

SUPER-RESOLUÇÃO DE IMAGENS BASEADA EM APRENDIZADO UTILIZANDO DESCRITORES DE CARACTERÍSTICAS

Ana Carolina Correia Rézio, William Robson Schwartz, Hélio Pedrini

Instituto de Computação - Universidade Estadual de Campinas, Campinas, SP, Brasil, 13084-971
aninharlx@gmail.com, {schwartz,helio}@ic.unicamp.br

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 imagens a partir da compensação residual aprendida pelas características extraídas a partir da imagem residual e de um 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.

Palavras-chave – Super-resolução, visão computacional, descritores de características, resolução de imagens.

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 images through the compensation of residual learned by feature descriptors extracted from the residual image and a set of training images. Results show that, in most of experiments, the proposed method achieves lower error compared to other state-of-art approaches.

Keywords – Super-resolution, computer vision, feature descriptors, image resolution.

1 INTRODUÇÃO

Em diversas aplicações, tais como medicina, biologia, automação industrial, vigilância, sensoriamento remoto, há uma grande demanda de imagens com alta resolução espacial [1–3]. Essas imagens possibilitam a análise e a visualização mais precisas dos detalhes presentes nos dados. Em virtude de fatores associados ao custo e às limitações dos dispositivos de aquisição, uma alternativa é aumentar a resolução e melhora da qualidade psicovisual das imagens por meio da aplicação de técnicas conhecidas como super-resolução.

Técnicas de super-resolução têm recebido crescente interesse nos últimos anos [4], cujo objetivo principal é aumentar a resolução espacial das imagens, favorecendo a precisão na análise e interpretação das imagens, melhorando a qualidade da visualização e preservando as informações originais sem a adição de artefatos às imagens resultantes [5–8].

Três principais abordagens são aplicadas para a obtenção de imagens super-resolvidas: baseadas em interpolação, baseadas em reconstrução e baseadas em aprendizado. Em geral, métodos mais recentes se baseiam na última abordagem. Um exemplo é o trabalho desenvolvido por Yu et al. [9], que utiliza a compensação residual associado a um método de aprendizado conhecido como *Locally-Linear Embedding* (LLE) [10] para efetuar a correspondência entre imagens residuais de baixa e alta resolução. No entanto, um problema é que este método apresenta diretamente os resíduos para o LLE, o que impede uma estimação acurada das imagens super-resolvidas, como será mostrado nos resultados experimentais.

Ao contrário do método desenvolvido por Yu et al. [9], neste trabalho é apresentada uma metodologia de super-resolução também baseada em compensação residual e LLE, entretanto, com a representação do resíduo sendo feita por meio de descritores de características, o que possibilita uma melhor estimação das imagens super-resolvidas, removendo diversos artefatos. Adicionalmente, também aplica-se um método de estimação inicial da imagem super-resolvida mais robusto que aquele utilizado por Yu et al. [9], denominado *Gradient Profile Prior* (GPP), o qual possui um maior foco na preservação de bordas.

Utiliza-se o método chamado histograma de coeficientes shearlets (HSC, do inglês *Histogram of Shearlet Coefficients*) [11] para extração de descritores de características. O HSC é baseado na análise multiescala acurada provida pela transformada shearlet e no uso de histogramas para estimação da distribuição da orientação de bordas. Seu uso tem-se mostrado bastante viável para aplicações envolvendo reconhecimento facial. Os resultados experimentais mostram que a descrição do resíduo utilizando HSC proporciona uma redução significativa de artefatos resultantes da aplicação da super-resolução.

O texto está organizado da seguinte forma. A seção 2 descreve brevemente os métodos de super-resolução utilizados nos experimentos. A seção 3 apresenta a metodologia proposta. Os resultados experimentais obtidos a partir da aplicação dos

métodos em imagens da base de imagens faciais FERET [12] são apresentados e analisados na seção 4. Finalmente, a seção 5 conclui o trabalho.

2 TRABALHOS RELACIONADOS

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. A resolução radiométrica consiste na quantificação de radiação eletromagnética empregada para amostrar a luminosidade refletida pela cena.

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

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

Métodos Baseados em Interpolação

Nos métodos baseados em interpolação da imagem, a estimação dos valores dos pixels na imagem de alta resolução é realizada pela interpolação da intensidade ou cor dos pixels já existentes na imagem de entrada.

Há vários métodos de interpolação existentes na literatura [13, 14], 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.

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.

Métodos Baseados em Reconstrução

A técnica de super-resolução *Iterative Back-Projection* (IBP), criada a partir de variações da técnica de *back-projection* originalmente proposta para reconstrução de vistas tomográficas de imagens médicas, utiliza um procedimento iterativo para minimização do erro entre os dados originais e a saída do modelo [3, 15], conforme equação

$$HR_k^{n+1} = HR_k^n + \sum_{j=1}^L H_{k,j}^{BP} (LR_j - C_{j,k} HR_k^n) \quad (1)$$

em que HR_k^{n+1} é uma imagem de alta resolução no instante k , $H_{k,j}^{BP}$ é o operador de *back-projection*, n é a iteração corrente, L é o número de imagens de baixa resolução, essas representadas por LR , $C_{j,k}$ é a matriz de transformação conjunta de movimento e aquisição. Este método é similar aos métodos iterativos para solução de mínimos quadrados. Uma de suas vantagens é a velocidade de convergência, a qual está associada ao operador *back-projection* [15].

Projeções em conjuntos convexos (POCS), 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 [16]. 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 uma convergência ou o processo é interrompido por um critério previamente estabelecido. 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 conterá todas as possíveis soluções do problema pois cada uma delas satisfaz a uma das informações desconhecidas.

Algumas melhorias nos métodos de reconstrução por super-resolução baseado no método POCS foram propostas por Patti e Altunbasak [17]. 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 *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 [18, 19] 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 [18, 19] 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

$$HR^{t+1} = HR^t - \tau \frac{\partial E(HR)}{\partial HR} \quad (2)$$

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

Métodos Baseados em Aprendizado

Destobbeleire [20] 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 [21]. 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.

O método proposto por Yu et al. [9] para super-resolução de imagem de face 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 da aprendizagem entre os dois conjuntos de bases de treinamento de resíduos de imagens de baixa e alta resolução correspondentes. A imagem de super-resolução é aprendida pela compensação do resíduo para imagem de alta resolução reconstruída inicial. O método utiliza o algoritmo de aprendizado de máquina chamado *Locally-Linear Embedding* (LLE) [10].

O método de aprendizado proposto em [9] 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 residual de baixa resolução é calculado como

$$\hat{g} = H\hat{f}r = g - \hat{g} \quad (3)$$

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

$$f_{n+1} = \hat{f}_n + \alpha\hat{s} \in (0, 1] \quad (4)$$

3 METODOLOGIA

O método proposto, baseado em ideias apresentadas por Yu et al. [9], utiliza a compensação residual iterativa para obter uma imagem super-resolvida (SR), 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. 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 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. Como as imagens de testes estão em baixa resolução é necessário determinar, na base de treinamento, os resíduos de baixa e de alta resolução correspondentes. No diagrama, as imagens da base em alta resolução são suavizadas e subamostradas gerando as imagens em baixa resolução.

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 1.

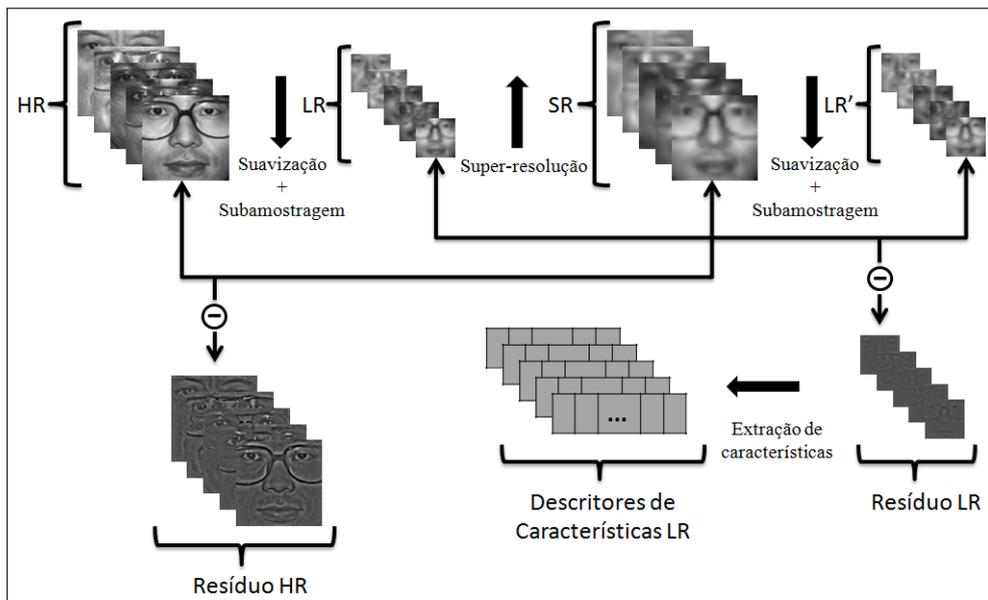


Figura 1: Processamento na base de treinamento das imagens.

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 na base de treinamento, pode-se iniciar o processo de super-resolução proposto no diagrama apresentado na Figura 2. 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 na base 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.

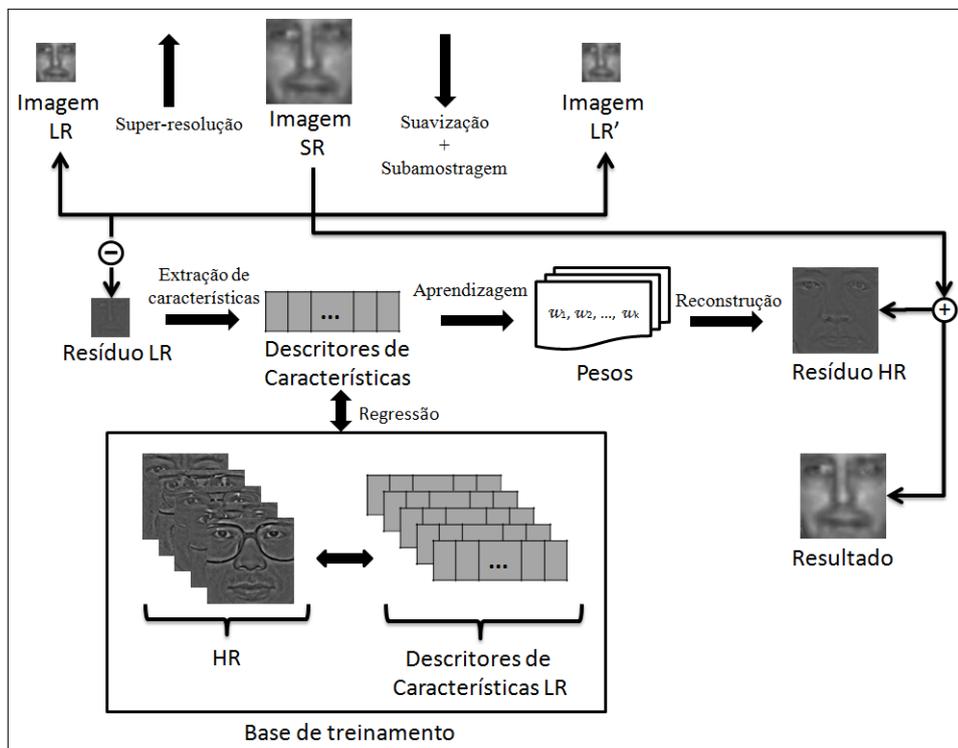


Figura 2: Método proposto para super-resolução de única imagem.

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, a raiz do erro médio quadrático (RMSE, do inglês *root mean square error*) do resíduo de baixa resolução (*resLR*) é calculado e este resíduo é determinado pela diferença entre as imagens LR e LR'.

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 5 a seguir. Como mencionado, este resíduo é reconstruído a partir da soma ponderada de várias amostras residuais de alta resolução presentes na base de treinamento.

$$SR_{n+1} = SR_n + \alpha \text{resHR} \quad (5)$$

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 na base 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, para os k vetores, os resíduos de alta resolução correspondentes.

Depois de aprendido os pesos e seus respectivos k vizinhos (resíduos de alta resolução), a imagem de resíduo de alta resolução é reconstruída pela soma ponderada, gerando a imagem *resHR*. Conforme Equação 5, 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 são apresentados no Algoritmo 1.

Algoritmo 1: Método de super-resolução.

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 = amostragem(teste, zoom)
2  for iter = 1 to maxIter do
3      LR = suavização(SR)
4      LR = amostragem(LR, 1/zoom)
5      resLR = teste - LR
6      if RMSE(resLR) < limiar then
7          return SR
8      end
9      descritores = extraiDescritores(resLR)
10     (viz, w) = LLE(descritores, treinamento, k)
11     resHR = w1viz1 + w2viz2 + ... + wkvizk
12     SR = SR + α resHR
13 end
14 return SR

```

4 RESULTADOS EXPERIMENTAIS

Esta seção descreve uma série de experimentos realizados e seus resultados utilizando o método de super-resolução proposto. Todos os experimentos relatados foram executados em computador com processador Intel(R) Core(TM) 2 Duo 2.2GHz, 6GB de RAM. A implementação foi feita em Matlab, no entanto, o programa faz uso de funções implementadas em C. O sistema operacional utilizado foi o Windows 7 Ultimate de 32 bits.

Base de Dados Para avaliar o desempenho da metodologia, os experimentos utilizaram 248 imagens em alta resolução retiradas da base de dados FERET [12], amplamente aplicada para o problema de reconhecimento de faces. Dessas imagens, 228 foram consideradas durante a etapa de treinamento do método proposto e 20 imagens foram utilizadas como *ground truth* e depois de suavizadas e subamostradas foram consideradas como imagens de teste. Estas imagens pertencem a indivíduos distintos e estão alinhadas pelos olhos e possuem 84×84 pixels e estão em níveis de cinza.

Métricas de Avaliação O processo de avaliação da qualidade da imagem de super-resolução (SR) obtida em relação à imagem de referência (LR) foi feito por meio da raiz do erro médio quadrático e do índice de similaridade estrutural, definidos a seguir.

A raiz do erro médio quadrático (RMSE, do inglês *Root Mean Square Error*) corresponde à soma da raiz quadrada da soma do quadrado das diferenças de cada ponto das imagens LR e HR. Essa medida indica o grau de similaridade entre as imagens LR e HR, tendo valor igual a zero quando as duas imagens são idênticas. A medida é dada pela Equação 6, em que M e N denotam as dimensões das imagens.

$$RMSE = \sqrt{\frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [LR(x, y) - HR(x, y)]^2} \quad (6)$$

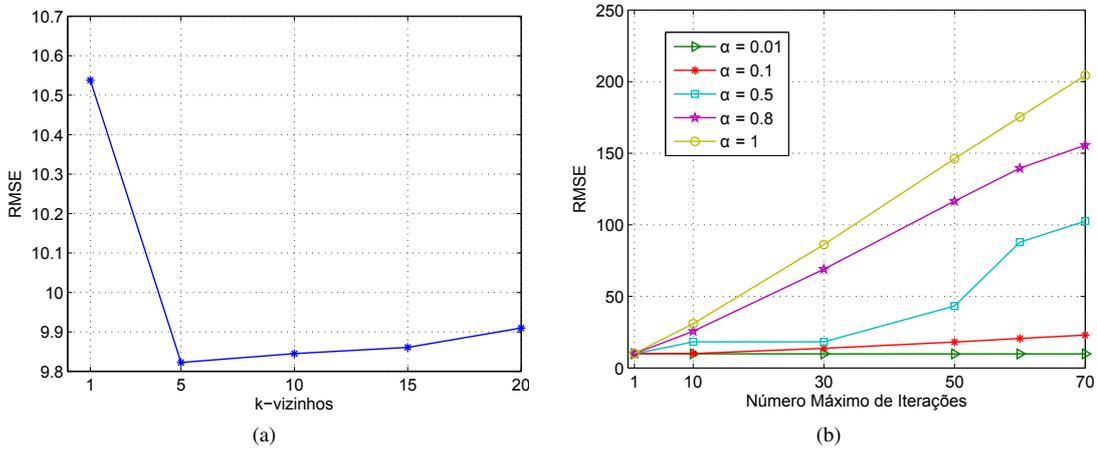


Figura 3: Estimação de parâmetros para o LLE e número de iterações, em função do RMSE. (a) número de vizinhos; (b) parâmetro α e número de iterações.

O índice de similaridade estrutural (SSIM, do inglês *Structural SIMilarity*) foi proposto em [22]. 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 [2]. O SSIM é dado por

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (7)$$

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 [22], utilizou-se $C_1 = 0.01$ e $C_2 = 0.03$. Nesta medida, os valores resultantes são normalizados entre 0 e 1, e valores mais próximo de 1 indicam a melhor qualidade da imagem.

Parâmetros Nos experimentos realizados, alguns parâmetros e funções precisam ser previamente definidos. Na amostragem, com objetivo de aumentar a resolução da imagem (linha 1 do Algoritmo 1), foi utilizado o método de super-resolução GPP (descrito na seção 2). O resultado desta reamostragem é uma estimativa inicial da imagem de super-resolução resultante do método.

A partir deste ponto, inicia-se um processo iterativo. A linha 3 do algoritmo refere-se a uma função de suavização. Como o objetivo é reduzir a qualidade da imagem, utilizou-se um filtro passa baixa Gaussiano. O outro método utilizado para amostragem é a interpolação bilinear, neste caso, o objetivo consiste em reduzir a resolução da imagem (linha 4).

Depois da suavização e subamostragem é gerado 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 RMSE do resíduo seja menor do que o limiar previamente estabelecido. Nos experimentos realizados, utilizou-se limiar igual a 0.1. Caso a condição não seja atendida, inicia-se o processo de extração dos descritores de características (função da linha 8), este baseado no HSC [11]. Os vetores de características resultantes serão utilizados para a estimação dos pesos da reconstrução do resíduo de baixa resolução.

Após a extração dos descritores, o próximo passo (linha 9) consiste em aprender os pesos dos descritores para a reconstrução. O método utilizado para aprendizagem foi o LLE (apresentado na seção 2). Neste método, a partir do conjunto de treinamento, localiza-se os k -vizinhos mais próximos dos descritores de características extraídos do resíduo. Para cada um desses vizinhos é atribuído um peso proporcional a sua importância na reconstrução do resíduo de baixa resolução. A função da linha 9 retorna os vizinhos localizados (*viz*) e seus respectivos pesos w . A partir dessas variáveis, reconstrói-se o resíduo de alta resolução (*resHR*), conforme linha 10 do algoritmo, utilizando-se o resíduo de alta resolução associado a cada imagem de baixa resolução.

O valor de k é empírico e foi determinado experimentalmente utilizando o conjunto de treinamento. Conforme os resultados mostrados na Figura 3(a), o número de vizinhos que obteve o menor erro de reconstrução foi 5, valor utilizado no restante dos experimentos.

Após determinado o resíduo de alta resolução, o próximo passo consiste em adicionar este resíduo à imagem de super-resolução inicialmente estimada. Para tanto, este resíduo deve ser suavizado por uma variável α , cujo valor é experimentalmente estimado, assim como o número máximo de iterações (*maxIter*) a serem realizadas. Para determinar estes valores, foram realizados alguns testes utilizando o conjunto de treinamento, conforme gráfico da Figura 3(b). Pode-se observar que o método possui melhor desempenho para α com valores menores. Nos experimentos foram utilizados os valores de α igual a 0.01 e o número máximo de iterações igual a 50, ponto que apresentou menor RMSE para o valor de α fornecido.

Resultados e Comparações Para avaliar o método proposto foram escolhidos outros métodos para realizar a comparação. Destes métodos, alguns se baseiam em reamostragem: vizinho mais próximo, bilinear e bicúbica, e os outros são de super-resolução: GPP, IBP, POCS. Também é avaliado o método proposto por Yu et al. [9]. A média dos resultados para medidas

Tabela 1: Média dos resultados da avaliação entre 20 amostras obtidas com as técnicas de interpolação e de super-resolução para fatores de ampliação iguais a $2\times$ e $4\times$.

Método	$2\times$		$4\times$	
	RMSE	SSIM	RMSE	SSIM
Vizinho mais próximo [14]	11.4942	0.9409	17.1981	0.8582
Bilinear [14]	11.3881	0.9395	16.6832	0.8579
Bicúbica [14]	10.2492	0.9522	15.5587	0.8809
IBP [15]	11.6037	0.9420	20.0407	0.8236
GPP [19]	10.0383	0.9550	15.3464	0.8863
POCS [16]	10.8597	0.9509	16.6818	0.8579
POCS + Resíduo + LLE [9]	10.8438	0.9508	16.6884	0.8573
método proposto	9.8276	0.9569	15.2125	0.8887

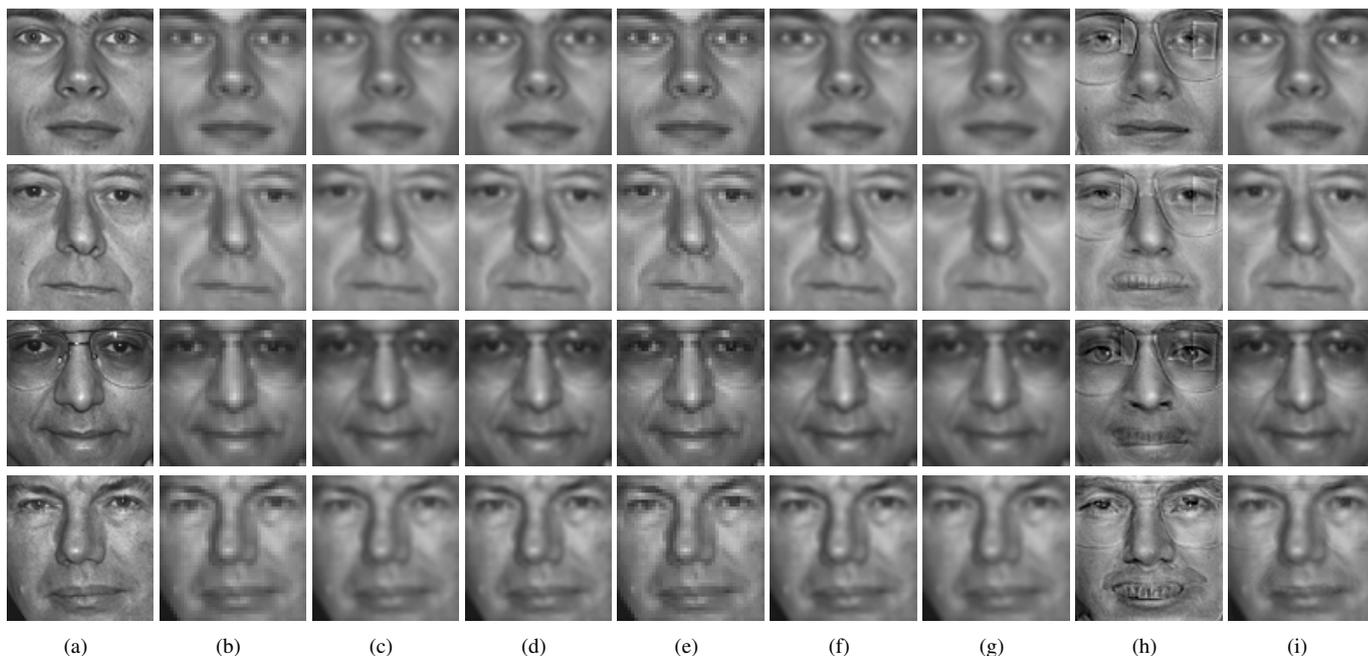
RMSE e SSIM é apresentada na Tabela 1. Conforme destacado em negrito na tabela, o método proposto possui, na média, melhores resultados tanto em relação ao RMSE quanto ao SSIM.

Para uma análise quantitativa, a Figura 4 apresenta resultados para quatro amostras (uma por linha). Os respectivos valores de RMSE e SSIM são mostrados na Tabela 2. Como destacado, 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 GPP aplicado isoladamente.

Tabela 2: Resultados com o métodos de interpolação e super-resolução com fator de ampliação de $2\times$.

Método	Amostra 1	Amostra 2	Amostra 3	Amostra 4
Vizinho mais próximo [14]	9.8216	9.6921	11.2949	10.2843
Bilinear [14]	9.6588	9.6222	11.2988	10.1636
Bicúbica [14]	8.6044	8.5594	10.4541	9.0905
IBP [15]	10.0070	9.7471	11.3162	10.4225
GPP [19]	8.4115	8.3515	10.3139	8.8521
POCS [16]	9.1853	9.0039	10.7507	9.8038
POCS + Resíduo + LLE [9]	9.1176	8.9786	10.7528	9.7875
método proposto	6.4071	6.8376	8.8312	9.6221

A análise quantitativa demonstra que, em geral, os métodos com resíduos utilizando estimativa inicial com método GPP apresentam melhor eficácia, destacando-se o método proposto. Adicionalmente, percebe-se vários artefatos presentes nas imagens super-resolvidas pelo método proposto por Yu et al. [9], 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.

Figura 4: Resultados obtidos para quatro amostras, uma por linha, a partir das técnicas avaliadas com fator de ampliação de $2\times$. (a) imagem original; (b) vizinho mais próximo; (c) bilinear; (d) bicúbica; (e) IBP; (f) GPP; (g) POCS; (h) POCS+Resíduo+LLE; (i) método proposto.

5 CONCLUSÕES

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 interpolação apresentam grande importância na obtenção de imagens de alta resolução.

Este artigo apresentou uma metodologia que utiliza a compensação residual iterativa baseada em conjunto de treinamento, extração de características e o método de aprendizado LLE visando à obtenção de imagens super-resolvidas. De acordo com as comparações efetuadas, o método proposto obteve os melhores resultados na maioria dos testes. Adicionalmente, percebeu-se que vários artefatos presentes nas imagens super-resolvidas pelo método proposto por Yu et al. [9] são removidos, indicando que a utilização de descritores de características provê melhores candidatos e o LLE é capaz de estimar uma reconstrução mais acurada para as imagens super-resolvidas.

REFERÊNCIAS

- [1] S. Chaudhuri. *Super-Resolution Imaging*. Kluwer Academic Publishers, 2001.
- [2] A. Rézio and H. Pedrini. “Avaliação de Interpoladores para Super-Resolução de Vídeos”. In *VI Workshop de Visão Computacional (WVC'2010)*, pp. 54–59, Presidente Prudente-SP, Brasil, July 2010.
- [3] M. V. W. Zibetti and J. Mayer. “Super-Resolução Aplicada em Sensoriamento Remoto”. In *XIII Simpósio Brasileiro de Sensoriamento Remoto*, pp. 6407–6414, 2007.
- [4] 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.
- [5] X. Liu, D. Song, C. Dong and H. Li. “MAP-Based Image Super-Resolution Reconstruction”. In *Proceedings of World Academy of Science*, pp. 208–211, 2008.
- [6] F. B. da Silva. “Super-Resolução Utilizando Quadros Chaves em Sequências de Vídeo de Resolução Mista”. Master’s thesis, Universidade de Brasília, 2009.
- [7] M. A. B. G. Telles Jr. “Fusão de Imagens de Sensoriamento Remoto Utilizando a Transformada Wavelet”. Master’s thesis, Universidade de Brasília, 2003.
- [8] W. Lucien. “Definitions and Terms of Reference in Data Fusion”. *IEEE Transactions on Geosciences and Remote Sensing*, vol. 37, no. 3, pp. 1190–1193, 1999.
- [9] H. Yu, M. Xiang, H. Hua and Q. Chun. “Face Image Super-Resolution through POCS and Residue Compensation”. *IET Conference Publications*, pp. 494–497, 2008.
- [10] H. Chang, D.-Y. Yeung and Y. Xiong. “Super-Resolution through Neighbor Embedding”. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 275–282, 2004.
- [11] W. R. Schwartz, R. D. da Silva, L. S. Davis and H. Pedrini. “A Novel Feature Descriptor Based on the Shearlet Transform”. In *IEEE International Conference on Image Processing*, Brussels, Belgium, 2011. to appear.
- [12] 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*, vol. 22, pp. 1090–1104, 2000.
- [13] 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*, vol. 63, pp. 691–699, 1997.
- [14] H. Pedrini and W. Schwartz. *Análise de Imagens Digitais - Princípios, Algoritmos e Aplicações*. Pioneira Thomson, 2007.
- [15] M. Irani and S. Peleg. “Improving Resolution by Image Registration”. *Graphical Models and Image Processing*, vol. 53, no. 3, pp. 231–239, May 1991.
- [16] H. Stark. “Theory of Convex Projection and its Application to Image Restoration”. *IEEE International Symposium on Circuits and Systems*, pp. 963–964, 1988.
- [17] 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*, vol. 10, no. 1, pp. 179–186, January 2001.
- [18] 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 (CVPR)*, 2008.
- [19] 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.
- [20] R. Destobbeleire. “Super-Resolution”. Technical report, Instituto de Matemática Pura e Aplicada, Rio de Janeiro-RJ, 2002.
- [21] W. T. Freeman, T. R. Jones and E. C. Pasztor. “Example-Based Super-Resolution”. *IEEE Computer Graphics and Applications*, vol. 22, no. 2, pp. 56–65, March 2002.
- [22] H. S. Z. Wang, A. Bovik and E. Simoncelli. “Image Quality Assessment: From Error Visibility to Structural Similarity”. *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600–612, April 2004.