

```
1: para todo  $i = 2$  to  $n$  faça
2:      $listImg_{i-1} = fus\tilde{a}o(amostragem(img_1, zoom), amostragem(img_i, zoom))$ 
3: fim para
4:  $n \leftarrow n - 1$ 
5: enquanto  $n > 1$  faça
6:     para todo  $i = 1$  to  $numel(listImg)$  faça
7:          $teste = suaviza\tilde{c}\tilde{a}o(listImg_i)$ 
8:          $teste = amostragem(teste, 1/zoom)$ 
9:          $listSR_i = \acute{u}nicaImagem(teste)$ 
10:    fim para
11:    para todo  $i = 2$  to  $n$  faça
12:         $listAux_{i-1} = fus\tilde{a}o(listSR_1, listSR_i)$ 
13:    fim para
14:     $listImg = listAux$ 
15:     $n \leftarrow n - 1$ 
16: fim enquanto
17: retorne  $listSR$ 
```

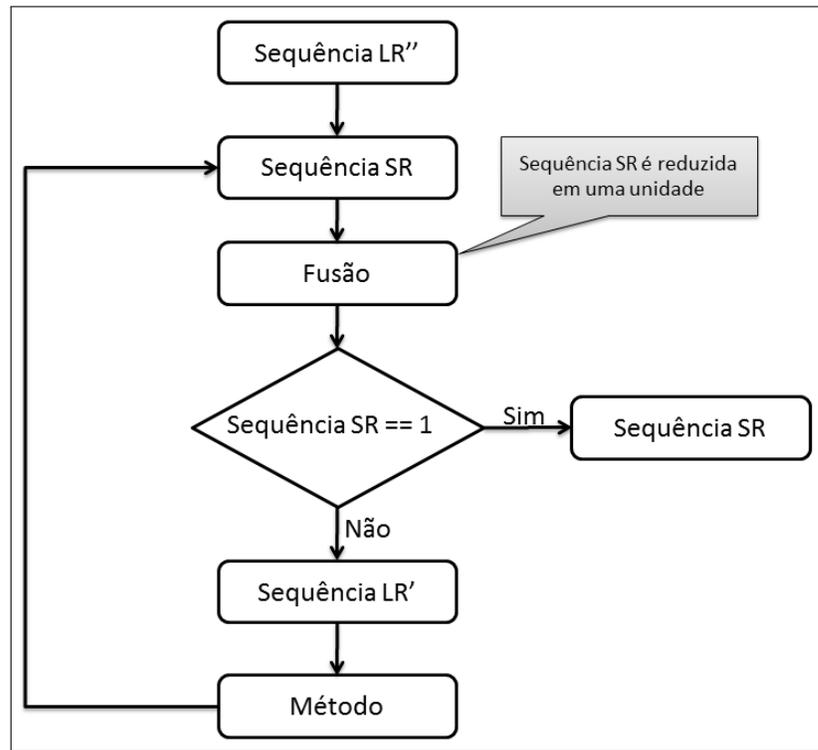


Figura 3.5: Fluxograma básico do método proposto para múltiplas imagens.

uma iteração interna. A segunda iteração é realizada até restar apenas uma imagem na sequência, resultado de todas as fusões.

Este capítulo apresentou, de forma detalhada, o método de super-resolução de única imagem e uma adaptação do mesmo para super-resolução de múltiplas imagens em uma única imagem. No próximo capítulo, os resultados obtidos a partir da aplicação dos métodos propostos são analisados e comparados com alguns métodos existentes na literatura.

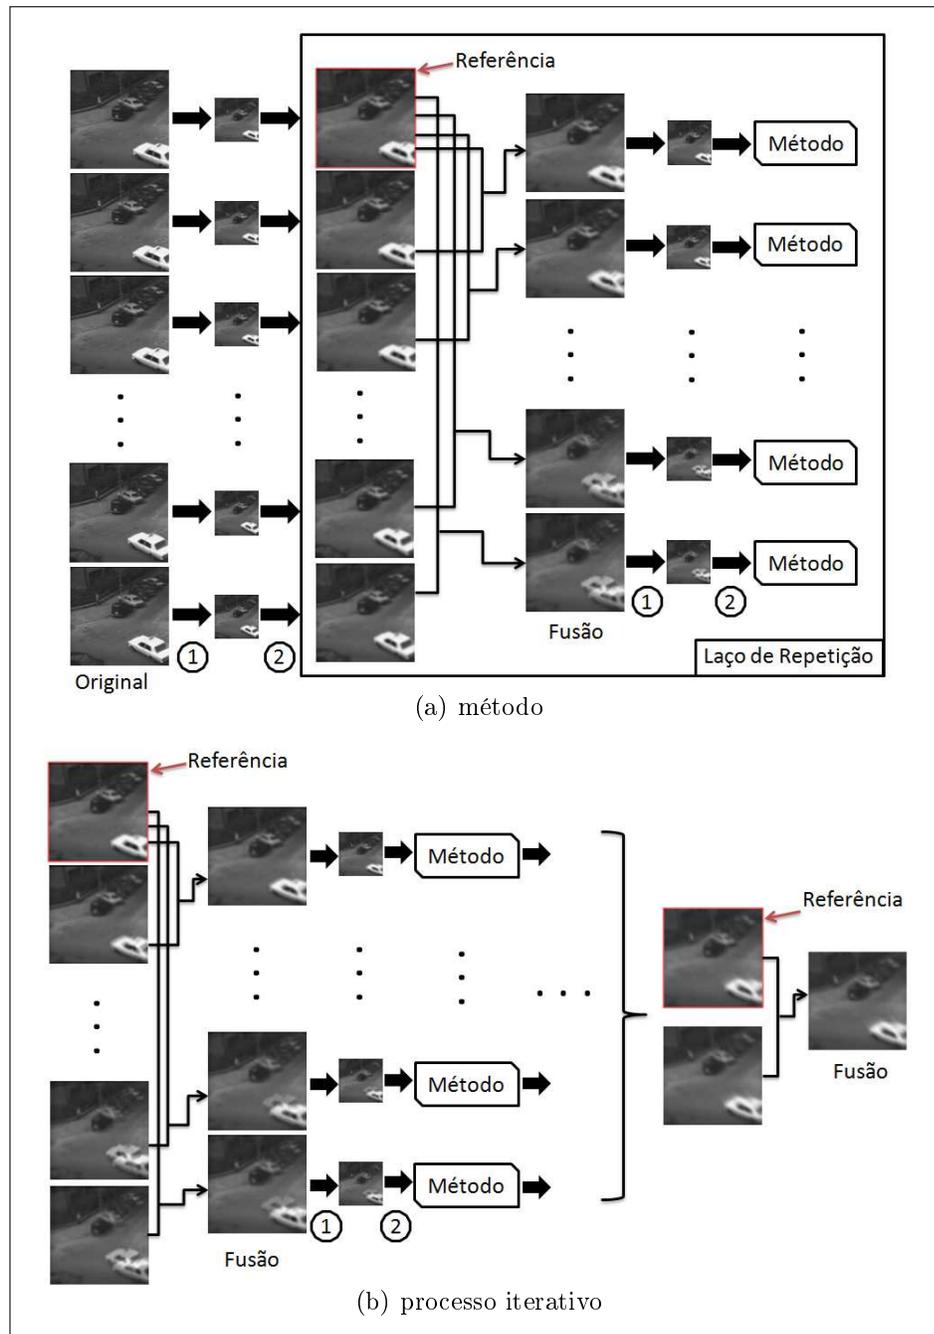


Figura 3.6: Método proposto para super-resolução de sequência de imagens.

Capítulo 4

Resultados Experimentais

Este capítulo descreve alguns experimentos realizados e os resultados obtidos com a aplicação dos métodos de super-resolução propostos e apresentados no Capítulo 3. O ambiente utilizado no desenvolvimento do trabalho, as bases de dados empregadas, as métricas para avaliação dos resultados e uma discussão dos experimentos com os métodos de super-resolução são descritos neste capítulo. Para analisar a eficácia dos métodos propostos, os resultados são comparados com algumas abordagens existentes na literatura.

4.1 Configuração do Ambiente

Os métodos propostos no Capítulo 3 para super-resolução de única imagem e de uma sequência de imagens possuem parâmetros que influenciam os resultados, os quais incluem o método de amostragem, o aprendizado e a extração dos descritores de características, o tamanho do conjunto de treinamento, a variável de suavização α e a forma de fusão para SR em sequência de imagens. Alguns desses parâmetros são previamente definidos, tomando-se como base estudos e comparações disponíveis na literatura, sendo apresentados mais detalhadamente nas Seções 4.4 e 4.5.

Todos os experimentos relatados foram executados em computador com processador Intel[®] Core[™] 2 Duo 2.2 GHz, 6 GBytes de RAM. A implementação foi feita em Matlab 8, no entanto, o programa também faz uso de funções implementadas em linguagem de programação C. O sistema operacional utilizado foi o Windows 7 Ultimate de 32 bits.

4.2 Amostras de Dados

Para avaliar o desempenho do método, algumas bases de dados foram utilizadas nos experimentos. Para o método proposto de super-resolução de única imagem, testes são

reportados em duas bases diferentes. No primeiro teste, utilizou-se um conjunto com 248 imagens, em alta resolução, retiradas da base de dados FERET [37]. Destas imagens, aleatoriamente, 228 foram utilizadas para o treinamento e 20 imagens foram utilizadas como *ground truth* e, após serem suavizadas e subamostradas, foram utilizadas como imagens de teste em baixa resolução. Estas amostras são imagens de faces de diferentes pessoas alinhadas pelos olhos (todas possuem mesma similaridade estrutural). Alguns exemplos de imagens dessa base são ilustrados na Figura 4.1. As imagens possuem tamanho de 84×84 pixels e são monocromáticas, ou seja, estão na escala de cinza, em que os valores dos pixes se encontram entre 0 a 255.



Figura 4.1: Algumas amostras da base FERET utilizadas para teste [37].

No segundo experimento com uma única imagem, 80 imagens de mamografia, em alta resolução, foram utilizadas, sendo retiradas da base de dados disponível em [11]. Destas imagens, 75 foram utilizadas como imagens de treinamento e as outras 5 foram utilizadas como *ground truth*. As cinco imagens de teste em baixa resolução foram geradas a partir de processos de suavização e subamostragem.

Como as imagens de mamografia originais possuem dimensões variadas, todas foram recortadas para o tamanho 150×150 pixels. Exemplos de amostras são ilustrados na Figura 4.2.

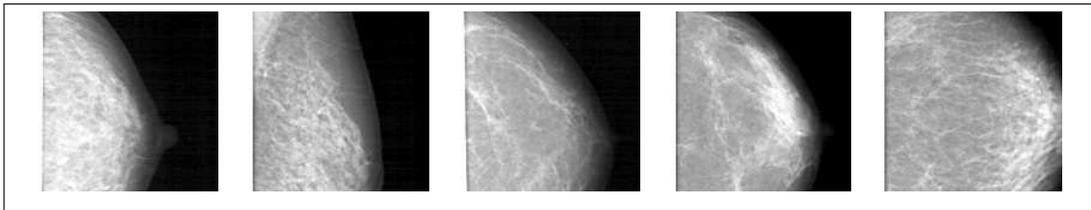


Figura 4.2: Algumas imagens de mamografia [11].

Na super-resolução de múltiplas imagens, utilizou-se um vídeo de táxi com uma sequência de 41 quadros, disponível para acesso público em [30]. Cada quadro possui dimensão original de 256×191 pixels em nível de cinza. Nos experimentos, os quadros são recortados para dimensão 128×128 devido ao fato de que alguns métodos utilizados na avaliação funcionam apenas com imagens de dimensão quadrada. Alguns quadros são ilustrados

na Figura 4.3. Os quadros originais são ainda utilizados como *ground truth*. Para os experimentos realizados, todos os quadros da sequência fornecida são subamostrados e suavizados.



Figura 4.3: Exemplos de quadros da sequência de vídeo de táxi utilizada [30].

No segundo experimento realizado para super-resolução de múltiplas imagens para formar uma imagem de alta resolução, utilizou-se um vídeo de pedestre com 610 quadros, disponível em [5]. Cada quadro está no espaço de cor RGB e possui dimensão igual a 384×288 pixels. Nos experimentos, os quadros são convertidos para nível de cinza e são recortados para a dimensão 128×128 pixels. O espaço de cores foi alterado a fim de que os resultados pudessem ser comparados com os métodos disponíveis na literatura. Alguns exemplos de quadros desse vídeo são apresentados na Figura 4.4.



Figura 4.4: Exemplos de quadros da sequência de vídeo de pessoa utilizada [5].

4.3 Métricas de Avaliação

O processo de avaliação da imagem de super-resolução (SR) obtida em relação à imagem de referência (LR) não é uma tarefa simples, uma vez que essas imagens possuem resoluções diferentes. Os resultados obtidos foram avaliados por meio de uma métrica quantitativa e uma métrica qualitativa, a raiz do erro médio quadrático e o índice de similaridade estrutural, respectivamente, descritos a seguir.

Em um trabalho anterior [40], uma análise comparativa entre diferentes técnicas de interpolação e seu impacto na super-resolução de múltiplas imagens é realizada a partir de diversas métricas quantitativas e qualitativas.

Raiz do Erro Médio Quadrático A raiz do erro médio quadrático (RMSE, do inglês, *Root Mean Square Error*) corresponde à raiz do erro médio quadrático levando-se em conta cada ponto das imagens HR (imagem de *ground truth*) e SR (imagem resultante do método de super-resolução). Essa medida indica o grau de similaridade entre as imagens HR e SR, tendo valor igual a zero quando as duas imagens são idênticas. A medida é dada por

$$\text{RMSE} = \sqrt{\frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [HR(x, y) - SR(x, y)]^2} \quad (4.1)$$

em que M e N são as dimensões das imagens.

Índice de Similaridade Estrutural O índice de similaridade estrutural (SSIM, do inglês, *Structural SIMilarity*) foi proposto em [53]. Este índice também é utilizado para mensurar a similaridade entre duas imagens. A qualidade é medida comparando-se as correlações locais em luminância, contraste e estrutura entre a imagem de referência e a imagem a ser avaliada [40]. O SSIM é dado por

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2\sigma_y^2 + C_2)} \quad (4.2)$$

em que as constantes C_1 e C_2 são utilizadas para estabilizar a equação quando $(\mu_x^2 + \mu_y^2)$ e $(\sigma_x^2\sigma_y^2)$ são próximos de zero. Como sugerido por [53], utilizou-se $C_1 = 0.01$ e $C_2 = 0.03$.

4.4 Experimentos para Única Imagem

Nos experimentos realizados em única imagem, cujos passos executados são descritos no Algoritmo 1, alguns parâmetros e funções devem ser previamente definidos, conforme já mencionado. No primeiro experimento realizado, utiliza-se a base de imagens de faces exemplificada na Figura 4.1.

Para a reamostragem de cada imagem, dois métodos distintos foram empregados. Com o objetivo de aumentar a resolução da imagem (linha 1, do Algoritmo 1), utilizou-se inicialmente o método de super-resolução GPP (descrito na Seção 2.5.1), cujos parâmetros necessários são a imagem a ser reamostrada (*teste*) e o fator de ampliação (*zoom*). O resultado desta reamostragem é uma estimativa inicial da imagem de super-resolução resultante do método, conforme mostrado na Figura 4.5. O outro método utilizado para reamostragem é a interpolação bilinear (descrito na Seção 2.5.1), cujo objetivo, neste caso, consiste em reduzir a resolução da imagem (linha 4 do Algoritmo 1).

A partir deste ponto, inicia-se um processo iterativo. A linha 3 do algoritmo apresentado refere-se a uma função de suavização, cujo objetivo é reduzir os detalhes da imagem. Um filtro passa-baixa Gaussiano foi utilizado nos experimentos.

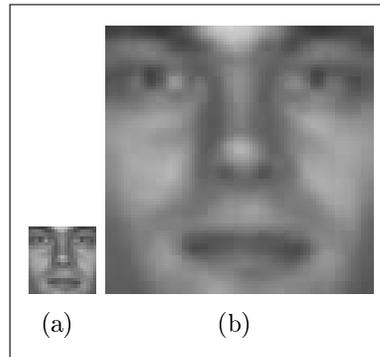


Figura 4.5: Processo de reamostragem. (a) imagem de baixa resolução; (b) imagem de alta resolução com o método GPP.

Depois de suavizada e subamostrada a imagem, gera-se o resíduo de baixa resolução ($resLR$) a partir da subtração entre a imagem de teste e a imagem resultante LR. O processo é interrompido caso o valor de RMSE do resíduo seja menor do que o limiar previamente estabelecido. Este limiar baseia-se na similaridade entre as imagens, nos experimentos realizados, utilizou-se um limiar igual a 0.1. Este valor foi atribuído empiricamente, sendo considerado apenas como um critério de parada. Dado que, quanto maior a similaridade entre duas imagens, menor é o RMSE, o valor escolhido foi baixo.

Caso a condição não seja atendida, inicia-se o processo de extração dos descritores de características (função da linha 9). Esses descritores serão utilizados na aprendizagem dos pesos da reconstrução do resíduo de alta resolução. Para fins de análise de desempenho, foram testados os métodos HOG e HSC para extração de características, descritos com mais detalhes na Seção 2.2.

O gráfico mostrado na Figura 4.6 demonstra que ambos os métodos possuem desempenho equivalente. Na média, o descritor HSC possui RMSE igual a 9.8275 e HOG possui RMSE igual a 9.9406. Conforme pode-se observar no gráfico, o HSC apresenta erro menor do que o método HOG em algumas amostras. A partir desta análise, optou-se por utilizar o descritor HSC nos demais experimentos realizados neste trabalho.

Após extração de características, o próximo passo (linha 10) consiste em aprender os pesos dos vetores de características para a reconstrução. O método de aprendizado utilizado foi o LLE, apresentado na Seção 2.4. Neste método, a partir do conjunto de treinamento, localiza-se os k -vizinhos mais próximos do vetor de característica desejado ($caract$). Um peso é atribuído a esses k -vizinhos, cuja soma é ponderada e possui valor total igual a 1.

O valor de k foi empiricamente determinado a partir de alguns testes. Conforme mostrado na Figura 4.7, o número de vizinhos que apresenta melhor desempenho, segundo os parâmetros definidos nos testes da Figura 4.8, foi igual 5. Cada k -ésimo vizinho do

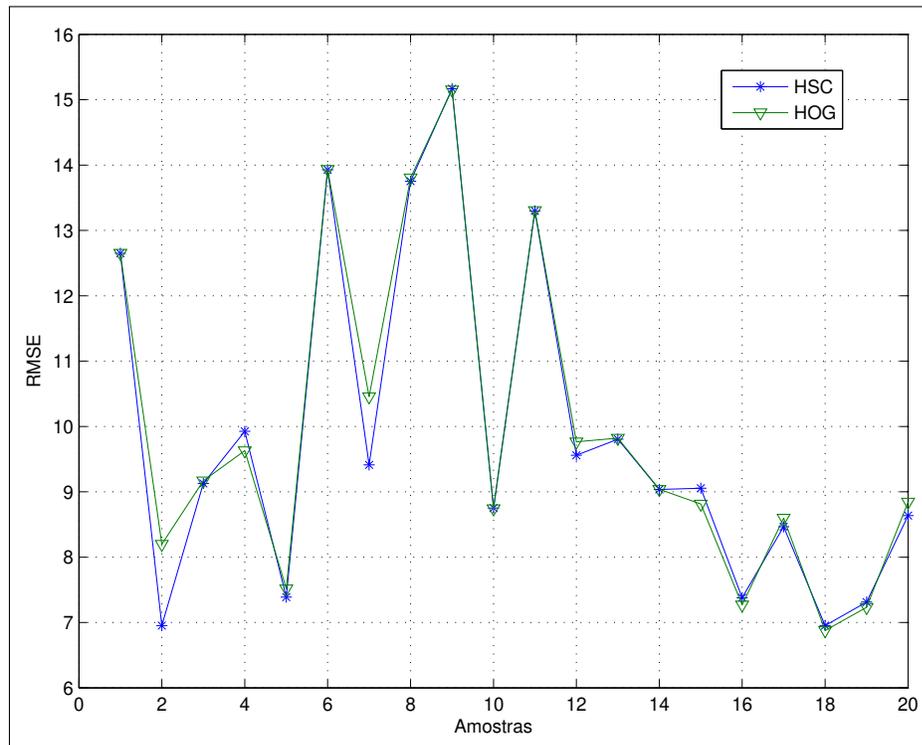


Figura 4.6: Descritores HOG e HSC.

vetor de característica de interesse está associado a um resíduo de alta resolução. A função da linha 10 retorna os vizinhos localizados (*viz*) e seus respectivos pesos. A partir dessas variáveis, reconstrói-se o resíduo de alta resolução (*resHR*), conforme linha 11 do Algoritmo 1.

Após determinado o resíduo de alta resolução, o próximo passo é acrescentar este resíduo à imagem de super-resolução inicialmente estimada. Para tanto, este resíduo deve ser suavizado por uma variável α , cujo valor é empírico, assim como, o número máximo de iterações (*maxIter*) a serem realizadas. Para determinar estes valores, foram realizados alguns testes, conforme gráfico da Figura 4.8

No gráfico da Figura 4.8, pode-se observar que o método possui melhor desempenho para valores mais baixos de α . As curvas do gráfico para α igual a 0.001 e 0.01 praticamente se sobrepõem. Para α igual a 0.001 e para as iterações fornecidas, a média do erro é igual a 10.02 e, para α igual a 0.01, sua média é igual a 9.89. Embora os valores sejam muito próximos, nos experimentos foram utilizados o valor de α igual a 0.01 e o número máximo de iterações (*maxIter*) igual a 50, ponto que apresentou menor RMSE para o valor de α fornecido.

Vários métodos da literatura foram comparados com o método proposto para avaliar sua eficácia. Dentre esses métodos, quatro são do tipo realce de detalhes (vizinho mais

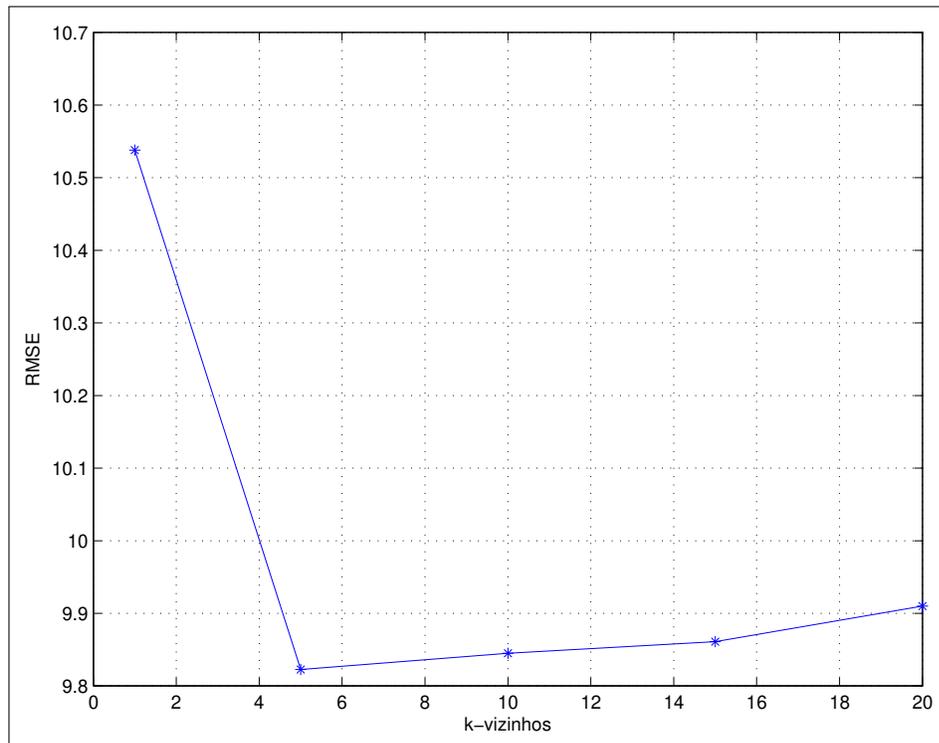


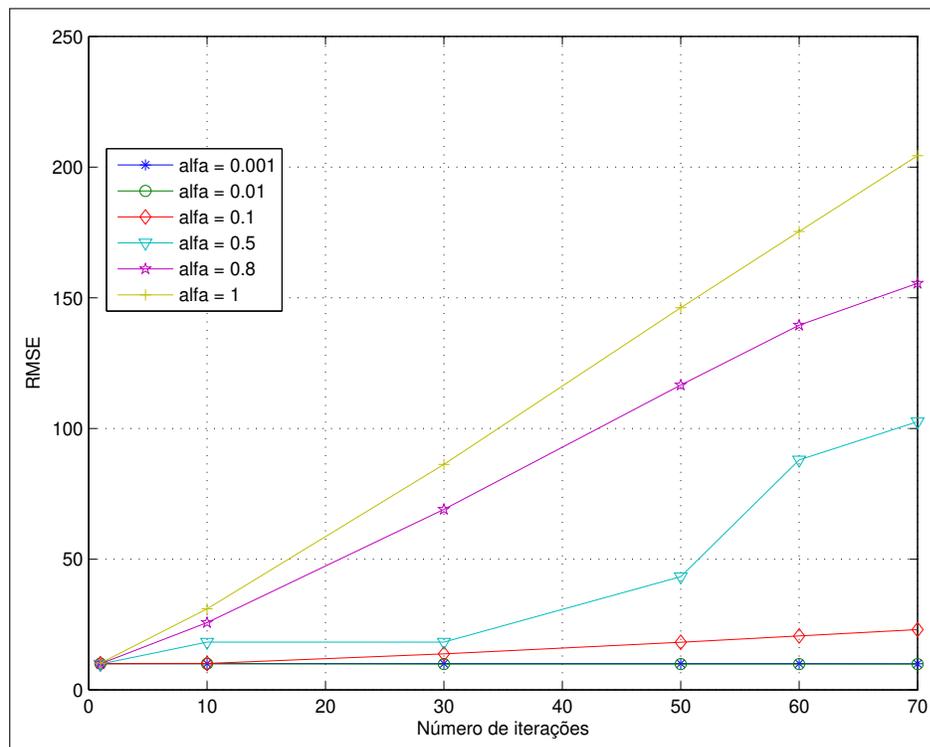
Figura 4.7: Número de vizinhos.

próximo, bilinear, bicúbica e GPP), um é do tipo reconstrução (POCS) e o outro baseado em aprendizado (POCS + Resíduo + LLE), sendo todos descritos na Seção 2.5. O método proposto neste trabalho combina a abordagem GPP com aprendizado LLE utilizando descritores de características HSC.

A avaliação foi realizada por meio das medidas estatísticas RMSE e SSIM, apresentadas na Seção 4.3. As imagens resultantes foram comparadas com as imagens originais (*ground truth*). A média dos resultados pode ser observada na Tabela 4.1.

Conforme destacado em **negrito** na Tabela 4.1, o método proposto possui, na média, os melhores resultados tanto em relação ao RMSE quanto para o SSIM. Para uma análise mais detalhada, a Tabela 4.2 apresenta os resultados para algumas amostras isoladas. Essas amostras podem ser visualizadas na Figura 4.9. O método proposto apresentou, nas amostras 1, 2 e 3, erros significativamente menores do que os outros métodos comparados. No entanto, na amostra 4, o erro foi maior do que o próprio método GPP aplicado isoladamente. Isso provavelmente se deve ao fato de que, como o método proposto é um método iterativo, no qual as informações são adicionadas ou removidas em cada iteração a partir da base de treinamento, para esta amostra a base de treinamento pode ter propiciado a adição de ruídos que não existiam apenas com o método GPP.

Os parâmetros identificados para super-resolução de única imagem, a partir dos testes

Figura 4.8: Número de iterações \times valor da variável α .

20 Amostras				
Método	2 \times		4 \times	
	RMSE	SSIM	RMSE	SSIM
Vizinho mais próximo [36]	11.4942	0.9409	17.1981	0.8582
Bilinear [36]	11.3881	0.9395	16.6832	0.8579
Bicúbica [36]	10.2492	0.9522	15.5587	0.8809
IBP [20]	11.6037	0.9420	20.0407	0.8236
GPP [46]	10.0383	0.9550	15.3464	0.8863
POCS [45]	10.8597	0.9509	16.6818	0.8579
POCS + Resíduo + LLE [52]	10.8438	0.9508	16.6884	0.8573
Método proposto	9.8276	0.9569	15.2125	0.8887

Tabela 4.1: Média do resultados da avaliação entre 20 amostras obtidas com os métodos de super-resolução.

realizados com as imagens de faces, foram os mesmos utilizados no segundo experimento, o qual empregou imagens de mamografia (Figura 4.2).

Os resultados destacados em negrito na Tabela 4.3 para o método proposto, assim como relatado nos experimentos anteriores utilizando imagens de faces, apresentam, na

Método	Amostra 1	Amostra 2	Amostra 3	Amostra 4
Vizinho mais próximo [36]	9.8216	9.6921	11.2949	10.2843
Bilinear [36]	9.6588	9.6222	11.2988	10.1636
Bicúbica [36]	8.6044	8.5594	10.4541	9.0905
IBP [20]	10.0070	9.7471	11.3162	10.4225
GPP [46]	8.4115	8.3515	10.3139	8.8521
POCS [45]	9.1853	9.0039	10.7507	9.8038
POCS + Resíduo + LLE [52]	9.1176	8.9786	10.7528	9.7875
Método proposto	6.4071	6.8376	8.8312	9.6221

Tabela 4.2: Resultados do RMSE para os métodos super-resolução com fator de ampliação igual a 2.

média, melhor desempenho na avaliação do RMSE e do SSIM quando comparado com os outros métodos da literatura.

5 Amostras		
Método	2×	
	RMSE	SSIM
Vizinho mais próximo [36]	7.1825	0.9843
Bilinear [36]	7.1724	0.9834
Bicúbica [36]	6.6142	0.9861
IBP [20]	7.2465	0.9845
GPP [46]	6.4856	0.9868
POCS [45]	7.1699	0.9834
POCS + Resíduo + LLE [52]	6.5564	0.9864
Método proposto	6.0762	0.9888

Tabela 4.3: Média dos resultados da avaliação entre 5 amostras obtidas com os métodos testados.

A partir da Tabela 4.4, pode-se observar o desempenho do método proposto, comparando os resultados do RMSE das 5 amostras utilizadas para os testes nos experimentos realizados. Quando analisado isoladamente, nota-se um ganho de desempenho do método proposto nas amostras 2, 3 e 4. Na amostra 1, embora o RMSE possua pouca variação entre os métodos, o melhor resultado encontra-se no método de super-resolução com aprendizado (LLE) utilizando POCS com compensação residual. Já na amostra 5, o melhor resultado encontra-se no método de super-resolução GPP.

A Figura 4.10 ilustra os resultados obtidos após realizados os experimentos utilizando as amostras apresentadas na Tabela 4.4.

A análise quantitativa demonstra que, em geral, os métodos com resíduos utilizando estimativa inicial com método GPP apresentam melhor eficácia, destacando-se o mé-

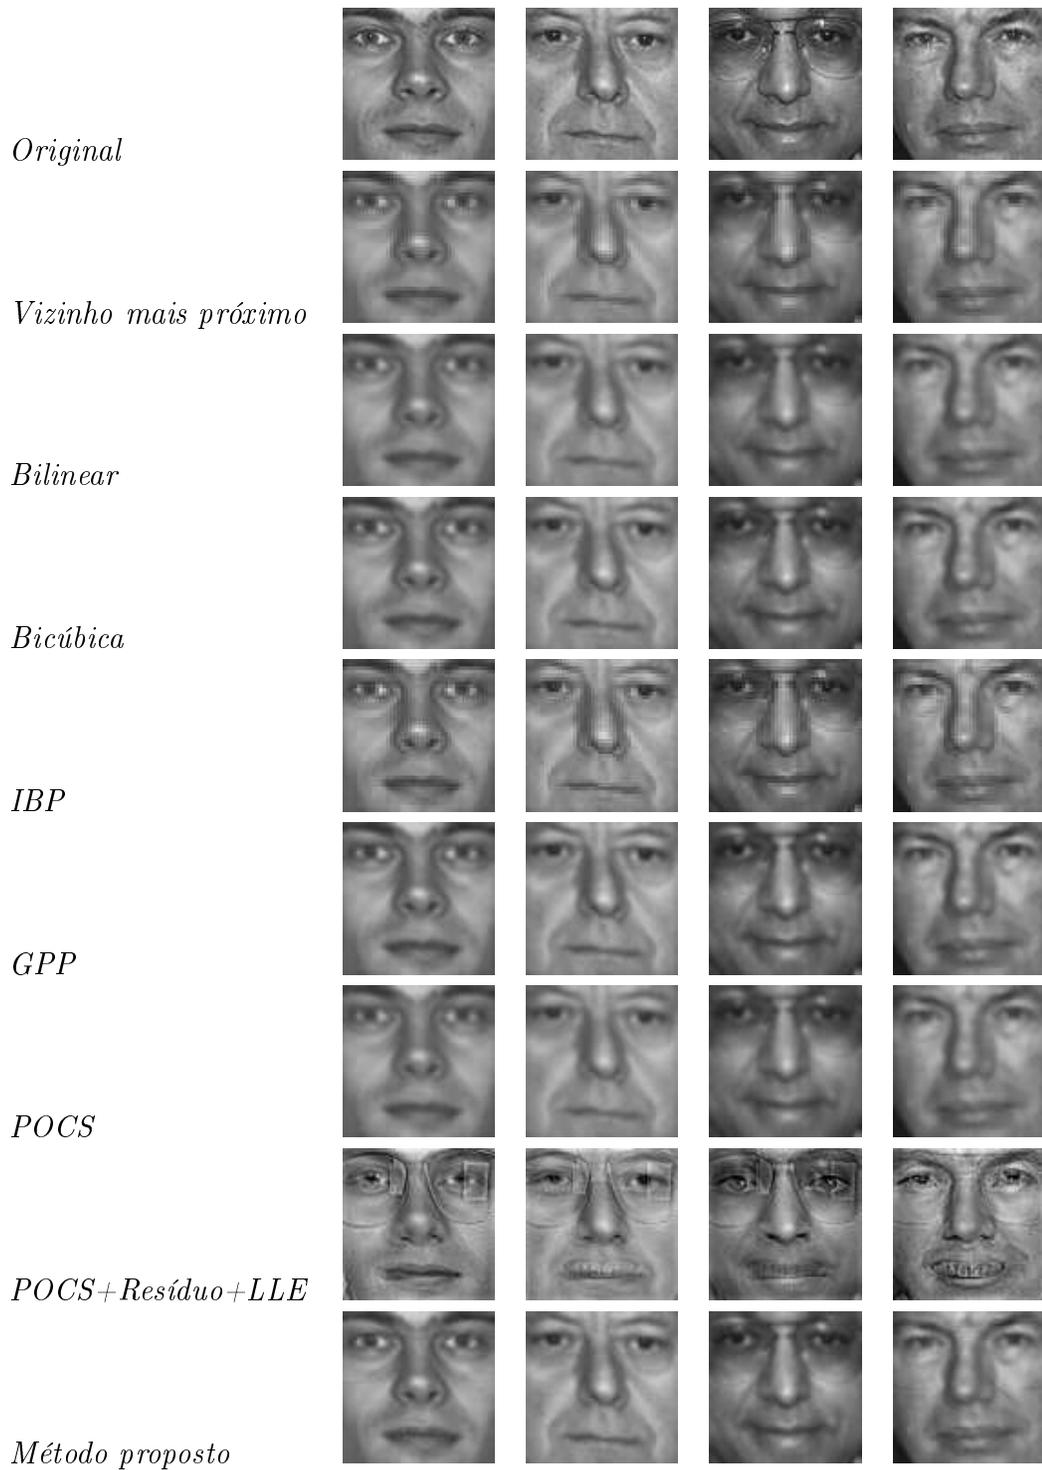


Figura 4.9: Alguns resultados obtidos a partir das técnicas avaliadas com fator de ampliação igual a 2.

Fator de ampliação 2x					
Método	Amostra 1	Amostra 2	Amostra 3	Amostra 4	Amostra 5
Vizinho mais próximo [36]	5.8500	9.8098	7.5778	6.2444	6.4308
Bilinear [36]	5.9597	9.1771	8.0135	6.2324	6.4797
Bicúbica [36]	5.4588	8.5919	7.2503	5.8405	5.9296
IBP [20]	5.8784	9.9357	7.6578	6.3308	6.4299
GPP [46]	5.3817	8.4437	7.0223	5.7735	5.807
POCS [45]	5.9602	9.1803	7.9993	6.2266	6.4831
POCS + Resíduo + LLE [52]	5.1761	8.1570	7.2264	5.7673	6.4554
Método proposto	5.2710	7.0206	6.5959	5.1886	6.3051

Tabela 4.4: Valor de RMSE para 5 amostras de imagens de mamografia obtidas com os métodos testados.

todo proposto. Adicionalmente, percebe-se vários artefatos presentes nas imagens super-resolvidas pelo método proposto por Yu et al. [52], principalmente na região dos olhos e da boca. Isso indica que a utilização de descritores de características provê melhores candidatos e o LLE é capaz de estimar uma reconstrução mais acurada.

4.5 Experimentos para Múltiplas Imagens

Assim como apresentado na seção anterior, nos experimentos realizados com múltiplas imagens também é necessária a estimação de alguns parâmetros e funções do Algoritmo 2. Embora a maioria deles tenha os mesmos valores do que o método de super-resolução de única imagem, alguns precisam ser reajustados para garantir a eficácia do método.

Conforme descrito na Seção 3.2, o primeiro passo do algoritmo consiste na fusão das imagens da sequência. Essas imagens, antes de serem fundidas, são reamostradas também com o método de super-resolução GPP. A reamostragem é realizada de acordo com a resolução apresentada no conjunto de treinamento, que foi gerado conforme descrito na Seção 3.2.

No processo de fusão, as imagens são concatenadas duas a duas, sendo uma delas a imagem de referência. Conforme ilustrado na Figura 3.6(b), a imagem de referência corresponde à primeira imagem da sequência. Para realizar o processo de fusão (linhas 2 e 12 do Algoritmo 2), o método SIFT foi aplicado para extrair características correspondentes entre pares de imagens (Figura 4.11). A partir dessa correspondência entre características, calcula-se uma transformada afim para então gerar a imagem fundida a partir da média entre os pontos correspondentes nas imagens. A transformada afim visa alinhar o par de imagens em questão.

No algoritmo apresentado, os processos de suavização (linha 7) e subamostragem (linha

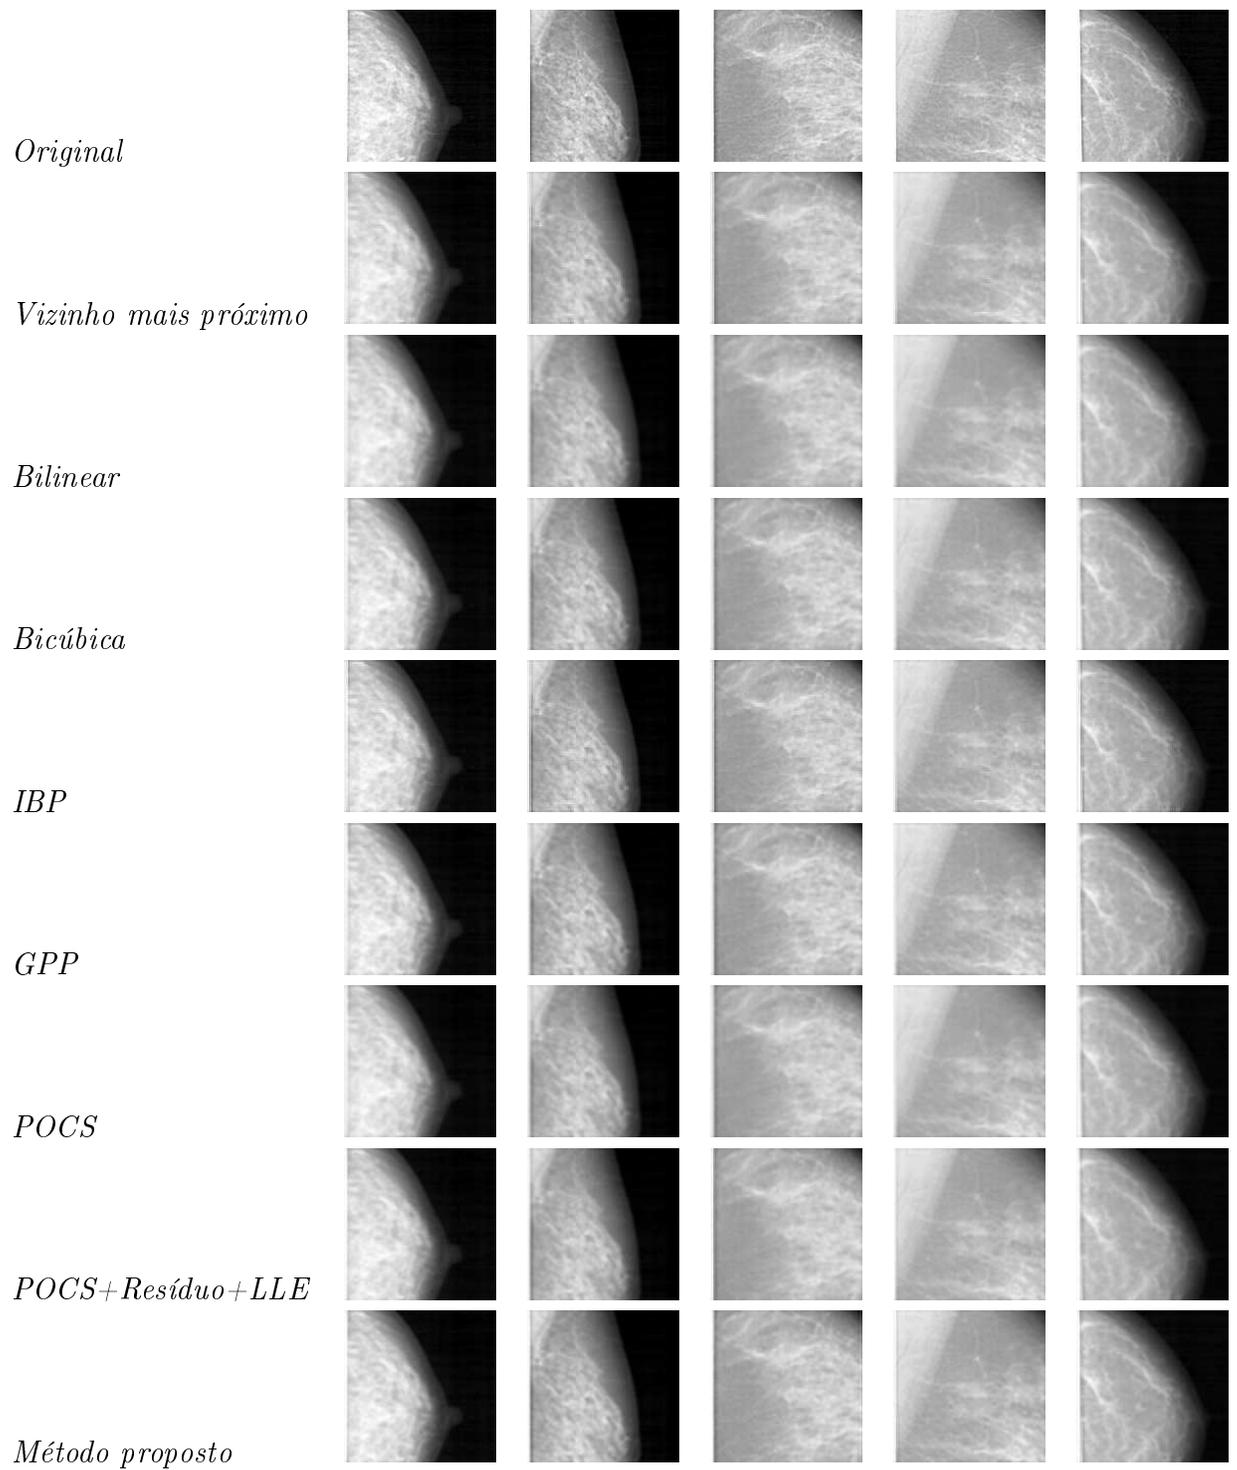


Figura 4.10: Alguns resultados obtidos a partir das técnicas avaliadas com fator de ampliação igual a 2.

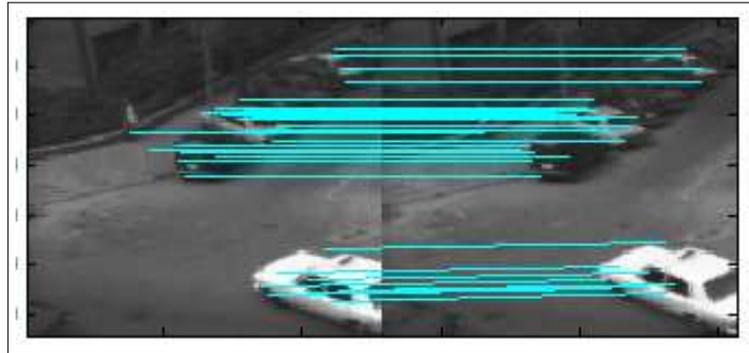


Figura 4.11: Correspondência entre duas imagens para realização do processo de fusão.

8) são os mesmos descritos no método de super-resolução de única imagem. Na linha 9 do algoritmo, deve-se ressaltar a referência feita ao método proposto de super-resolução de única imagem e descrito na Seção 3.2. Entretanto, a configuração de parâmetros não é a mesma adotadas nos experimentos para única imagem, tal que alguns parâmetros necessitam ser reajustados.

Visando melhores resultados, testes foram realizados com diferentes configurações (conforme gráfico da Figura 4.12), em que são variados os valores de α e o número de iterações. Analisando o gráfico apresentado, pode-se observar que o método possui melhor eficácia para α (parâmetro de suavização) baixo, como 0.001. Além disso, comparando o número de iterações do método, nota-se que o melhor desempenho é alcançado no teste com 150 iterações.

Com base na configuração estimada ($\alpha = 0.001$ e 150 iterações), o método de super-resolução de múltiplas imagens foi comparado com outros dois métodos de super-resolução para sequência de imagens (IBP e POCS) existentes na literatura e apresentados com mais detalhes no Capítulo 2.

As Tabelas 4.5 e 4.6 apresentam os resultados obtidos com os métodos de super-resolução para fatores de ampliação iguais a 2 e 4, respectivamente. Estes valores foram alcançados comparando os resultados dos métodos com a imagem de referência do *ground truth* (primeira imagem da sequência fornecida).

A análise quantitativa e qualitativa dos resultados demonstra a eficácia do método proposto, como pode ser visto pelos valores destacados em negrito nas tabelas. Em geral, para realizar o processo de super-resolução não se utiliza sequências de imagens longas, pois quanto maior o número de quadros da sequência, maior será a quantidade de ruído acrescentada no processo de fusão. Nos experimentos realizados, subsequências do vídeo com 6 e com 12 quadros foram utilizados, tais como os exemplos mostrados na Figura 4.3.

Além da avaliação efetuada pela quantidade de quadros da sequência, o método proposto também foi avaliado segundo o fator de ampliação 2 e 4. Em ambos os casos, o

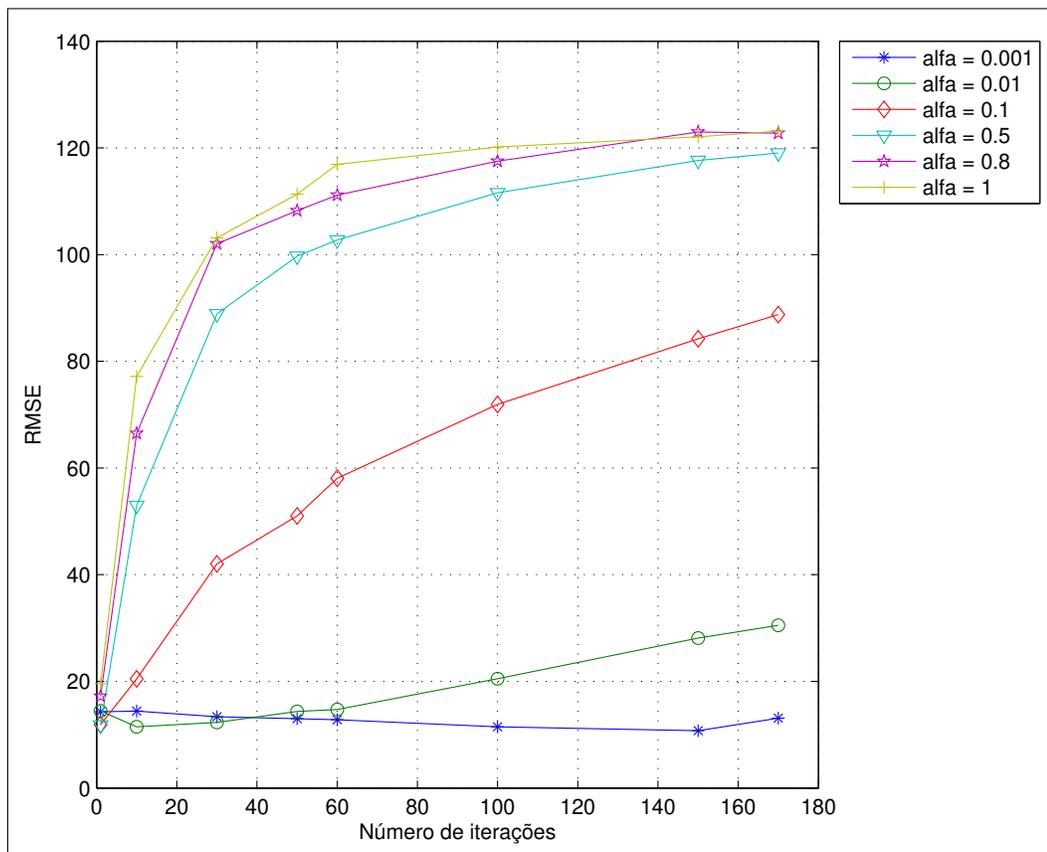


Figura 4.12: Estimação do número de iterações em função do RMSE. Parâmetros α e número de iterações.

Fator de ampliação 2x				
Método	6 Quadros		12 Quadros	
	RMSE	SSIM	RMSE	SSIM
IBP [20]	32.5863	0.7476	34.0467	0.7081
POCS [45]	22.4413	0.8511	30.0020	0.7442
Método proposto	10.7686	0.9604	18.0773	0.8893

Tabela 4.5: Resultados obtidos com os métodos de super-resolução de múltiplas imagens, fator de ampliação igual a 2.

desempenho do método proposto foi superior aos outros dois métodos da literatura.

Uma análise visual dos resultados dos métodos testados pode ser feita a partir da Figura 4.13. Pode-se observar que o método proposto apresenta melhor nitidez nos detalhes, comparado aos demais.

Os parâmetros estimados para super-resolução de múltiplas imagens no primeiro experimento foram os mesmos utilizados no segundo. Os resultados destacados em negrito

Fator de ampliação 4x				
Método	6 Quadros		12 Quadros	
	RMSE	SSIM	RMSE	SSIM
IBP [20]	29.8295	0.7648	30.7796	0.7417
POCS [45]	21.5620	0.8571	29.4161	0.7501
Método proposto	14.0965	0.9303	16.1489	0.9161

Tabela 4.6: Resultados obtidos com os métodos de super-resolução de múltiplas imagens, fator de ampliação igual a 4.

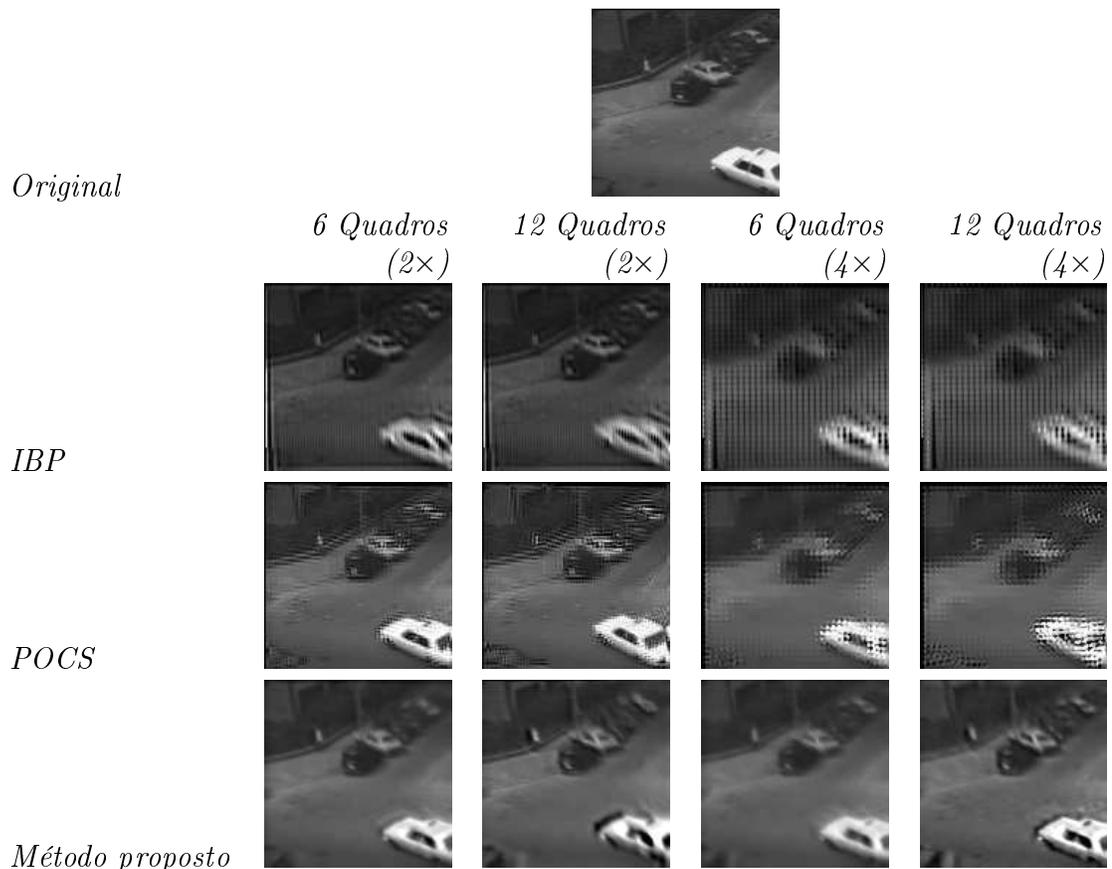


Figura 4.13: Resultados obtidos para fator de ampliação 2 e 4 e para sequências com 6 e 12 quadros.

na Tabela 4.7, assim como relatado nos experimentos anteriores utilizando a sequência de vídeo de táxi, apresentam melhor eficácia em termos de RMSE e SSIM, comparados com outros métodos da literatura.

A Tabela 4.7 apresenta os resultados obtidos para a geração de uma imagem de alta resolução a partir da subsequência de 5 quadros do vídeo original, aqueles mesmos ilus-

trados na Figura 4.4. Estes valores foram alcançados comparando-se os resultados dos métodos testados com a imagem de referência (*ground truth*), ou seja, a primeira imagem da sequência fornecida (Figura 4.14-(a)), considerando fator de ampliação igual a quatro.

Fator de ampliação 4x		
Método	5 Quadros	
	RMSE	SSIM
IBP [20]	50.1041	0.2842
POCS [45]	29.7727	0.4527
Método proposto	10.2753	0.8757

Tabela 4.7: Resultados obtidos com os métodos de super-resolução de múltiplas imagens, fator de ampliação igual a 4.

Similarmente ao experimento anterior, uma análise visual dos resultados obtidos pelos métodos testados pode ser feita a partir da Figura 4.14, em que o método proposto apresenta melhor nitidez nos detalhes, quando comparado aos demais.

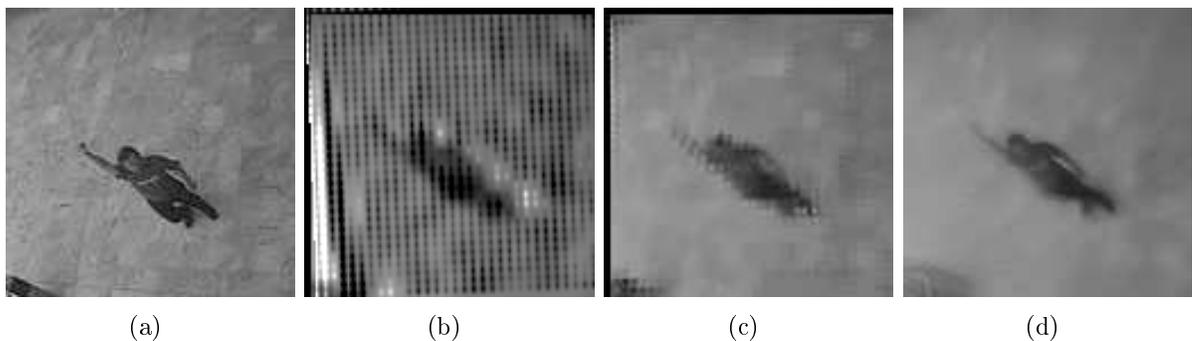


Figura 4.14: Resultados obtidos a partir das técnicas avaliadas com fator de ampliação de $4\times$. (a) imagem original; (b) IBP; (c) POCS; (d) método proposto.

4.6 Discussão

Esta seção apresenta uma discussão sobre os resultados experimentais obtidos a partir da aplicação do método proposto de super-resolução de imagens.

A configuração dos parâmetros utilizados no método influencia sua acurácia, tal que os parâmetros devem ser criteriosamente estimados. Nos gráficos mostrados nas Figuras 4.8 e 4.12, pode-se observar a tendência no aumento do valor de RMSE à medida que valor de α aumenta. Este parâmetro afeta diretamente a qualidade das imagens produzidas, uma vez que, quanto maior o seu valor, mais informações ruidosas são inseridas nos resultados.

As configurações dos parâmetros sugeridas nas Seções 4.4 e 4.5 para super-resolução de uma única imagem e múltiplas imagens, respectivamente, resultaram em acurácia superior aos outros métodos comparados.

Para super-resolução de única imagem, o desempenho médio do método proposto é próximo ao método de super-resolução GPP [46] aplicado isoladamente. Entretanto, conforme Tabelas 4.2 e 4.3, observou-se que o método proposto obteve melhor eficácia que os demais comparados na maioria das amostras analisadas.

Uma desvantagem do método de super-resolução de única imagem é o uso de um conjunto de treinamento durante a fase de aprendizado. Para garantir um bom desempenho, as imagens de treinamento deveriam ser relativamente homogêneas (similares) entre si. No entanto, essa desvantagem não ocorre para o método de super-resolução de múltiplas imagens, visto que o conjunto de treinamento é gerado a partir da própria sequência. Nesta abordagem, a diferença nos resultados entre os métodos apresentados na literatura e o método proposto é significativa (Tabelas 4.5 e 4.6).

Capítulo 5

Conclusões e Trabalhos Futuros

Devido à demanda por imagens de alta resolução em diversos domínios de conhecimento e ainda ao custo elevado dos sensores de alta precisão e às limitações existentes para redução do tamanho dos pixels das imagens encontradas no próprio sensor, técnicas de super-resolução apresentam grande importância na obtenção de imagens de alta resolução.

Este trabalho propôs dois métodos de super-resolução baseados em aprendizado, um para única imagem e uma adaptação do mesmo para sequência de imagens. No método proposto para super-resolução de única imagem, considera-se uma base de treinamento contendo um conjunto de pares de imagens de alta e baixa resolução correspondentes. Como o objetivo consiste em acrescentar informações na imagem resultante por meio de compensação residual, em que os pesos para a reconstrução dos resíduos são aprendidos na base de treinamento a partir dos seus descritores, esta base precisa ser bem manipulada. A abordagem é iterativa, os descritores de características são extraídos pelo método HSC e a técnica de aprendizado adotada é o LLE.

No método de super-resolução de múltiplas imagens, em que as informações provenientes de várias imagens de baixa resolução são utilizadas para recuperar os detalhes e gerar uma imagem em alta resolução, o processo de fusão das imagens é realizado a partir do método SIFT. As imagens são fundidas duas a duas e, para super-resolver, o método iterativamente faz uso do método de super-resolução de única imagem proposto.

De acordo com as comparações efetuadas e apresentadas no Capítulo 4, os métodos desenvolvidos neste trabalho obtiveram os melhores resultados na maioria dos testes realizados. Para uma única imagem, observou-se que o método proposto por Yu et al. [52] gera vários artefatos nas imagens super-resolvidas, o que não ocorreu com o método proposto. Isto indica que a utilização de descritores robustos de características provê melhores candidatos e o LLE é capaz de estimar uma reconstrução mais acurada para as imagens super-resolvidas. Para as sequências de imagens, pode-se observar uma melhor nitidez

nos resultados apresentados utilizando o método de fusão juntamente com o desempenho do método de super-resolução de única imagem.

Como proposta para trabalhos futuros, sugere-se a utilização de blocos da imagem para compensação residual, ao invés de utilizar a imagem como um todo. Com essa alteração, imagina-se que o desempenho do método fique menos suscetível à base de treinamento e a compensação residual seja mais precisa.

Bibliografia

- [1] W. Ayala and J. Domingo. Spatial Size Distributions: Applications to Shape and Texture Analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(12):1430–1442, Dec. 2001.
- [2] B. Bascle, A. Blake, and A. Zisserman. Motion Deblurring and Super-resolution from an Image Sequence. In *Fourth European Conference on Computer Vision*, pages 573–582. Springer-Verlag, 1996.
- [3] N. A. V. Beça. Construção de uma Câmara de Alta Sensibilidade e Baixa Resolução para Super-Resolução. Master’s thesis, Faculdade de Ciências e Tecnologia, Universidade de Coimbra, Coimbra, Portugal, 2008.
- [4] S. Borman and R. L. Stevenson. Super-Resolution from Image Sequences - A Review. In *Midwest Symposium on Circuits and Systems*, pages 374–378, 1998.
- [5] CAVIAR. CAVIAR Test Case Scenarios. <http://homepages.inf.ed.ac.uk/rbf/CAVIARDATA1/>, acesso em Abril 2011.
- [6] H. Chang, D.-Y. Yeung, and Y. Xiong. Super-Resolution through Neighbor Embedding. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 275–282, 2004.
- [7] S. Chaudhuri. *Super-Resolution Imaging*. The Springer International Series in Engineering and Computer Science, 2001.
- [8] S. Chaudhuri. *Super-Resolution Imaging*. Kluwer Academic Publishers, 2001.
- [9] F. B. da Silva. Super-Resolução Utilizando Quadros Chaves em Sequências de Vídeo de Resolução Mista. Master’s thesis, Departamento de Ciência da Computação, Universidade de Brasília, Brasília, DF, 2009.
- [10] N. Dalal and B. Triggs. Histograms of Oriented Gradients for Human Detection. In *IEEE Conference on Computer Vision and Pattern Recognition*, pages 886–893, San Diego, CA, USA, June 2005.

- [11] DDSM. Digital Database for Screening Mammography. University of South Florida Digital Mammography. <http://marathon.csee.usf.edu/Mammography/Database.html>, acesso em Abril 2010.
- [12] L. L. de Almeida and A. M. G. Tommaselli. Melhoramento da Resolução a partir de Sequências de Imagens. *Boletim de Ciências Geodésicas*, 9(2):163–178, July/Dec. 2003.
- [13] R. Destobbeleire. Super-Resolution. Technical report, Instituto de Matemática Pura e Aplicada, Rio de Janeiro-RJ, 2002.
- [14] S. Farsiu, D. Robinson, M. Elad, and P. Milanfar. Advances and Challenges in Super-Resolution. *International Journal of Imaging Systems and Technology*, 14:47–57, 2004.
- [15] S. Farsiu, M. D. Robinson, M. Elad, and P. Milanfar. Fast and Robust Multiframe Super Resolution. *IEEE Transactions on Image Processing*, 13(10):1327–1344, Oct. 2004.
- [16] S. R. Fountain and T. N. Tan. Efficient Rotation Invariant Texture Features for Content-Based Image Retrieval. *Pattern Recognition*, 31(11):1725–1732, 1998.
- [17] W. T. Freeman, T. R. Jones, and E. C. Pasztor. Example-Based Super-Resolution. *IEEE Computer Graphics and Applications*, 22(2):56–65, Mar. 2002.
- [18] R. C. Gonzalez and R. E. Woods. *Processamento de Imagens Digitais*. Edgard Blucher Ltda, São Paulo, SP, Brasil, 2000.
- [19] R. M. Haralick, K. Shanmugam, and I. Dinstein. Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*, 3(6):610–621, Nov. 1973.
- [20] M. Irani and S. Peleg. Improving Resolution by Image Registration. *Graphical Models and Image Processing*, 53(3):231–239, May 1991.
- [21] W. Lim. The Discrete Shearlet Transform: A New Directional Transform and Compactly Supported Shearlet Frames. *IEEE Transactions on Image Processing*, 19(5):1166–1180, May 2010.
- [22] F. C. Lin, C. B. Fookes, V. Chandran, and S. Sridharan. Investigation into Optical Flow Super-Resolution for Surveillance Applications. In *APRS Workshop on Digital Image Computing: Pattern Recognition and Imaging for Medical Applications*, Brisbane, Australia, Feb. 2005.

- [23] X. Liu, D. Song, C. Dong, and H. Li. MAP-Based Image Super-Resolution Reconstruction. In *Proceedings of World Academy of Science*, pages 208–211, 2008.
- [24] D. Lowe. Object Recognition from Local Scale-Invariant Features. In *Proceedings of the International Conference on Computer Vision*, volume 2, pages 1150–1157, 1999.
- [25] D. Lowe. Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision*, 60:91–110, Nov. 2004.
- [26] W. Lucien. Definitions and Terms of Reference in Data Fusion. *IEEE Transactions on Geosciences and Remote Sensing*, 37(3):1190–1193, 1999.
- [27] W. Lucien, T. Ranchin, and M. Mangolini. Fusion of Satellite Images of Different Spatial Resolutions: Assessing the Quality of Resulting Images. *Photogrammetric Engineering & Remote Sensing*, 63:691–699, 1997.
- [28] A. Martins. Uso do Algoritmo ICM Adaptativo a Descontinuidades para o Aumento da Resolução de Imagens Digitais por Técnicas de Reconstrução por Super-Resolução. Master’s thesis, Departamento de Computação, Universidade Federal de São Carlos, São Carlos, SP, Brasil, 2007.
- [29] C. J. F. Medeiros and J. A. F. Costa. Uma Comparação Empírica de Métodos de Redução de Dimensionalidade Aplicados a Visualização de Dados. *Revista da Sociedade Brasileira de Redes Neurais (SBRN)*, 6(2):81–110, 2008.
- [30] H.-H. Nagel. Image Sequence Server. Institut für Algorithmen und Kognitive Systeme, Universität Karlsruhe. http://i21www.ira.uka.de/image_sequences/, acesso em Abril 2011.
- [31] J. M. Ollinger and J. A. Fessler. Positron-emission tomography. *IEEE Signal Processing Magazine*, 14(1):43–55, Jan. 1997.
- [32] K. Onishi, T. Takiguchi, and Y. Arika. 3D Human Posture Estimation using the HOG Features from Monocular Image. In *19th International Conference on Pattern Recognition*, pages 1–4, Tampa, FL, USA, Dec. 2008.
- [33] J. P. Papa. Restauração das Imagens do Satélite CBERS-1 Utilizando POCS. Master’s thesis, Universidade Federal de São Carlos, Departamento de Computação, 2005.
- [34] S. C. Park, M. K. Park, and M. G. Kang. Super-Resolution Image Reconstruction: A Technical Overview. *IEEE Signal Processing Magazine*, 20(3):21–36, 2003.

- [35] A. J. Patti and Y. Altunbasak. Artifact Reduction for Set Theoretic Super Resolution Image Reconstruction with Edge Adaptive Constraints and Higher-Order Interpolants. *IEEE Transactions on Image Processing*, 10(1):179–186, Jan. 2001.
- [36] H. Pedrini and W. Schwartz. *Análise de Imagens Digitais - Princípios, Algoritmos e Aplicações*. Pioneira Thomson, 2007.
- [37] P. J. Phillips, H. Moon, S. A. Rizvi, and P. J. Rauss. The FERET Evaluation Methodology for Face-Recognition Algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22:1090–1104, 2000.
- [38] S. Roweis and L. Saul. Nonlinear Dimensionality Reduction by Locally Linear Embedding. *Science*, 290:2323–2326, Dec. 2000.
- [39] C. Rubert, L. Fonseca, and L. Velho. Super-Resolução de Imagens de Sensores Remotos Usando a Transformada de Cor YUV para Estimação das Altas Frequências. In *IV Workshop dos Cursos de Computação Aplicada*. INPE, 2004.
- [40] A. Rézio and H. Pedrini. Avaliação de Interpoladores para Super-Resolução de Vídeos. In *VI Workshop de Visão Computacional*, pages 54–59, Presidente Prudente-SP, Brasil, July 2010.
- [41] Y. Saad. *Iterative Methods for Sparse Linear Systems*. International Thompson Publishing, 1995.
- [42] R. R. Schultz and R. L. Stevenson. Extraction of High-Resolution Frames from Video Sequences. *IEEE Transactions on Image Processing*, 5(6):996–1011, June 1996.
- [43] W. Schwartz, R. da Silva, L. Davis, and H. Pedrini. A Novel Feature Descriptor Based on the Shearlet Transform. In *IEEE International Conference on Image Processing*, Brussels, Belgium, Sept. 2011.
- [44] A. H. S. Solberg and A. K. Jain. A Study of the Invariance Properties of Textural Features in SAR Images. *IEEE Transactions on Computers*, pages 670–672, July 1995.
- [45] H. Stark. Theory of Convex Projection and its Application to Image Restoration. *IEEE International Symposium on Circuits and Systems*, pages 963–964, 1988.
- [46] J. Sun, J. Sun, Z. Xu, and H.-Y. Shum. Image Super-resolution using gradient profile prior. *IEEE Conference on Computer Vision and Pattern Recognition*, 2008.

- [47] J. Sun, J. Sun, Z. Xu, and H.-Y. Shum. Gradient Profile Prior and Its Applications in Image Super-Resolution and Enhancement. *IEEE Transactions on Image Processing*, 2010.
- [48] M. Telles Jr. *Super-Resolução de Imagens de Sensoriamento Remoto*. PhD thesis, Instituto de Geociências, Universidade de Brasília, Brasília, DF, Brasil, 2008.
- [49] M. Telles Jr and A. Santa Rosa. Super-Resolução de Imagens CBERS 2. In *XIII Simpósio Brasileiro de Sensoriamento Remoto*, pages 1197–1204, 2007.
- [50] L. Yaroslavsky. Signal Sinc-Interpolation: A Fast Computer Algorithm. *Bioimaging*, 4:255–231, 1996.
- [51] S. Yi, D. Labate, G. Easley, and H. Krim. A Shearlet Approach to Edge Analysis and Detection. *IEEE Transactions on Image Processing*, 18(5):929–941, May 2009.
- [52] H. Yu, M. Xiang, H. Hua, and Q. Chun. Face Image Super-Resolution through POCS and Residue Compensation. *IET Conference Publications*, pages 494–497, 2008.
- [53] H. S. Z. Wang, A. Bovik and E. Simoncelli. Image Quality Assessment: From Error Visibility to Structural Similarity. *IEEE Transactions on Image Processing*, 13(4):600–612, Apr. 2004.
- [54] J. Zheng, O. Fuentes, M. Leung, and E. Jackson. Mammogram Compression Using Super-Resolution. In *Digital Mammography / IWDM'10*, pages 46–53, 2010.
- [55] M. V. W. Zibetti. *Super-Resolução Simultânea para Sequência de Imagens*. PhD thesis, Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil, 2007.
- [56] M. V. W. Zibetti and J. Mayer. Super-Resolução Aplicada em Sensoriamento Remoto. In *XIII Simpósio Brasileiro de Sensoriamento Remoto*, pages 6407–6414, 2007.