

Otimização do algoritmo Non Local Means utilizando método de segmentação K-means

Douglas Andrade de Meneses¹

Leonardo Vidal Batista²

Resumo - O algoritmo Non Local Means é amplamente utilizado para filtragem e remoção de ruído de imagens. No entanto, sua alta complexidade computacional torna-se um obstáculo para aplicações que exigem resultados em tempo real. Em vista disso, este trabalho propõe uma otimização para esse algoritmo utilizando o método de agrupamento K-means para agrupar pixels com valores de nível de cinza semelhantes e, assim, aplicar o Non Local Means para cada agrupamento gerado, contendo os pixels mais semelhantes entre si. Os resultados experimentais encontrados testemunham uma melhoria no tempo de processamento e no Erro Médio Quadrático (para alguns casos), e que as imagens processadas são semelhantes às aquelas filtradas pelo algoritmo original.

Palavras-chave - Non Local Means; Filtragem de imagens; K-means; Ruído.

Abstract - Non Local Means algorithm is widely utilized for filtering and image denoising. Nevertheless, its high computational complexity becomes an obstacle to applications requiring fast results. Therefore, this paper proposes an optimization to this algorithm using K-means clustering to group similar pixels with resembling gray levels, thereby applying the Non Local Means algorithm in each created cluster, containing the most similar pixels each other. Experimental results testify an improvement in computational time and Mean Square Error (in some instances), and the processed images are similar to those filtered by the original algorithm.

Key-words - Non Local Means; Image filtering; K-means; Noise.

¹Estudante de Mestrado pelo Programa de Pós-graduação em Informática –PPGI da Universidade Federal da Paraíba – UFPB.

² Doutor em Engenharia Elétrica pela Universidade Federal da Paraíba – UFPB, professor do Centro de Informática da Universidade Federal da Paraíba – UFPB.

1. Introdução

Apesar do crescente avanço tecnológico nos processos de digitalização de imagens, o ruído continua sendo um fator relevante. Devido a diversos fatores, como interferência na transmissão do sinal ou alta sensibilidade de sensores, o ruído estabeleceu-se como algo inerente ao produto dos aparelhos digitais, de modo que a solução mais tangível tem sido encontrada no processamento pós-captura de imagens.

Muitos foram os métodos desenvolvidos dentro da grande área de Processamento Digital de Imagens na tentativa de reduzir ruído e, assim, obter imagens filtradas mais adequadas para outras aplicações como compressão de dados, reconhecimento de padrões, análise de imagens médicas, entre outras. Esses métodos buscam preservar ao máximo as bordas e outras características essenciais da imagem enquanto reduzem as degradações existentes (JAIN; TYAGI, 2014).

Durante muito tempo, as abordagens criadas para implementar esses métodos envolviam procedimentos locais, isto é: para filtrar um determinado pixel da imagem, utilizava-se a informação da sua vizinhança - os pixels vizinhos a ele. Porém, limitar-se às vizinhanças não permite que se explore uma característica recorrente: a redundância de informação que existe ao longo de toda a imagem.

Compreendendo que existem padrões que se repetem por toda imagem, em Buades *et. al.* (2004) notou-se a necessidade de criar um método não-local que filtrasse cada pixel da imagem utilizando a informação contida nos demais, atribuindo pesos de acordo com o grau de semelhança entre eles. Desse modo, propôs-se o algoritmo Non Local Means (NLM), que foi o precursor de outros algoritmos não-locais (SALMON; STROZECKI, 2010). Para uma imagem ruidosa $v = \{v(i) \mid i \in I\}$, a equação que define o funcionamento do algoritmo sobre um *pixel* i pode ser descrita como

$$NL(v)(i) = \sum_{j \in I} w(i, j)v(j) \quad (1)$$

onde $NL(v)(i)$ é o valor a ser encontrado da filtragem do pixel i ; $w(i, j)$ é o peso do pixel j em relação a i ; e $v(j)$ o valor de j . Faz-se, portanto, uma média ponderada de todos os pixels da imagem com relação ao pixel alvo para obter-se o valor final de sua filtragem.

Embora apresente resultados considerados muito bons, tanto visualmente quanto matematicamente, em comparação com os métodos tradicionais de redução de ruído, o NLM

possui uma complexidade computacional bastante elevada, uma vez que precisa analisar todos os pixels da imagem para a filtragem de cada pixel individualmente. Por essa razão, torna-se inapropriado para aplicações atuais que necessitam produzir resultados em tempo reduzido, ou em tempo real.

Sabendo disso, Buades *et. al* (2005) sugerem uma adaptação ao método, limitando a filtragem a uma janela de busca, na tentativa de reduzir a complexidade do algoritmo original. Muitos aprimoramentos para tal adaptação foram desenvolvidos e publicados, como pode-se encontrar em Zhang *et. al.* (2012), Bhujle e Chaudhuri (2012), Wu *et. al.* (2013), Tombari e Di Stefano (2015), Yang *et. al.* (2013), entre tantos outros.

Na literatura atual a imensa maioria de trabalhos encontrados são estudos e melhoramentos para a adaptação do NLM com a janela de busca e não para o algoritmo original. Além disso, o uso de uma janela de busca torna o algoritmo mais próximo de um método local do que não-local, reduzindo a capacidade de explorar redundância de informação e padrões nas imagens.

Em virtude disso, uma proposta de otimização para o NLM original é apresentada neste trabalho, tendo em vista a declinação da sua complexidade computacional e, conseqüentemente, do tempo de processamento, possibilitando a utilização do algoritmo para os diversos fins atuais.

2. Material e métodos

Como inspiração para a metodologia aqui adotada, os trabalhos utilizando o algoritmo K-Means para agrupar pixels com nível de cinza semelhante (PETER; RAMYA, 2012) e a otimização do NLM utilizando uma abordagem baseada em agrupamentos (DANG *et. al.*, 2013), permitiram a abstração de conceitos importantes e a geração de ideias que originaram o método aqui proposto.

A Figura 1 expressa um diagrama simples que resume o funcionamento do método desenvolvido. Primeiramente, recebe-se uma imagem em escala de cinza com ruído gaussiano branco. Em seguida, realiza-se um agrupamento, em K clusters, de acordo com os valores de nível de cinza da vizinhança de cada pixel. Obtendo-se tais grupos de pixels com vizinhanças semelhantes, executa-se o NLM para cada um dos K (valor escolhido na entrada do sistema)

clusters. Por fim, os novos valores de cada pixel são obtidos e uma nova imagem filtrada é gerada como saída.

O processo apresentado pode ser subdividido em duas etapas principais: agrupamento e aplicação do NLM. Sendo assim, nas seções seguintes cada uma dessas etapas será descrita e esclarecida quanto aos seus detalhes.

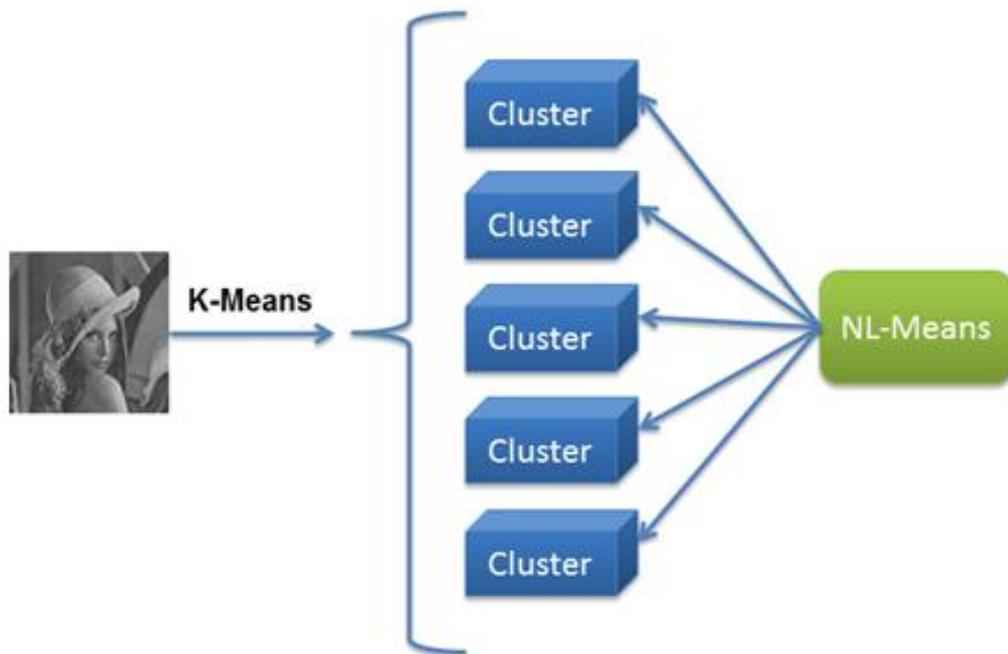


Fig. 1. Diagrama do funcionamento do método desenvolvido.

2.1 Agrupando os pixels semelhantes em clusters

Recebendo a imagem ruidosa como entrada, obtém-se o seu tamanho e a quantidade total de pixels como primeiro passo. Em seguida, o algoritmo K-Means inicia o processo de agrupamento, analisando cada pixel através do seu valor de nível de cinza.

Inicialmente escolhe-se de forma aleatória K centroides e computa-se as distâncias, que são medidas pelo grau de semelhança dos coeficientes do centroide com relação aos coeficientes dos demais pixels.

Formam-se os primeiros clusters e, logo em seguida, através da média de todos os elementos de cada agrupamento, recalcula-se o valor dos centroides e obtém-se os novos. Repete-se o processo n vezes até alcançar-se o equilíbrio. Têm-se então os K clusters contendo os pixels mais semelhantes entre si, de acordo com o nível de cinza. Um breve resumo do procedimento encontra-se na Figura 2.

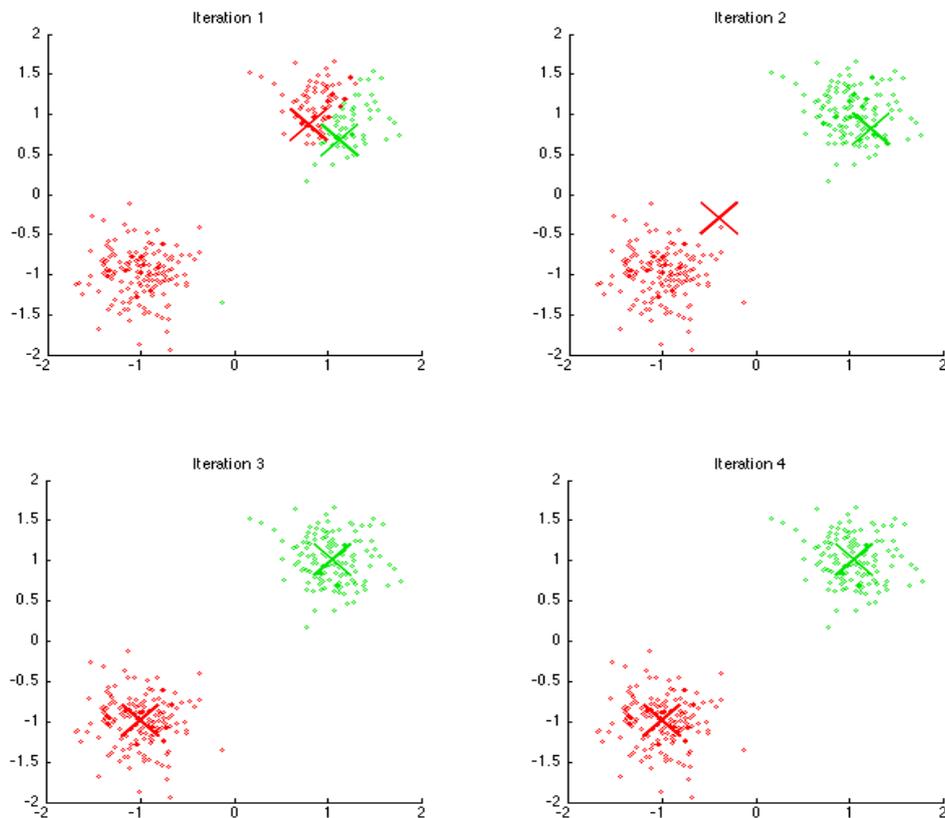


Fig. 2. Iterações do algoritmo K-means com $K=2$.

2.2. Filtragem através do NLM

Possuindo os K clusters contendo os pixels mais semelhantes, o próximo passo então é a filtragem para remoção do ruído, como pode-se observar na Figura 1.

Aqui o algoritmo analisa cada pixel da imagem, identificando o cluster que ele faz parte e utilizando as vizinhanças participantes para calcular os pesos - que são todos relevantes, uma vez que há semelhança entre todos os elementos do agrupamento. Em seguida, realiza-se a

filtragem do pixel, visando eliminar o ruído indesejado, e armazena-se o seu novo valor para transferir à imagem resultante que será gerada.

3. Resultado e discussões

Nesta seção serão descritos os procedimentos realizados e os detalhes dos experimentos, bem como a análise dos resultados obtidos.

3.1 Quantidade de clusters ideal

O primeiro passo para a obtenção dos resultados comparativos entre o método proposto e o algoritmo original é a obtenção da quantidade ideal de clusters para os experimentos.

Para a realização dos testes, adicionou-se ruído gaussiano branco a uma imagem monocromática em nível de cinza de 512 x 512 pixels, variando o nível de ruído entre 0,001 e 0,1, e alternou-se a quantidade de clusters entre 50, 100, 150 e 200. Para cada instância foi calculado o valor do *Mean Square Error* (MSE) obtendo-se a Tabela 1.

RUÍDO	K=50	K=100	K=150	K=200
0,001	97,8	95,2	93,4	92,8
0,002	105,8	102,7	101,1	100,1
0,003	115,2	111,9	110,1	109,1
0,004	125,9	122,4	120,4	119,6
0,005	138,7	135	133,5	132,3
0,006	152,2	148,6	146,4	145,5
0,007	168,1	164,1	162	161,1
0,008	184,8	181	178,4	177,3
0,009	204,6	200,3	198	197
0,01	225,5	220,9	219	218,1

Tabela 1. Valores do MSE para diferentes níveis de ruído e clusters

O MSE é um método matemático sugerido por Buades *et. al.* (2005) como um dos mais eficazes meio de avaliação de filtragem de imagens, que consiste em encontrar a diferença Euclidiana entre a imagem restaurada e a original. Isso se dá através do cálculo *pixel a pixel*

em um somatório, dividido pelo número de *pixels* da imagem. O valor do MSE de uma imagem filtrada demonstra o grau de semelhança que ela possui em relação à original de modo que, quanto menor for esse valor, mais restaurada está a imagem - ou menos ruidosa.

Percebe-se claramente que 200 clusters seria a quantidade ideal para a filtragem nas mais diversas intensidades de ruído gaussiano branco, uma vez que o aumento da quantidade de clusters resulta numa queda do valor do MSE.

3.2. Comparação com o algoritmo original

A última etapa, então, consistiu em comparar o algoritmo desenvolvido com o NLM original. Tal comparação foi realizada como segue: obteve-se os valores do MSE para diversas variâncias com o NLM original e com o método proposto neste trabalho, utilizando 200 clusters, e colocou-se os resultados comparativos na Figura 3. A cor azul representa o NLM original e a vermelha o algoritmo proposto.

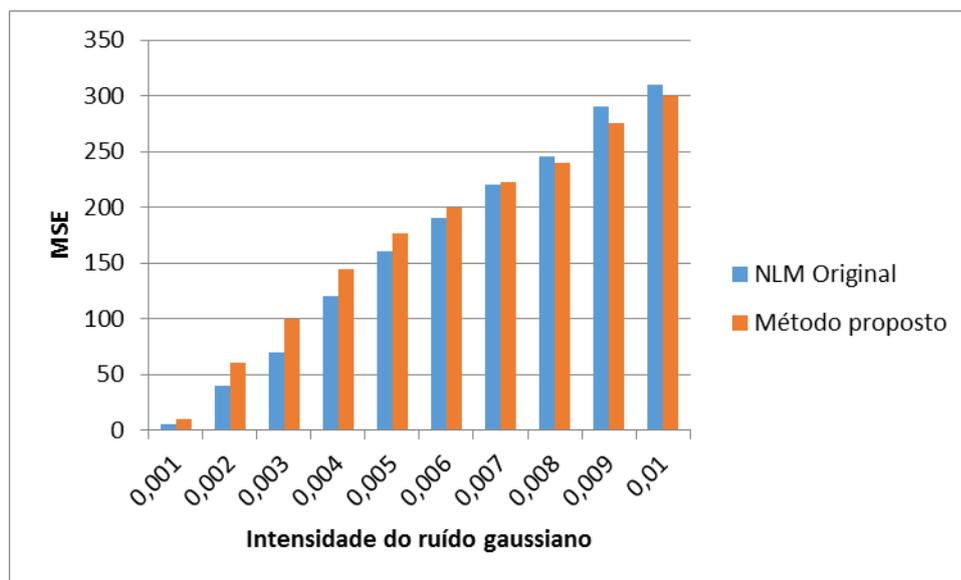


Fig. 3. Gráfico comparativo dos valores do MSE obtidos entre o NLM Original e o algoritmo proposto.

Após a análise, pode-se concluir que para variâncias de ruído mais baixa, isto é, entre 0.001 e 0.004, o NLM original apresenta MSE menor de forma mais discrepante. Entre 0.005

e 0.007, a diferença vai sendo reduzida até que, a partir de 0.008 o método proposto passa a apresentar valores do MSE sempre menores do que o algoritmo original. Portanto, apenas para imagens bastante ruidosas é possível encontrar uma melhoria em termos de valores matemáticos.

Com relação ao tempo de processamento, a Tabela 2 expressa os resultados obtidos em minutos para cada nível ruído. Pode-se observar que há uma redução considerável de, em média, 9 vezes.

RUÍDO	NLM ORIGINAL	MÉTODO PROPOSTO
0,001	173,1	18,2
0,002	135,2	14,8
0,003	17,7	18,6
0,004	201,1	21,4
0,005	136	14,5
0,006	140,8	15,3
0,007	167,3	17,6
0,008	177,6	18,9
0,009	135,9	14,7
0,01	156,8	16,7

Tabela 2. Comparação dos tempos de processamento (em minutos) do NLM original e do algoritmo proposto.

Analisados o MSE e o tempo de execução, o último passo então é a análise visual subjetiva acerca do resultado da filtragem. Isto se dá devido aos resultados matemáticos nem sempre considerarem o valor estético e a harmonia da figura obtida após o processamento.

A Figura 4 expõe a imagem ruidosa, o resultado da filtragem do NLM original (no meio) e do método proposto (por último). É possível encontrar algumas pequenas diferenças (uma mais suavizada do que a outra, perda de textura, entre outras) mas, de forma geral, o resultado visual de ambos algoritmos é bem semelhante.



Fig. 4. Resultado visual da filtragem da imagem Lena. Acima, a imagem ruidosa; no meio, o resultado do NLM original; por último, o resultado do método proposto.

4. Considerações finais

Neste trabalho, uma otimização para o algoritmo de remoção de ruído Non Local Means foi apresentado. Por estar no estado da arte na área de Processamento Digital de Imagens, esse algoritmo tem sido estudado por muitos pesquisadores e diversas propostas de otimização tem sido desenvolvidas e apresentadas na literatura. Porém, tais propostas visam aprimorar uma adaptação do algoritmo utilizando uma janela de busca, que possui complexidade computacional bem menor, e não o algoritmo original que é puramente não-local.

Por tal motivo, este trabalho propôs uma otimização utilizando agrupamento com K-Means para reduzir a complexidade do algoritmo e, conseqüentemente, seu tempo de processamento.

O método consiste em agrupar os pixels através do K-Means, de acordo com a semelhança dos níveis de cinza de suas vizinhanças. Após isso, direciona-se a ação do NLM para cada cluster, obtendo-se os valores dos novos pixels para gerar a imagem filtrada.

Os resultados obtidos testificam uma redução no tempo de execução de cerca de 9 vezes, obtendo valores do MSE mais baixos para a imagens mais ruidosas, com variância de ruído Gaussiano acima de 0.007; bem como resultados visuais semelhantes aos encontrados com a filtragem através do NLM original.

5. Agradecimentos

Agradecimento à CAPES pela concessão da bolsa de estudos que permitiu o desenvolvimento desse trabalho.

6. Referências

- BUADES A., COLL B. e MOREL J. **On image denoising methods**. Technical Note v. 5, CMLA, p.40, 2004
- BUADES A., COLL B. e MOREL J. **A Non-Local Algorithm for Image Denoising**. Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Vol.2, pp.60-65, 2005.
- BHUJLE H. e CHAUDHURI S. **Accelerating non-local denoising with a patch based dictionary**. Proceedings of the Eighth Indian Conference on Computer Vision, Graphics and Image Processing, 2012
- DANG S., ZHANG Y. e GONG D. **A patch-based Non-local Means Method for Image Denoising**. Intelligent Science and Intelligent Data Engineering, 2013.
- JAIN P. e TYAGI V. **A survey of edge-preserving image denoising methods**. Information Systems Frontiers, 1-12, 2014.
- PETER J. e RAMYA R. **A novel adaptive Non Local Means for image de-noising**. Procedia Engineering, v. 38, p. 3278-3282, 2012.

- SALMON J. e STROZECKI Y. **From patches to pixels in Non-Local methods: Weighted-average reprojection.** Image Processing (ICIP), 2010 17th IEEE International Conference on , vol., no., pp.1929,1932, 2010
- TOMBARI F. e DI STEFANO L. **Bounded Non-Local Means for Fast and Effective Image Denoising.** Image Analysis and Processing — ICIAP 2015: 18th International Conference, Genoa, Italy, September 7-11, 2015, Proceedings, Part II, Italy, September 7-11, 2015.
- YANG M., LIANG J., ZHANG J., GAO H., MENG F., XINGDONG L. e SONG S. **Non-local means theory based Perona–Malik model for image denosing.** Neurocomputing, Volume 120, November 2013.
- ZHANG K., GAO X., TAO D. e LI X. **Single Image Super-Resolution With Non-Local Means and Steering Kernel Regression.** IEEE Transactions on Image Processing, vol. 21, no. 11, pp. 4544-4556, Nov. 2012.
- WU Y., TRACEY B., NATARAJAN P. e NOONAN J. P. **James–Stein Type Center Pixel Weights for Non-Local Means Image Denoising,** *IEEE Signal Processing Letters*, vol. 20, no. 4, pp. 411-414, April 2013.