

Super-Resolução Aplicada em Sensoriamento Remoto

Marcelo Victor Wüst Zibetti¹
Joceli Mayer¹

¹ Universidade Federal de Santa Catarina - UFSC
Florianópolis - SC, 88040-900, Brasil
marcelo.zibetti@terra.com.br, mayer@eel.ufsc.br

Abstract. This paper describes the application of the classical and the state-of-art regularized super-resolution methods in remote sensing. These methods are applied in airspace surveillance, aerial photography and satellite image enhancement. The super-resolution methods and its implementations are described in details. Some visual results illustrate the performance of the super-resolution methods for remote sensing applications.

Palavras-chave: super-resolution, image processing, image enhancement, restoration.

1. Introdução

Na maioria das aplicações de imagem em Sensoriamento Remoto é desejável que o sistema de aquisição forneça imagens com a maior resolução possível e introduza uma quantidade mínima de distorções devido às imperfeições óticas e aos ruídos inerentes ao sistema. Entretanto, devido ao alto custo dos sistemas e devido às dificuldades práticas de determinada aplicação nem sempre é possível obter um sistema de imageamento com a resolução desejada.

Uma alternativa para aumentar a resolução e a qualidade das imagens adquiridas, aproveitando os sistemas de aquisição existentes, é a utilização de técnicas de processamento de imagens visando ao aumento de resolução. Diversas técnicas de restauração e interpolação têm sido utilizadas com bastante sucesso para este fim, como Gonzalez (1992), Fonseca (1993) e Bovik (2000). Recentemente, técnicas de processamento, chamadas de Super-Resolução (SR), têm sido desenvolvidas para gerar imagens com resolução superior à fornecida pelo dispositivo de aquisição, conforme Chaudhuri (2001) e Park (2003).

As técnicas de SR procuram remover possíveis distorções geradas no processo de aquisição, realçando, por exemplo, as bordas e os detalhes dos objetos para produzir imagens de alta-resolução (HR - *high-resolution*), considerando as limitações de um determinado sistema de aquisição. As técnicas SR obtêm esta melhoria utilizando modelos que descrevem o comportamento espacial das imagens da seqüência e considerando a informação existente em um conjunto de imagens capturadas da mesma cena.

As técnicas de SR de única imagem são baseadas na utilização de uma informação aprimorada sobre o comportamento espacial das imagens HR. Estas técnicas utilizam uma única imagem capturada para produzir uma única imagem HR, conforme Schultz (1994), onde são utilizados modelos para produção de imagens de objetos com bordas bem nítidas. Em muitos trabalhos estas técnicas são chamadas apenas de melhoramento de imagem.

Contudo, a maioria das técnicas de SR utiliza um conjunto de imagens capturadas para recuperar os detalhes das imagens HR. O objetivo pode ser a produção de uma única imagem HR ou de várias imagens HR. Assume-se que as imagens capturadas, denominadas de imagens de baixa resolução (LR - *Low-resolution*), têm grande similaridade entre si. Porém, uma pequena diferença de informação existente em cada imagem capturada proporciona uma nova informação para a recuperação dos detalhes nas imagens HR. A fonte mais comum desta diferença de informação é o movimento de “subpixel”, descrito em detalhes em Chaudhuri

¹ Este trabalho tem o suporte do CNPQ, proc. 140543/2003-1.

(2001) e Park (2003), o qual ocorre quando o movimento existente entre as imagens é fracionário com respeito à grade de baixa resolução.

Entretanto, a utilização de uma seqüência de imagens com movimento pode trazer algumas dificuldades para os algoritmos SR. Isto pode acontecer devido a erros na estimativa de movimento ou devido a objetos que aparecem em uma imagem e desaparecem em outras imagens. Nestas situações é inevitável a ocorrência de erros na representação do movimento. Portanto, para que se possa aproveitar a informação do movimento de subpixel, é necessário que o algoritmo de super-resolução seja robusto a estes erros. Os métodos de SR robusto, que não requerem detecção ou tratamento especial nestes erros de movimento, são recentes, como Farsiu (2004) e Zibetti (2006). A robustez é muito importante na aplicação prática dos algoritmos de super-resolução.

Neste trabalho vamos mostrar a utilização dos métodos de super-resolução em três aplicações importantes de sensoriamento remoto. São elas: o aumento da resolução de imagens de satélite, super-resolução de fotografias aéreas e melhoramento de resolução de uma seqüência de imagens usadas em vigilância aeroespacial.

Este trabalho está organizado da seguinte forma, na Seção 2 são apresentados os modelos utilizados em super-resolução. Na Seção 3 os algoritmos de super-resolução implementados são apresentados. Os detalhes sobre a implementação dos algoritmos são apresentados na Seção 4. Na Seção 5 os experimentos com as aplicações de sensoriamento remoto são detalhados e na Seção 6 são oferecidas as conclusões.

2. Modelos Utilizados nos Métodos de Super-Resolução

2.1. Modelo de Aquisição de Imagem

O modelo de aquisição descreve as transformações que ocorrem com as imagens HR durante o processo de aquisição. Neste modelo, os dados observados são as imagens LR. O modelo é descrito pela seguinte equação:

$$\mathbf{g}_k = \mathbf{D}_k \mathbf{f}_k + \boldsymbol{\eta}_k \quad (1)$$

onde \mathbf{g}_k é um vetor, de tamanho $N \times 1$, que representa a imagem LR adquirida no instante de tempo k . Os elementos de \mathbf{g}_k correspondem aos pixels da imagem LR, ordenados lexicograficamente. Onde $N=N_1N_2$ é o número de pixels na imagem LR, sendo $N_1 \times N_2$ o tamanho da imagem LR na direção horizontal e vertical, respectivamente. O vetor \mathbf{f}_k , de tamanho $M \times 1$, representa a imagem HR, de tamanho $M_1 \times M_2$, com $M=M_1M_2$ pixels ordenados lexicograficamente, onde $N \leq M$. O vetor $\boldsymbol{\eta}_k$ representa o ruído de aquisição, o qual é normalmente modelado como um ruído Gaussiano branco, de variância σ^2 .

A matriz \mathbf{D}_k , de tamanho $N \times M$, representa o sistema de aquisição para a imagem \mathbf{f}_k . Cada linha de \mathbf{D}_k representa a *Função de Aquisição* do respectivo pixel na imagem LR, e contém a ponderação de cada pixel da imagem HR na formação do pixel da imagem LR. A matriz \mathbf{D}_k é uma versão discretizada do sistema de aquisição contínuo, conforme Barrett (2004). O processo de aquisição degrada a imagem, e \mathbf{D}_k representa as degradações sofridas na aquisição. As degradações são divididas em distorção ótica, gerada nas lentes e fotossensores, e a distorção devido à subamostragem, a qual depende do arranjo geométrico dos sensores. A subamostragem implica na redução do número de amostras ou pixels.

2.2. Modelo de Movimento entre Imagens

O modelo de movimento descreve a transformação causada pelo movimento entre as imagens da seqüência. Este modelo é necessário quando um conjunto de imagens capturadas com movimento é utilizado. Assume-se que a imagem no instante temporal k pode ser composta

pela imagem do instante temporal j , com o movimento compensado, mais uma nova informação, que não pode ser obtida da imagem no instante j . A equação que descreve o modelo é:

$$\mathbf{f}_k = \mathbf{M}_{k,j} \mathbf{f}_j + \mathbf{e}_{k,j} \quad (2)$$

onde \mathbf{f}_k e \mathbf{f}_j são vetores que representam as imagens nos instantes temporais k e j , respectivamente. A matriz $\mathbf{M}_{k,j}$, de tamanho $M \times M$, representa a transformação de movimento. Esta matriz é, normalmente, bastante esparsa. Uma linha m , qualquer, é quase toda composta por zeros, exceto por: 1) um elemento com valor unitário, na coluna n , que representa o deslocamento do pixel n em \mathbf{f}_j para posição m em \mathbf{f}_k ; 2) poucos elementos não-nulos que correspondem a combinação de determinados pixels (interpolação) de \mathbf{f}_j para formar o pixel m em \mathbf{f}_k . Isso ocorre em movimentos cujo deslocamento do pixel é fracionário na grade de alta resolução.

A matriz $\mathbf{M}_{k,j}$ pode ser uma versão discretizada do operador contínuo de transformação de movimento, no caso de movimento paramétrico, ou pode ser criada a partir de um campo discreto de vetores de movimento, conforme Stiller (1999).

O vetor $\mathbf{e}_{k,j}$, também chamado de erro de movimento, representa a nova informação que não pode ser obtida da imagem no instante j . Este vetor pode conter erros de grande magnitude, considerados como *outliers*², conforme Hasler (2003). No contexto do movimento, um *outlier* é geralmente uma região ou um objeto que recebeu oclusão pelo movimento de outros objetos, objetos que aparecem repentinamente na cena ou regiões que sofrem um movimento não esperado. Os *outliers* introduzem distorções nas imagens estimadas. É necessário utilizar algoritmos SR robustos para evitar estas distorções. Neste trabalho vamos considerar os métodos propostos em Farsiu (2004) e Zibetti (2006) que são robustos a este tipo de erro.

2.3. Modelo de Aquisição e de Movimento Combinados

O algoritmo de super-resolução proposto em Farsiu (2004) utiliza o modelo de aquisição combinado com o modelo de movimento. O modelo combinado é utilizado para relacionar uma imagem LR à uma outra imagem HR, em um instante temporal diferente. Esse modelo é descrito pela equação:

$$\begin{aligned} \mathbf{g}_k &= \mathbf{D}_k (\mathbf{M}_{k,j} \mathbf{f}_j + \mathbf{e}_{k,j}) + \boldsymbol{\eta}_k \\ \mathbf{g}_k &= \mathbf{D}_k \mathbf{M}_{k,j} \mathbf{f}_j + \mathbf{D}_k \mathbf{e}_{k,j} + \boldsymbol{\eta}_k \\ \mathbf{g}_k &= \mathbf{C}_{k,j} \mathbf{f}_j + \boldsymbol{\varepsilon}_{k,j} \end{aligned} \quad (3)$$

onde $\mathbf{C}_{k,j} = \mathbf{D}_k \mathbf{M}_{k,j}$ é a matriz de *transformação conjunta* de movimento e aquisição. O erro $\boldsymbol{\varepsilon}_{k,j}$ do modelo combinado é uma soma de dois erros de naturezas diferentes: o ruído de aquisição, $\boldsymbol{\eta}_k$, e o erro de movimento projetado nos dados, $\mathbf{D}_k \mathbf{e}_{k,j}$, o qual pode conter *outliers*.

2.4. Modelos de Imagem

Em geral, super-resolução é um problema mal-posto³, seja porque tem infinitas soluções possíveis ou porque a solução possui grande sensibilidade ao ruído, conforme Park (2003) e Vogel (2002). Para resolver este problema e obter uma solução suave e sem ruído, os algoritmos de super-resolução usam informações adicionais sobre a imagem. Esta informação

² O termo “*outlier*” foi, inicialmente, utilizado em Estatística. Na literatura da área de Estatística um *outlier* é um elemento ou uma medida ruim, geralmente um erro de grande magnitude, que não segue o modelo assumido, conforme Huber (1981).

³ Um problema mal-posto (*ill-posed*) é um problema que tem, pelo menos, uma das seguintes características: não tem solução; tem infinitas soluções; ou a solução é instável em relação a entrada, Vogel (2002).

é tratada, geralmente, como uma penalidade de regularização, conforme Barrett (2004), Vogel (2002) e Bovik (2000).

A informação adicional mais comumente assumida é de que as imagens são suaves. Em outras palavras, as variações na intensidade de \mathbf{f}_k são relativamente pequenas, conforme Bovik (2000). Esta informação adicional é, geralmente, expressa na forma:

$$Q(\mathbf{R}_k \mathbf{f}_k) = P\beta_R \quad (4)$$

onde $Q(\mathbf{x})$ é uma norma escolhida e P é a dimensão do vetor \mathbf{x} . A \mathbf{R}_k , de tamanho $P \times M$, representa um operador “passa-alta”, como os operadores de diferenças finitas ou Laplaciano discreto. O β_R é uma medida conhecida de $Q(\mathbf{x})/P$. O vetor resultante de $\mathbf{R}_k \mathbf{f}_k$ representa as variações na intensidade de \mathbf{f}_k . Em muitos casos, o mesmo operador \mathbf{R}_k é considerado para todas imagens da seqüência.

Em trabalhos como Stevenson (1994) e Bovik (2000) são mencionadas as vantagens da produção de imagens com bordas nítidas. Para isso, a norma Huber, ou a norma ℓ_1 , pode ser utilizada, visando preservar detalhes e bordas. A norma Huber é descrita por $Q(\mathbf{x}) = H_T(\mathbf{x}) = \sum_i h_T(x_i)$, onde:

$$h_T(x_i) = \begin{cases} |x_i|^2 & \text{se } |x_i| \leq T \\ 2T|x_i| - T^2 & \text{se } |x_i| > T \end{cases} \quad (5)$$

sendo x_i um elemento do vetor \mathbf{x} . O parâmetro T determina a influência da região quadrática ou da região linear da norma Huber. Neste modelo, a norma Huber preserva grandes valores das variações de amplitude de \mathbf{f}_k , gerando imagens com detalhes e bordas mais nítidas em relação à implementações baseadas na norma ℓ_2 ao quadrado, comumente utilizada. A norma ℓ_2 ao quadrado é descrita por $Q(\mathbf{x}) = \|\mathbf{x}\|_2^2 = \sum_i |x_i|^2$. Uma outra alternativa é a utilização da norma ℓ_1 , descrita por $Q(\mathbf{x}) = \|\mathbf{x}\|_1 = \sum_i |x_i|$. A norma ℓ_1 proporciona resultados similares aos da norma Huber com T pequeno.

O modelo de imagem, com a especificação de \mathbf{R}_k , de β_R e da norma $Q(\mathbf{x})$, descreve a informação adicional necessária para ser utilizada na busca da imagem de alta resolução.

3. Métodos Implementados

3.1. Super-Resolução de Única imagem

Estes algoritmos baseiam-se na utilização de uma única imagem LR para a produção de uma única imagem HR. Esta abordagem é capaz de ampliar a imagem e reduzir as distorções causadas pela aquisição, produzindo uma imagem com uma qualidade maior do que a produzida por simples interpolação, como em Thevenaz (2000).

A formulação geral desta abordagem é dada por:

$$\hat{\mathbf{f}}_k = \arg \min_{\mathbf{f}_k} \|\mathbf{g}_k - \mathbf{D}_k \mathbf{f}_k\|_2^2 + \lambda Q(\mathbf{R}_k \mathbf{f}_k) \quad (6)$$

onde, segundo Barrett (2004), λ é especificado como σ^2/β_R , sendo σ^2 a variância do ruído de aquisição e β_R a medida do modelo de imagem, definida na seção 2.4.

Este algoritmo é recomendado para situações onde apenas uma imagem LR está disponível e o objetivo é a produção de uma única imagem HR. Entretanto, ele também pode ser aplicado individualmente em situações onde uma seqüência de imagens está disponível. A utilização da norma ℓ_2 ao quadrado no termo de dados é justificada assumindo-se que o erro nos dados pode ser modelado como aditivo, branco e Gaussiano, conforme Barrett (2004) e Bovik (2000). Algoritmos desta classe são encontrados em Schultz (1994).

3.2. Super-Resolução Tradicional Robusta

Os algoritmos tradicionais de super-resolução, como em Chaudhuri (2001) e Park (2003), utilizam toda a seqüência de imagens LR para a produção de uma imagem de HR. Em geral, aproveitando a informação proveniente das várias imagens de uma seqüência LR se obtém uma recuperação de detalhes aprimorada em relação aos algoritmos que se baseiam em uma única imagem LR isoladamente.

Estes métodos utilizam as equações do modelo de aquisição e movimento combinados. Entretanto, devido à possível ocorrência de erros de movimento, é necessária a utilização de algoritmos robustos para evitar distorções nos resultados. Assim, em Farsiu (2004) foi proposto um algoritmo de super-resolução robusto à *outliers*.

A formulação do método tradicional robusto é dada por:

$$\hat{\mathbf{f}}_k = \arg \min_{\mathbf{f}_k} \sum_{j=1}^L \|\mathbf{g}_j - \mathbf{C}_{j,k} \mathbf{f}_k\|_1 + \lambda \|\mathbf{R}_k \mathbf{f}_k\|_1 \quad (7)$$

onde o primeiro termo da equação é composto de um somatório que relaciona a imagem HR estimada com outras L imagens LR capturadas.

Nestes algoritmos, o movimento é utilizado no modelo combinado. Para tal, o movimento entre as imagens deve ser previamente conhecido ou deve ser estimado utilizando um método de estimação de movimento, conforme Stiller (1999).

3.3. Super-Resolução Simultânea Robusta

Os algoritmos simultâneos estimam toda a seqüência de imagens HR conjuntamente, em um único processo. Estes métodos são interessantes para aplicações onde o produto final é uma seqüência de imagens e não apenas uma única imagem. Os métodos simultâneos são conhecidos pela grande qualidade obtida nos resultados. O primeiro trabalho sobre a abordagem simultânea foi proposto em Borman (1999). Posteriormente ele foi aperfeiçoado em Zibetti (2005), onde o custo computacional foi reduzido, e em Zibetti (2006), onde uma grande robustez e a característica de preservação de bordas foi alcançada.

Neste trabalho vamos implementar o método apresentado em Zibetti (2006), utilizando os modelos de movimento mais simples, de primeira ordem. A formulação é dada por:

$$\hat{\mathbf{f}}_1, \dots, \hat{\mathbf{f}}_L = \arg \min_{\mathbf{f}_k} \sum_{k=1}^L \|\mathbf{g}_k - \mathbf{D}_k \mathbf{f}_k\|_2^2 + \lambda_R \sum_{k=1}^L Q(\mathbf{R}_k \mathbf{f}_k) + \lambda_M \sum_{k=2}^L Q(\mathbf{f}_k - \mathbf{M}_{k,k-1} \mathbf{f}_{k-1}) \quad (8)$$

São utilizados os seguintes valores para os coeficientes de regularização: $\lambda_R = \sigma^2 / \beta_R$ e $\lambda_M = \sigma^2 / \beta_M$ sendo que β_M é uma medida do erro de movimento, $Q(\mathbf{f}_k - \mathbf{M}_{k,k-1} \mathbf{f}_{k-1}) / M$, assumida igual para todas as imagens para reduzir o número de coeficientes, conforme Barrett (2004).

4. Implementação

As formulações apresentadas nas equações (6), (7) e (8) podem ser minimizadas através de métodos baseados no gradiente. Neste trabalho consideramos as implementações baseadas no método de otimização de Gradiente Conjugado (GC) Não-Linear, encontrados em Vogel (2002) e Shewchuk (1994). O método do Gradiente Conjugado é significativamente mais rápido do que o método do Gradiente Descendente, o qual é utilizado na maioria dos trabalhos de super-resolução.

Para solução do método de super-resolução de única imagem, apresentado em (6), através do GC Não-Linear, é necessário utilizar o seguinte gradiente:

$$\frac{1}{2} \nabla J(\mathbf{f}_k) = \mathbf{D}_k^T (\mathbf{g}_k - \mathbf{D}_k \mathbf{f}_k) + \lambda_R \mathbf{R}_k^T \mathbf{W}_{(\mathbf{R}_k \mathbf{f}_k)} \mathbf{R}_k \mathbf{f}_k \quad (9)$$

onde $\mathbf{W}_{(x)}$ é uma matriz de ponderação, diagonal, de tamanho $P \times P$ neste caso, onde o elemento da posição i na diagonal, especificado como w_i , é:

$$w_i = 1/(|x_i| + \delta) \quad (10)$$

quando a norma ℓ_1 é utilizada, onde δ é um valor bem pequeno para evitar um possível denominador nulo e x_i é o elemento i do vetor \mathbf{x} , e:

$$w_i = \begin{cases} 1 & \text{se } |x_i| \leq T \\ T/|x_i| & \text{se } |x_i| > T \end{cases} \quad (11)$$

quando a norma Huber é utilizada. A matriz $\mathbf{W}_{(x)}$ é atualizada a cada iteração do método.

Para o método de super-resolução tradicional robusto, apresentado em (7), o gradiente é:

$$\frac{1}{2} \nabla J(\mathbf{f}_k) = \sum_{j=1}^L \mathbf{C}_{j,k}^T \mathbf{W}_{(\mathbf{g}_j - \mathbf{C}_{j,k} \mathbf{f}_k)} (\mathbf{g}_j - \mathbf{C}_{j,k} \mathbf{f}_k) + \lambda_R \mathbf{R}_k^T \mathbf{W}_{(\mathbf{R}_k \mathbf{f}_k)} \mathbf{R}_k \mathbf{f}_k \quad (12)$$

onde as matrizes de ponderação tem tamanhos diferentes.

Para o método de super-resolução simultânea robusta, apresentado em (8), o gradiente é:

$$\frac{1}{2} \nabla J(\mathbf{f}) = \mathbf{D}^T (\mathbf{g} - \mathbf{D}\mathbf{f}) + \lambda_R \mathbf{R}^T \mathbf{W}_{(\mathbf{R}\mathbf{f})} \mathbf{R}\mathbf{f} + \lambda_M \mathbf{M}\mathbf{W}_{(\mathbf{M}\mathbf{f})} \mathbf{M}\mathbf{f} \quad (13)$$

sendo os vetores são $\mathbf{g} = [\mathbf{g}_1^T \dots \mathbf{g}_L^T]^T$ e $\mathbf{f} = [\mathbf{f}_1^T \dots \mathbf{f}_L^T]^T$ e as matrizes são:

$$\mathbf{D} = \begin{bmatrix} \mathbf{D}_1 & \dots & \mathbf{0} \\ \vdots & \ddots & \vdots \\ \mathbf{0} & \dots & \mathbf{D}_L \end{bmatrix}, \quad \mathbf{R} = \begin{bmatrix} \mathbf{R}_1 & \dots & \mathbf{0} \\ \vdots & \ddots & \vdots \\ \mathbf{0} & \dots & \mathbf{R}_L \end{bmatrix} \quad \text{e} \quad \mathbf{M} = \begin{bmatrix} -\mathbf{M}_{2,1} & \mathbf{I} & \dots & \mathbf{0} \\ \vdots & \ddots & \ddots & \vdots \\ \mathbf{0} & \dots & -\mathbf{M}_{L,L-1} & \mathbf{I} \end{bmatrix} \quad (14)$$

Detalhes sobre a implementação do Gradiente Conjugado Não-Linear podem ser encontrados em Vogel (2002) ou Shewchuk (1994). Neste trabalho foi utilizado o armazenamento esparsa das matrizes, devido a grande quantidade de elementos nulos (zeros). Entretanto, existem implementações alternativas, como apresentado em Farsiu (2004).

5. Experimentos:

Neste trabalho vamos apresentar três aplicações para exemplificar a utilização dos métodos de super-resolução. São elas: aumento da resolução de uma imagem de satélite, que se trata de uma aplicação para super-resolução de única imagem; super-resolução de fotos aéreas, onde várias fotos aéreas são processadas para formar uma imagem final com maior resolução; e ampliação de seqüência de imagens de vigilância aeroespacial, onde é aplicada super-resolução simultânea em uma seqüência de imagens capturadas para formar uma outra seqüência de imagens com resolução superior.

5.1. Aplicações para Super-Resolução Única Imagem

Neste experimento vamos mostrar a utilização do método de super-resolução de única imagem, apresentado na Seção 3.1, em uma imagem de satélite. Nestas aplicações temos, geralmente, a captura de uma única imagem de determinada região. Possivelmente, quando o satélite passar novamente pela região as condições atmosféricas e de iluminação estarão muito diferentes, tornando difícil a utilização de mais imagens LR no processo de super-resolução.

Assumimos que a imagem recebeu distorção equivalente a uma filtragem gaussiana, seguida de subamostragem de duas vezes (um pixel, na imagem LR, é formado a partir da média de um bloco de 2x2 pixels da imagem HR), mais a adição de um ruído gaussiano. Estas são as distorções assumidas para o modelo de aquisição, definido na Seção 2.1.

Para comparar a qualidade obtida pelo método de SR, vamos mostrar o resultado obtido através da combinação de interpolação seguindo de restauração. Estes resultados são mostrados na Figura 1.




Imagem Capturada

Interpolação + Restauração

Super-resolução

Figura 1: Ampliação de imagem de satélite, imagem da banda 2 do CBERS-II.

5.2. Aplicações para Super-Resolução Tradicional

Neste experimento vamos mostrar a utilização do método de super-resolução tradicional robusto, apresentado na Seção 3.2, onde um conjunto de imagens capturadas é utilizado para formar uma imagem com resolução superior. Vamos utilizar este método para melhorar a resolução de fotos aéreas. Neste tipo de aplicação, em geral, é possível fazer a aquisição de diversas fotos de uma mesma região, para posteriormente juntá-las em uma imagem com mais resolução.

Assumimos que as imagens capturadas receberam distorção equivalente a uma filtragem gaussiana, seguida de subamostragem de três vezes, mais a adição de um ruído gaussiano. Os resultados deste experimento são mostrados na Figura 2.



Figura 2: Super-resolução de 3 vezes em fotos aéreas.

5.3. Aplicações para Super-Resolução Simultânea

Neste experimento utilizaremos o método de super-resolução simultânea robusta, apresentada na Seção 3.3, em uma seqüência de imagens usada para vigilância aeroespacial. Neste tipo de aplicação a seqüência de imagens traz informações importantes, pois mostra como determinado objeto está se movimentando, isto ajuda na sua identificação.

Assumimos que as imagens da seqüência receberam distorção equivalente a uma subamostragem de quatro vezes, mais a adição de um ruído gaussiano. Neste caso a super-resolução é aplicada em toda a seqüência. Alguns resultados deste experimento são mostrados na Figura 3.

6. Conclusões

Neste trabalho mostramos a utilização de alguns dos métodos de super-resolução em aplicações de sensoriamento remoto. Foram apresentados o método de super-resolução de única imagem, o método tradicional robusto e o método simultâneo robusto. Estes métodos

foram utilizados em aplicações como aumento da resolução de imagem de satélite, super-resolução de fotos aéreas e ampliação de seqüência de imagens de vigilância aeroespacial, respectivamente. Os resultados visuais demonstram o potencial da aplicação dos métodos de super-resolução de imagem em sensoriamento remoto.



Figura 3: Super-resolução de 4 vezes em uma seqüência de vigilância aeroespacial.

Referências

- Gonzalez, R. C. e Woods, R. E. **Digital Image Processing**. Addison-Wesley, 1992.
- Fonseca, L.M.G.; Prasad, G. S. S. D e Mascarenhas, N. D. A. Combined Interpolation-Restoration of Landsat Images Through a FIR Filter Design Techniques, **International Journal of Remote Sensing**, v. 14, n. 13, p. 1247-2561, 1993.
- Bovik, A. **Handbook of Image and Video Processing**. Academic Press, 2000.
- Chaudhuri, S. **Super-Resolution Imaging**. Kluwer, 2001.
- Park, S. C., Park, M. K., Kang, M. G. Super-resolution image reconstruction: a technical overview, **IEEE Signal Processing Magazine**, v. 20, n. 3, p. 21-36, 2003.
- Schultz, R. R., Stevenson, R. L. G. A Bayesian Approach to Image Expansion for Improved Definition, **IEEE Transactions on Image Processing**, v. 3, n. 3, p. 233-242, 1994.
- Farsiu, S., Robinson, D. Elad, M. Milanfar, P. Fast and robust multi-frame super-resolution, **IEEE Transactions on Image Processing**, v. 13, n. 10, p. 1327-1344, 2004.
- Huber, P. J. **Robust Statistics**. John Wiley & Sons, 1981.
- Zibetti, M. V. W. e Mayer, J. Outlier robust and edge-preserving simultaneous super-resolution. In: IEEE International Conference on Image Processing (ICIP'06), 10, 2006, Atlanta. **Anais** v.1 p. 1741-1744.
- Barrett, H H. Myers, K. J. **Foundations of Image Science**. John Wiley & Sons, 2004.
- Stiller, C., Konrad, J. Estimating motion in image sequences, **IEEE Signal Processing Magazine**, v. 16, n. 4, p. 70-91, 1999.
- Hasler, D., Sbaiz, L., Süssstrunk, S. e Vetterli, M. Outlier modeling in image matching, **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 25, n. 3, p. 301-315, 2003.
- Vogel, C. R. **Computational Methods for Inverse Problems**. SIAM, 2002.
- Thévenaz, P., Blu, T. Unser, M. Interpolation Revisited, **IEEE Transactions on Medical Imaging**, v. 19, n. 7, p. 739-758, 2000.
- Borman, S. e Stevenson, R. L. Simultaneous multi-frame MAP super-resolution video enhancement using spatio-temporal priors. In: IEEE International Conference on Image Processing (ICIP'99), 1999. **Anais** v.3 p. 469-473.
- Zibetti, M. V. W. e Mayer, J. Simultaneous super-resolution for video sequences. In: IEEE International Conference on Image Processing (ICIP'05), 9, 2005, Genova. **Anais** v.1 p. 877-880.
- Shewchuk, J. R. **An Introduction to Conjugate Gradient Method Without the Agoning Pain**. Carnegie Mellon University, 1994.