

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
DEPARTAMENTO DE COMPUTAÇÃO

**FILTRAGEM NÃO LOCAL DE RUÍDOS EM IMAGENS
DE TOMOGRAFIA COMPUTADORIZADA**

Ricardo Araújo da Silva

São Carlos

2025

Ricardo Araújo da Silva

FILTRAGEM NÃO LOCAL DE RUÍDOS EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADA

Trabalho de conclusão de curso apresentado como requisito parcial para a obtenção do título de bacharel em engenharia de computação pela Universidade Federal de São Carlos.

Orientador: Prof. Dr. Alexandre Luís Magalhães Levada

São Carlos

2025

Agradecimentos

A Deus, pela vida, oportunidades, força e sabedoria.

Aos meus familiares, pelo apoio constante e incentivo durante todos esses anos.

A todos os professores que contribuíram para minha formação acadêmica, fornecendo o melhor conhecimento e oportunidades. Um agradecimento especial aos professores Mário Felice e Pedro Hokama pelo apoio na minha carreira científica, e ao professor Alexandre Levada, cuja excelente orientação foi essencial para a realização deste trabalho.

À Universidade Federal de São Carlos e ao Departamento de Computação, pelos recursos, ensinamentos e pela oportunidade de crescimento acadêmico e profissional.

A todos os meus amigos que direta ou indiretamente estiveram comigo nessa jornada.

*“Se você quiser fazer uma torta de maçã a partir do zero,
você deve primeiro inventar o Universo.”
(Carl Sagan)*

Resumo

A tomografia computadorizada (TC) é amplamente utilizada em diagnósticos médicos devido à sua capacidade de gerar imagens tridimensionais de alta precisão. No entanto, a presença de ruídos Poisson e Gaussiano pode degradar significativamente a qualidade dessas imagens, dificultando diagnósticos precisos. Neste trabalho é investigado o desempenho de filtros não-locais, em particular o *Non-Local Means* e o *Block-Matching and 3D Filtering*, na redução de ruídos em imagens de TC. Para isso, foi implementada uma metodologia que aplica esses filtros em imagens com diferentes níveis de ruído, avaliando os resultados através das métricas PSNR e SSIM. Além disso, explorou-se o impacto da Transformada de Anscombe na linearização do ruído Poisson, potencializando a eficácia dos algoritmos. Os resultados demonstram que o BM3D, em conjunto com a Transformada de Anscombe, apresentou o melhor desempenho na maioria dos cenários, destacando-se como uma ferramenta promissora para aplicações em imagens médicas.

Palavras-chave: tomografia computadorizada, filtros não-locais, Transformada de Anscombe.

Abstract

Computed tomography (CT) is widely used in medical diagnostics due to its ability to generate high-precision three-dimensional images. However, the presence of Poisson and Gaussian noise can significantly degrade the quality of these images, making accurate diagnoses more challenging. This study investigates the performance of non-local filters, particularly Non-Local Means and Block-Matching and 3D Filtering, in reducing noise in CT images. To achieve this, a methodology was implemented that applies these filters to images with varying noise levels, evaluating the results using the PSNR and SSIM metrics. Additionally, the impact of the Anscombe Transform on the linearization of Poisson noise was explored, enhancing the algorithms' effectiveness. The results demonstrate that BM3D, combined with the Anscombe Transform, delivered the best performance in most scenarios, emerging as a promising tool for medical imaging applications.

Keywords: computed tomography, non-local filters, Anscombe Transform.

Lista de ilustrações

Figura 1 – Estrutura simplificada de um tomógrafo.	13
Figura 2 – Projeção de um corpo $f(x, y)$ em um ângulo θ	15
Figura 3 – Projeções diretas de uma imagem em diferentes ângulos. Em (a), $\theta = 0^\circ$, e em (b), $\theta = 90^\circ$	15
Figura 4 – Retroprojeções de uma imagem em diferentes ângulos. Em (a), $\theta = 0^\circ$, e em (b), $\theta = 90^\circ$	16
Figura 5 – Busca por <i>patches</i> semelhantes no algoritmo Non-Local Means. Em (a), a busca ocorre em toda a imagem; em (b), é restrita a uma região delimitada.	21
Figura 6 – Diagrama de blocos das etapas do algoritmo BM3D.	23
Figura 7 – Resultados visuais da filtragem para a imagem ct3.	29

Lista de tabelas

Tabela 1 – Valores do PSNR, em decibéis, e do SSIM da imagem ruidosa para diferentes imagens e tipos de ruído.	27
Tabela 2 – Ganho percentual do valor do PSNR da imagem filtrada em relação ao PSNR da imagem ruidosa para diferentes imagens e tipos de ruído. Cada nível de ruído apresenta o resultado sem aplicação da TA na coluna da esquerda e o resultado usando TA na coluna da direita (em negrito).	27
Tabela 3 – Ganho percentual do valor do SSIM da imagem filtrada em relação ao SSIM da imagem ruidosa para diferentes imagens e tipos de ruído. Cada nível de ruído apresenta o resultado sem aplicação da TA na coluna da esquerda e o resultado usando TA na coluna da direita (em negrito).	28
Tabela 4 – Tempo de execução (em segundos) dos algoritmos NLM e BM3D para diferentes imagens. A coluna à esquerda apresenta o tempo sem TA, enquanto a coluna à direita (em negrito) apresenta o tempo com a aplicação da TA.	28

Sumário

1	INTRODUÇÃO	9
1.1	Trabalhos relacionados	9
1.2	Objetivos e justificativa	10
2	IMAGEM DE TOMOGRAFIA COMPUTADORIZADA	12
2.1	Tomógrafo	12
2.2	Formação da imagem de TC	12
2.3	Retroprojeção	14
2.4	Transformada de Anscombe	16
3	FILTROS NÃO LOCAIS	19
3.1	Filtro Non-Local Means	19
3.1.1	Complexidade computacional	21
3.2	Filtro Block-Matching and 3D Filtering	21
3.2.1	Estágio 1: Estimativa base	22
3.2.2	Estágio 2: Filtragem refinada com Wiener	22
3.2.3	Complexidade computacional	23
4	ESTUDO COMPUTACIONAL	25
4.1	Metodologia	25
4.2	Resultados	26
5	CONCLUSÃO	30
	REFERÊNCIAS	31

1 Introdução

A tomografia computadorizada (TC) é uma ferramenta de destaque utilizada no diagnóstico e no monitoramento de diversas condições de saúde, como doenças cardiovasculares, doenças pulmonares, presença de tumores e infecções. Além disso, ela é aplicada em diversas outras áreas, como a agronomia (HELLIWELL et al., 2013), ciência dos materiais (WEVERE et al., 2018) e geotecnia (BRAZ, 1997).

Uma imagem de TC é construída a partir de múltiplas medições da intensidade dos raios- X que atravessam o corpo do paciente em diferentes ângulos. Neste processo, a qualidade da imagem é frequentemente comprometida por ruídos, que estão associados a fatores como limitações físicas, movimentação do paciente, quantidade de dose de radiação utilizada, entre outros. Esses ruídos não apenas deterioram a qualidade visual das imagens, mas também influenciam a qualidade do diagnóstico. Por essas razões, a aplicação de técnicas de pós-processamento para a redução de ruídos na imagem de TC torna-se essencial, uma vez que melhora significativamente a qualidade das imagens permitindo a preservação dos detalhes clínicos, o que é fundamental para um diagnóstico mais preciso e eficaz.

Dentre as diversas técnicas de pós-processamento para redução de ruído, a utilização de filtros não-local tem apresentado resultados promissores. Entre eles, destacam-se o filtro *Non-Local Means* (NLM), apresentado por (BUADES; COLL; MOREL, 2005), que utiliza não apenas os vizinhos mais próximos, mas também regiões semelhantes da imagem para realizar a filtragem, e o filtro *Block-Matching and 3D Filtering* (BM3D), apresentado por (DABOV et al., 2006), que utiliza grupos de regiões similares na imagem para uma filtragem colaborativa.

1.1 Trabalhos relacionados

Desde que a TC foi introduzida, diversos pesquisadores têm extensivamente estudado e projetado técnicas de remoção de ruído em imagens tomográficas. Trabalhos recentes apresentam técnicas baseadas em filtragem não local de ruídos, transformada de Wavelet, redes neurais e aprendizado profundo, entre outros. A seguir, apresentam-se alguns dos trabalhos recentes mais relevantes que exploram essas abordagens.

No trabalho de (JEROME et al., 2019) explorara-se a melhoria da qualidade de imagens 3D de TC em tempo real por meio de um filtro de média espacialmente variante. O método combina o uso de limiares de Otsu e filtragem de média estendida para fornecer uma renderização visual 3D automática e de alta qualidade de dados de TC. A técnica

demonstrou ser eficiente em preservar estruturas importantes ao mesmo tempo que melhora a percepção visual das imagens.

Em (WANG et al., 2022), é apresentada uma nova medida de similaridade baseada na decomposição em valores singulares (SVD) aplicada ao método de médias não-locais (NLM). Essa abordagem busca aumentar a precisão na identificação de regiões similares em imagens tomográficas, o que resulta em uma redução de ruído mais eficaz e preservação de detalhes estruturais. Os resultados apresentam desempenho superior a algoritmos de última geração.

O trabalho de (JUNEJA et al., 2022) introduziu uma rede de autocodificadores chamada BMAuto-Net, baseada em filtros de mediana bilateral, com camadas de normalização de lote e fatores de abandono. O objetivo principal foi remover ruído gaussiano de imagens de TC. Os resultados demonstraram que a arquitetura proposta pode reduzir ruídos enquanto mantém a integridade estrutural das imagens.

No campo das redes assistidas por transformadas wavelet, (KIM et al., 2022) propuseram uma rede que utiliza a transformada wavelet estacionária para processar frequências de alta e baixa intensidade em imagens de TC. A rede foi treinada com funções de perda específicas para cada domínio de frequência, permitindo a obtenção de imagens com alta qualidade objetiva e perceptual. Testes em imagens clínicas e artificiais mostraram resultados superiores em relação a algoritmos de última geração.

Por fim, (LEPCHA et al., 2023) apresentaram um algoritmo inovador para redução de ruído em imagens de TC de baixa dose (LDCT). A técnica baseia-se em um método de médias não-locais construtivo combinado com processamento residual morfológico. Essa abordagem preserva bordas e características estruturais, ao mesmo tempo que reduz ruídos e artefatos. Além disso, a técnica foi projetada para ser altamente eficiente em termos computacionais, permitindo implementação em plataformas paralelas. Os resultados experimentais demonstraram melhorias qualitativas e quantitativas em comparação a outros métodos.

1.2 Objetivos e justificativa

A proposta deste trabalho de pesquisa é investigar e comparar a qualidade dos filtros NLM e BM3D na redução de ruídos em imagens de TC. Em resumo, ao final do projeto, a expectativa é validar ou refutar a hipótese de que os filtros NLM e BM3D possuem desempenho equiparável na filtragem de ruídos em imagens de TC.

Os objetivos específicos concentram-se em:

1. Compreender e apresentar conceitos básicos sobre a formação de imagens de TC e a degradação que surge durante esse processo.

2. Analisar o funcionamento dos filtros Non-Local Means e BM3D.
3. Comparar a efetividade dos filtros não locais na redução de ruído em imagens de TC.

2 Imagem de Tomografia Computadorizada

A Tomografia Computadorizada, introduzida por (HOUNSFIELD, 2014), é um método de diagnóstico por imagem que permite reproduzir seções internas de um objeto com alta fidelidade. Desenvolvida inicialmente na década de 1970, esta técnica revolucionou a medicina ao possibilitar a obtenção de imagens transversais do corpo humano de maneira não invasiva, utilizando feixes de raios-X e reconstrução computacional. Hounsfield foi premiado com o Nobel em 1979 por sua contribuição, destacando o impacto dessa inovação.

Neste capítulo, são apresentados os princípios fundamentais da formação de imagens de TC, abordando os aspectos físicos do sistema, os métodos de aquisição, reconstrução, e as principais características dessa técnica.

2.1 Tomógrafo

O tomógrafo é o equipamento responsável pela aquisição de imagens de TC, permitindo a captura de cortes axiais do corpo humano. Ele é composto essencialmente por duas partes principais: o gantry, que abriga o tubo de raios-x e os detectores, e a mesa do paciente, que possibilita o posicionamento adequado durante o exame (GOLDMAN, 2007).

No gantry, o tubo de raios-x emite feixes que atravessam o corpo do paciente. À medida que os feixes interagem com diferentes tipos de tecidos, eles são absorvidos em intensidades variadas: tecidos densos, como ossos, absorvem maior quantidade de radiação, enquanto tecidos moles, como músculos e órgãos, absorvem menos. Do lado oposto à fonte de raios-x, os detectores captam a radiação remanescente e convertem as informações em sinais elétricos, que serão processados pelo computador para gerar a imagem final.

Durante a aquisição, o gantry movimenta-se em círculo ou semi-círculo ao redor do paciente, coletando dados de múltiplos ângulos. Essa configuração permite a reconstrução tridimensional das estruturas internas (JUNG, 2021).

A Figura 1 ilustra a estrutura básica de um tomógrafo.

2.2 Formação da imagem de TC

Uma imagem pode ser definida como uma grade finita de pixels. Na TC a cor (ou intensidade) de um pixel é determinado pela quantidade de radiação que atravessou o paciente, onde regiões mais densas deixam passar pouca radiação, resultando em pixels com valores mais baixos, e regiões menos densas permitem muita passagem de radiação,




Figura 1 – Estrutura simplificada de um tomógrafo.

Fonte: Elaborado pelo autor.

fazendo com que muito sinal seja captado pelos receptores, resultando em um pixel mais intenso.

Um escâner de TC realiza duas medições: I_0 , na fonte de radiação, e a intensidade de cada feixe, I_1 , no detector. As mudanças na intensidade de um único feixe dependem da densidade interna do objeto ao longo da linha que o raio- X atravessa. Pode-se dizer que o processo da TC envolve dois movimentos principais, um movimento circular (ou semi-circular) em volta do paciente (translação), e um movimento paralelo ao paciente (deslocamento). Com o movimento de translação, é possível obter detalhes sobre a densidade interna de uma única fatia observando as mudanças ocorridas na intensidade da radiação. Já o movimento de deslocamento, por sua vez, permite uma varredura de n fatias do corpo para uma análise tridimensional (BEATTY, 2012).

A princípio, considere um único feixe de raio- X representado pela linha

$$x \cos(\theta) + y \sin(\theta) = t \quad (2.1)$$

atravessando um corpo definido pela função $f(x, y)$. Nela, x e y são as coordenadas de um ponto qualquer na linha, θ é o ângulo que a linha faz com o eixo horizontal (eixo x), e t é a distância da linha à origem (ponto $0,0$). Em outras palavras, o parâmetro θ determina a direção do feixe de raio- X , e t especifica a posição da linha de varredura no espaço.

Medidas as intensidades inicial e final, a diferença $I_0 - I_1$ representa a quantidade de atenuação que o raio X sofreu ao atravessar o corpo. É esperado que um raio atravessasse muitos materiais diferentes, como sangue, ossos, tecidos, etc., e, como discutido anteriormente, a densidade de cada material influencia de maneira direta na atenuação do raio. Portanto, a diferença da intensidade pode ser vista como o acúmulo dos coeficientes de radiação dos diferentes materiais pelo qual aquele raio passou. É possível representar a

atenuação total sofrida pelo feixe de raio- X ao percorrer o corpo em linha reta, como uma integral de linha, definida por:

$$P_{\theta}(t) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \delta(x \cos \theta + y \sin \theta - t) dx dy. \quad (2.2)$$

onde $f(x, y)$ é a função que descreve a densidade de absorção do feixe de raio- X no ponto (x, y) , e $\delta(x \cos \theta + y \sin \theta - t)$ é a função delta de Dirac, também conhecida por função impulso, que restringe a integração à linha de varredura correspondente ao valor de t . A função $P_{\theta}(t)$ resultante dessa integral é conhecida como a transformada de Radon da função $f(x, y)$, e ela descreve a atenuação do feixe de radiação em diferentes direções, representadas pelo parâmetro θ .

Um aspecto desafiador na aquisição de imagens de TC é que um único feixe de raios-x atravessa muitos materiais diferentes, como sangue, osso, tecido, etc. Isso faz com que a densidade do objeto varie ao longo do comprimento do feixe, e medir as intensidades inicial e final de um único feixe em uma direção não fornece nenhuma informação sobre as densidades variáveis ao longo do caminho percorrido pelo feixe, apenas a perda total de intensidade. Generalizando a ideia apresentada, o processo de aquisição utiliza múltiplos feixes e múltiplos detectores para capturar as atenuações sofridas em diferentes áreas do corpo. Chama-se esse conjunto de medições de projeção. A forma mais simples de uma projeção é formada pela combinação de um conjunto de integrais de raios paralelos conforme definido por $P_{\theta}(t)$ para um ângulo θ constante. A Figura 2 ilustra o conceito de projeção.

A ideia por trás da TC é que, utilizando o movimento de translação para obter projeções em diferentes ângulos, seja possível identificar a distribuição das densidades internas do objeto através da reconstrução de uma imagem detalhada. Ao combinar essas projeções de múltiplos ângulos, é possível reconstruir a imagem tridimensional interna do objeto, obtendo uma representação precisa da estrutura interna. Esse processo é facilitado pelo uso de algoritmos matemáticos, como a retroprojeção filtrada, que integram os dados das projeções em um modelo tridimensional. Assim, a TC permite a visualização não apenas das variações de densidade ao longo de um único feixe, mas de toda a complexidade estrutural do objeto analisado.

2.3 Retroprojeção

Conforme o discutido na subseção anterior, a projeção de uma imagem de TC pode ser descrita como o resultado da soma das intensidades (níveis de cinza) dos pixels ao longo de uma linha em um ângulo θ . Esta é chamada de projeção direta (HERMAN, 2009). Em termos práticos, a projeção direta é realizada quando múltiplos feixes de raios-x passam pelo objeto em diferentes ângulos, medindo a atenuação ao longo desses caminhos. Cada




Figura 2 – Projeção de um corpo $f(x, y)$ em um ângulo θ
 Fonte: Elaborado pelo autor.

projeção resulta na característica unidimensional da absorção de raios-x, correspondente ao ângulo específico. A Figura 3 exemplifica a ideia dessa operação aplicadas aos pixels de uma imagem. A mesma ideia é aplicada no tomógrafo.

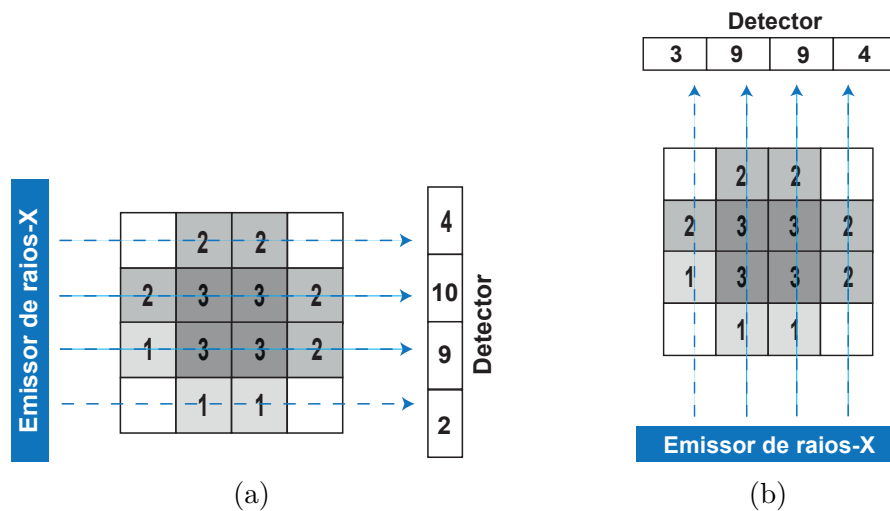


Figura 3 – Projeções diretas de uma imagem em diferentes ângulos. Em (a), $\theta = 0^\circ$, e em (b), $\theta = 90^\circ$

Fonte: Elaborado pelo autor.

A ideia da reconstrução é realizar o caminho inverso, onde se utilizam as projeções para reconstruir a imagem bidimensional original do objeto. Este processo é conhecido como

retroprojeção (HERMAN, 2009). A retroprojeção consiste em espalhar de volta na imagem o valor capturado ao longo dos ângulos em que foram adquiridos. Em outras palavras, cada projeção unidimensional é projetada de volta ao longo do ângulo correspondente na imagem bidimensional. A figura 4 exemplifica a ideia dessa operação.




Figura 4 – Retroprojeções de uma imagem em diferentes ângulos. Em (a), $\theta = 0^\circ$, e em (b), $\theta = 90^\circ$

Fonte: Elaborado pelo autor.

A retroprojeção simples tende a gerar imagens borradas porque o processo distribui os valores das projeções ao longo do domínio da imagem, espalhando a informação. Para reduzir esse efeito e melhorar a nitidez da reconstrução, utiliza-se a retroprojeção filtrada (FBP, do inglês *Filtered Backprojection*). Esse método aplica um filtro espacial às projeções antes da retroprojeção, suprimindo componentes de baixa frequência que causam o borramento. Dessa forma, a reconstrução final apresenta melhores detalhes e maior fidelidade à estrutura original.

2.4 Transformada de Anscombe

Além dos processos fundamentais de aquisição e reconstrução de imagens, é importante considerar os desafios relacionados ao ruído que podem afetar a qualidade da imagem na TC.

Conforme mencionado nas seções anteriores, na TC a aquisição da imagem é baseada na detecção de raios-x que atravessam o corpo do paciente. Esses raios-x são absorvidos de maneira diferente pelos tecidos, e a imagem final é reconstruída a partir da quantidade de fótons que chegam aos detectores após atravessar o corpo.

O processo de contagem dos fótons de raios-x que atingem os detectores é intrinsecamente aleatório e segue a distribuição de Poisson (HSIEH, 2003). Isso ocorre porque a emissão dos fótons pelo tubo de raios-x, assim como sua detecção, são eventos discretos e independentes, com uma média λ que depende da intensidade do feixe e da atenuação

pelos tecidos. Devido a essa natureza discreta e probabilística, a contagem dos fótons varia de um pixel para outro, resultando em variação na intensidade da imagem, percebida como ruído.

Na teoria da probabilidade, a distribuição de Poisson é usada para calcular a probabilidade de que um certo número k de eventos ocorra em um intervalo de tempo ou espaço, dado que o número médio esperado de eventos é λ . A fórmula para calcular essa probabilidade é:

$$P(k; \lambda) = \frac{e^{-\lambda} \lambda^k}{k!}, \quad (2.3)$$

Onde:

- $P(k; \lambda)$ é a probabilidade de observar exatamente k eventos.
- λ é o número médio de eventos esperados em um intervalo de tempo ou espaço.
- k é o número de eventos que se deseja calcular a probabilidade.

Logo, se você sabe que o número médio de eventos que ocorre em um intervalo é λ , e deseja calcular a probabilidade de exatamente k eventos ocorrerem, a distribuição de Poisson fornece essa probabilidade.

Além do ruído de Poisson, que é inerente ao processo de detecção de fótons na aquisição das imagens de TC, a reconstrução da imagem também introduz ruído Gaussiano. Esse ruído é resultado de várias operações matemáticas que ocorrem durante o processamento dos dados adquiridos, como a filtragem, retroprojeção e interpolação do sinal (GONZALEZ, 2009).

O ruído Gaussiano tem uma distribuição simétrica em torno de uma média (normalmente zero), e sua intensidade é uniforme em toda a imagem. Ao contrário do ruído de Poisson, que é dependente da intensidade do sinal, o ruído Gaussiano afeta todas as regiões da imagem de forma similar, independentemente do nível de contraste ou da quantidade de fótons detectados.

Esse ruído misto é problemático, pois técnicas eficazes para um tipo de ruído podem não funcionar bem quando há outro tipo presente. Por exemplo, um filtro que seja bom para suavizar o ruído Gaussiano pode suavizar demais as áreas de baixo contraste, onde o ruído de Poisson é predominante, resultando em perda de detalhes importantes na imagem.

Um ponto positivo é que o ruído Poisson tem uma característica específica: sua variância é igual à média, o que significa que o ruído é heterocedástico (varia com a intensidade do sinal). Nesse cenário, a transformada Anscombe (ANSCOMBE, 1948) é aplicada para linearizar o ruído, transformando-o em um ruído aproximadamente Gaussiano

(com variância constante em todos os pixels da imagem), o que facilita a aplicação de métodos de filtragem que assumem ruído aditivo e de variância constante, uma vez que muitos filtros e métodos de suavização, como o filtro de Wiener ou a transformada wavelet, são otimizados para lidar com ruído Gaussiano aditivo. A transformada de Anscombe é expressa por:

$$f(z) = 2\sqrt{z + \frac{3}{8}}, \quad (2.4)$$

onde z é o pixel da imagem.

Agora, utilizando as técnicas de filtragem estabelecidas, é possível aplicar a redução do ruído, agora aditivo e independente do sinal, sobre a nova imagem no domínio de Anscombe. Após a redução do ruído deve-se fazer uma transformada inversa de Anscombe, para obter, desse modo, uma estimativa do sinal com o ruído Poisson reduzido. A inversão direta é obtida por:

$$f^{-1}(D) = \left(\frac{D}{2}\right)^2 - \frac{3}{8}. \quad (2.5)$$

Onde D é o valor do pixel observado após a aplicação da transformada Anscombe e o processo de filtragem. Outra possibilidade é utilizar a transformada inversa ajustada, dada por:

$$f^{-1}(D) = \left(\frac{D}{2}\right)^2 - \frac{1}{8}, \quad (2.6)$$

que proporciona não enviesamento assintótico para contagens grandes. Esta é a inversa tipicamente usada em aplicações práticas, pois oferece uma estimativa mais precisa do valor subjacente λ , especialmente quando os valores observados z são elevados.

3 Filtros não locais

Na representação de qualquer imagem no meio digital, os níveis de cinza observados nos pixels estão sujeitos a perturbações, conhecidas como ruídos. Esses ruídos podem ser causados pela natureza aleatória da contagem de fótons no sensor, pela conversão analógica para digital dos sinais, pela interferência de luz ou campos eletromagnéticos, entre outros fatores. Além disso, correções digitais realizadas pela câmera ou softwares de processamento de imagem podem amplificar o ruído presente.

As técnicas de remoção de ruído baseadas em filtragem dividem-se em duas abordagens principais: filtros locais e filtros não-locais.

Na filtragem local, o valor de saída de um pixel é determinado com base em uma vizinhança ao seu redor (SZELISKI, 2022). Exemplos clássicos incluem os filtros de média, mediana e gaussiano, amplamente utilizados para suavizar ruídos em imagens. Esses filtros são eficazes na preservação de estruturas de baixo contraste, enquanto reduzem variações de intensidade indesejadas. Hadid et al. (HADID; PIETIKÄINEN, 2009) destacam que filtros locais atuam como operadores capazes de extrair características significativas de uma imagem, úteis em tarefas como detecção e reconhecimento de objetos.

No entanto, filtros locais assumem que pixels próximos são mais importantes do que pixels distantes, o que limita sua capacidade de capturar relações de longo alcance na imagem. Para superar essa restrição, surgem os filtros não-locais, também chamados de filtros globais.

Filtros não-locais analisam a imagem na totalidade, considerando regiões e pixels similares com base em medidas adaptativas de similaridade. Esses filtros atribuem pesos aos pixels levando em conta tanto sua proximidade espacial quanto a similaridade de intensidade. Como resultado, conseguem remover ruídos e aprimorar detalhes enquanto preservam as características globais da imagem, oferecendo uma solução mais precisa em comparação aos métodos locais (DELEDALLE et al., 2014).

Nas seções seguintes, serão apresentados dois exemplos importantes de filtros não-locais.

3.1 Filtro Non-Local Means

Diferentemente do filtro de média local, que calcula a média de um grupo de pixels ao redor de um píxel-alvo para suavizar a imagem, o filtro Non-Local Means (NLM), proposto por Buades et al. (BUADES; COLL; MOREL, 2005), calcula a média ponderada de pixels não apenas em uma vizinhança, mas potencialmente em toda a imagem.

O principal objetivo do NLM é atribuir pesos a cada pixel com base na similaridade entre regiões (*patches*) da imagem. Essa abordagem permite que pixels distantes, mas com padrões semelhantes, contribuam de forma significativa para a média final, o que aumenta a eficácia na remoção de ruídos sem comprometer detalhes importantes. Em outras palavras, regiões com pixels semelhantes na imagem apresentam um peso maior para o cálculo.

Dada uma imagem ruidosa $v = \{v(i) \mid i \in I\}$, o valor filtrado de um pixel i é calculado como:

$$NL[v](i) = \sum_{j \in I} w(i, j)v(j) \quad (3.1)$$

Nesta equação, $w(i, j)$ é um peso que reflete a similaridade entre os pixels i e j . Os pesos obedecem às seguintes condições:

$$0 \leq w(i, j) \leq 1 \quad (3.2)$$

$$\sum_i w(i, j) = 1 \quad (3.3)$$

Os pesos $w(i, j)$ são calculados usando a seguinte expressão:

$$w(i, j) = \frac{1}{Z(i)} e^{-\frac{\|v(N_i) - v(N_j)\|_2^2}{h^2}} \quad (3.4)$$

Aqui, $v(N_i)$ e $v(N_j)$ representam *patches* (submatrizes) da imagem centrados nos pixels i e j , respectivamente. A distância Euclidiana entre os *patches* é dada por:

$$\|v(N_i) - v(N_j)\|_2^2 = \sum_{k \in N_i} a_k (v(N_i)_k - v(N_j)_k)^2 \quad (3.5)$$

O termo a_k é um peso que ajusta a contribuição de cada pixel dentro do *patch*, enquanto $(v(N_i)_k - v(N_j)_k)$ representa a diferença entre os valores dos pixels correspondentes nos *patches* N_i e N_j . O parâmetro h controla a intensidade do decaimento exponencial: valores baixos de h preservam detalhes, mas podem deixar o ruído residual, enquanto valores altos suavizam excessivamente a imagem, possivelmente eliminando detalhes.

A constante $Z(i)$ normaliza os pesos para que respeitem a condição de soma igual a 1 (Eq. (3.3)):

$$Z(i) = \sum_{j \in I} e^{-\frac{\|v(N_i) - v(N_j)\|_2^2}{h^2}}$$

3.1.1 Complexidade computacional

No NLM, o processo envolve calcular uma média ponderada para cada pixel com base na similaridade entre *patches* de pixels. Em imagens de tamanho $N \times M$ com *patches* de dimensão $k \times k$, o custo computacional é da ordem de $O(k^2 N^2 M^2)$. Para mitigar essa alta complexidade, os autores propuseram limitar a busca por *patches* semelhantes a uma janela delimitadora de tamanho $b \times b$ ao redor do pixel de interesse, reduzindo o custo para $O(k^2 b^2 NM)$.

A Figura 5 ilustra o conceito de *patches* semelhantes em dois cenários: (a) com busca global e (b) com busca restrita a uma janela delimitadora.

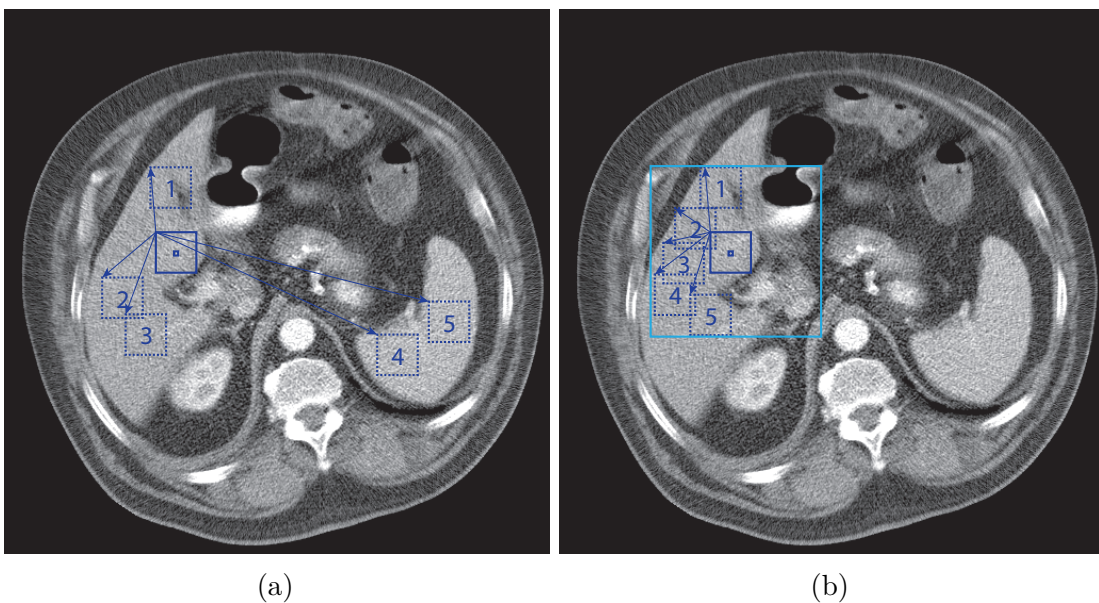


Figura 5 – Busca por *patches* semelhantes no algoritmo Non-Local Means. Em (a), a busca ocorre em toda a imagem; em (b), é restrita a uma região delimitada.

Fonte: Elaborado pelo autor.

3.2 Filtro Block-Matching and 3D Filtering

O filtro Block-Matching and 3D Filtering (BM3D), proposto por (DABOV et al., 2006), é amplamente reconhecido como uma das técnicas mais eficazes para remoção de ruído em imagens. Sua abordagem combina conceitos de agrupamento não-local com técnicas avançadas de processamento em domínios transformados, garantindo alta qualidade na preservação de detalhes estruturais em imagens ruidosas. A ideia central é explorar a redundância entre *patches* semelhantes dentro da imagem, agrupando-os em estruturas 3D e aplicando operações colaborativas para atenuar o ruído.

O algoritmo BM3D consiste em dois estágios principais, cada um com objetivos e metodologias distintas, mas complementares. As etapas detalhadas são descritas a seguir.

3.2.1 Estágio 1: Estimativa base

O objetivo do primeiro estágio é gerar uma estimativa inicial da imagem verdadeira (sem ruído) que servirá como referência para o estágio subsequente. Este processo é realizado em várias etapas:

- i. **Correspondência de *patches*.** Para cada pixel na imagem de entrada, realiza-se uma busca por *patches* (pequenas janelas) na imagem semelhantes à região de referência ao redor dele. A similaridade entre os *patches* é avaliada utilizando a distância Euclidiana normalizada:

$$d(Z_{x_R}, Z_x) = \frac{\|Z_{x_R} - Z_x\|_2^2}{(N^{\text{ht}})^2}, \quad (3.6)$$

onde Z_{x_R} e Z_x representam os *patches* centrados nos pixels de referência e comparação, respectivamente, e N^{ht} é o tamanho do bloco.

- ii. **Agrupamento.** Os *patches* semelhantes identificados são empilhados, formando um bloco 3D. Este agrupamento explora a redundância de informações em *patches* similares para facilitar a remoção de ruído.
- iii. **Filtragem colaborativa.** Aplica-se uma transformação tridimensional ao bloco 3D agrupado, como a Transformada de Coseno Discreta (DCT) ou a Transformada Wavelet. A redução de ruído é então realizada por meio de um *Hard Thresholding* (DONOHO; JOHNSTONE, 1994), onde coeficientes abaixo de um limiar pré-definido são eliminados. Após a filtragem, a inversa da transformação é aplicada para retornar os *patches* ao domínio espacial.
- iv. **Agregação.** A imagem base é reconstruída agregando as estimativas filtradas dos *patches*, levando em conta os pesos associados a cada um. Essa etapa reduz artefatos e melhora a consistência entre os *patches* sobrepostos.

3.2.2 Estágio 2: Filtragem refinada com Wiener

No segundo estágio, a imagem base gerada no primeiro estágio é usada como referência para aprimorar ainda mais a qualidade da remoção de ruído. A filtragem agora é realizada utilizando o filtro de Wiener (WIENER, 1949), que é conhecido por levar em consideração tanto o ruído quanto os detalhes estruturais da imagem.

- i. **Correspondência de *patches*.** A correspondência de *patches* é repetida, desta vez utilizando a imagem base como referência.
- ii. **Agrupamento.** *patches* semelhantes da imagem ruidosa e da imagem base são empilhados separadamente, formando dois blocos 3D. As localizações dos *patches* na imagem base determinam os *patches* correspondentes na imagem ruidosa.

- iii. **Filtragem colaborativa com Wiener.** A filtragem colaborativa é aplicada em ambos os blocos 3D, utilizando o filtro de Wiener. Este filtro ajusta os coeficientes transformados com base na relação entre o ruído e o sinal, usando a imagem base como referência para estimar a variância local do sinal. Após a filtragem, aplica-se a inversa da transformação 3D para retornar ao domínio espacial.
- iv. **Agregação.** As estimativas refinadas dos *patches* são combinadas para gerar a imagem final, utilizando uma média ponderada para suavizar transições e garantir continuidade entre os blocos.

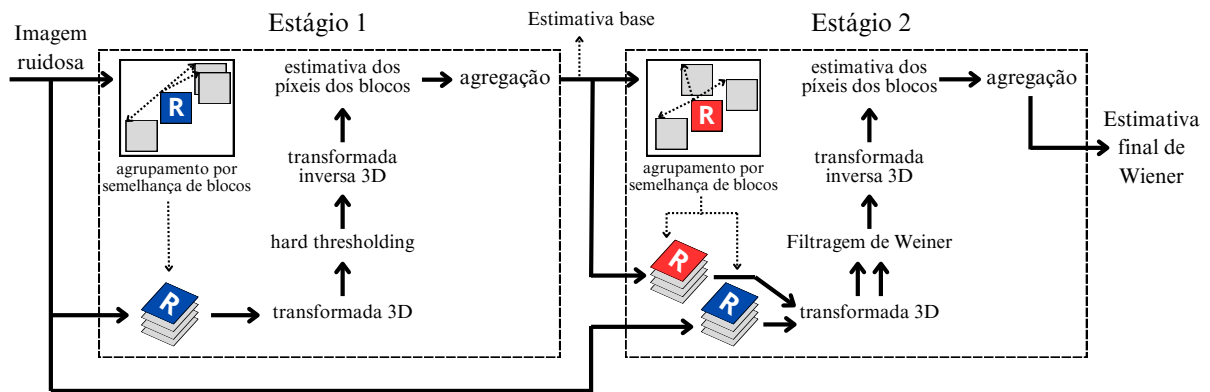


Figura 6 – Diagrama de blocos das etapas do algoritmo BM3D.

Fonte: Adaptado de (DABOV et al., 2006).

3.2.3 Complexidade computacional

A complexidade computacional do algoritmo BM3D pode ser expressa como:

$$O(MN \cdot O_{T_{2D}}(N_1, N_1)) + O\left(MN \cdot \frac{N_1^2 + N_2}{N_{\text{step}}^2} N_S^2\right) + O\left(MN \cdot \frac{O_{T_{3D}}(N_1, N_1, N_2)}{N_{\text{step}}^2}\right)$$

onde as variáveis:

- M e N são as dimensões da imagem de entrada;
- $O_{T_{2D}}(N_1, N_1)$ e $O_{T_{3D}}(N_1, N_1, N_2)$ denotam as complexidades das transformadas bidimensional e tridimensional usadas para a filtragem;
- N_1 e N_2 representam as dimensões dos blocos utilizados no agrupamento colaborativo;
- N_S é o tamanho da janela de pesquisa para correspondência de blocos;
- N_{step} define o número de passos para deslocamento dos blocos durante a filtragem.

Cada parte da expressão se refere a:

- **Agrupamento:** A complexidade $O(MN \cdot O_{T_{2D}}(N_1, N_1))$ refere-se ao custo das operações de correspondência de blocos e transformações 2D durante a fase de agrupamento.
- **Pesquisa de Blocos Semelhantes:** O termo $O\left(MN \cdot \frac{N_1^2 + N_2}{N_{\text{step}}^2} N_S^2\right)$ está associado à busca de blocos semelhantes em uma janela de pesquisa definida pelo parâmetro N_S .
- **Filtragem 3D:** A complexidade $O\left(MN \cdot \frac{O_{T_{3D}}(N_1, N_1, N_2)}{N_{\text{step}}^2}\right)$ refere-se à aplicação das transformadas tridimensionais durante o processo de filtragem.

As complexidades $O_{T_{2D}}$ e $O_{T_{3D}}$ dependem das propriedades das transformadas adotadas. Por exemplo, a Transformada Discreta de Fourier (DFT) pode ser implementada de forma eficiente usando algoritmos FFT (*Fast Fourier Transform*). A FFT bidimensional tem uma complexidade $O(N_1 N_2 \log(N_1 N_2))$, enquanto uma transformada não separável personalizada apresenta complexidade $O(N_1^2 N_2^2)$.

4 Estudo computacional

4.1 Metodologia

Visando analisar a eficiência dos filtros NLM e BM3D, bem como comparar seus resultados, foram selecionadas três imagens reais de domínio público obtidas de um subconjunto disponibilizado na plataforma Keeagle, derivado do banco de dados público *The Cancer Imaging Archive (TCIA)* (COMMUNITY, 2020; ALBERTINA et al., 2016).

As imagens escolhidas são bidimensionais (2D) e consistem em fatias da região do peitoral e tronco, originalmente utilizadas para a classificação de adenocarcinoma pulmonar. Essas imagens integram o conjunto *Cancer Genome Atlas Lung Adenocarcinoma (TCGA-LUAD)*, uma iniciativa do projeto *The Cancer Genome Atlas (TCGA)*. O objetivo principal do TCGA-LUAD é estabelecer correlações entre fenótipos de câncer e genótipos, combinando dados clínicos, genéticos e de imagem.

O experimento foi dividido em três etapas. Primeiramente, os pixels de cada imagem foram reescalados para a faixa de valores entre 0 e 255, utilizando tipo decimal, para garantir maior precisão na aplicação dos filtros. Em seguida, na segunda etapa, para um nível de ruído previamente definido, aplicou-se a transformada de Radon à imagem original, gerando seu sinograma. Após isso, foi adicionado ruído Poisson no domínio de Radon, seguido pela aplicação da transformada de Radon inversa, resultando em uma imagem ruidosa no domínio espacial.

Na terceira etapa, foi realizada a filtragem da imagem ruidosa. Este processo foi dividido em dois cenários: no primeiro, os algoritmos não-locais foram aplicados diretamente à imagem ruidosa; no segundo, utilizou-se a Transformada Anscombe (TA), com os filtros sendo aplicados no domínio de Anscombe e posteriormente reconvertidos ao domínio espacial.

Os critérios para avaliar e comparar a eficiência das filtrações basearam-se nas métricas PSNR (*Peak Signal-to-Noise Ratio*, do inglês, Relação Pico-Sinal-Ruído) e SSIM (*Structural Similarity Index*, do inglês, Índice de Similaridade Estrutural). Estas métricas foram escolhidas para avaliar a qualidade das imagens filtradas por apresentarem características complementares.

A realização dos experimentos se deu em um ambiente com as seguintes configurações: Sistema Operacional Windows 11, com 8GB de memória RAM, 512GB de memória virtual, processador Intel(R) Core(TM) i3-1005G1 com 2 núcleos e 4 processadores lógicos que trabalham em 1.20GHz.

No quesito de software, foi utilizada a linguagem Python, versão 3.9.13, com o auxílio das seguintes bibliotecas de código aberto:

- **numpy**: utilizada para operações em imagens representadas em formato matricial;
- **scikit-image**: empregada para carregamento e salvamento de imagens, aplicação da transformada de Radon e sua inversa, cálculo das métricas PSNR e SSIM, cálculo do parâmetro σ , e aplicação do filtro *Non-Local Means*;
- **matplotlib**: utilizada para visualização de imagens e geração de gráficos; e
- **pandas**: utilizada para manipulação e análise de tabelas de resultados.

O código-fonte do projeto está disponibilizado em um repositório git, na plataforma GitHub, acessível em (SILVA, 2024).

4.2 Resultados

Para a avaliação do desempenho dos filtros, foram escolhidos as métricas *Peak Signal-to-Noise Ratio* e *Structural similarity index measure*.

O *Peak Signal-to-Noise Ratio* (PSNR) é uma métrica utilizada para avaliar a qualidade da reconstrução de uma imagem comparando-a com uma imagem de referência. O PSNR é calculado a partir do erro quadrático médio (MSE) entre as duas imagens, representando a relação entre o sinal original e o ruído introduzido pelo processo de reconstrução (WANG; BOVIK, 2009; TAN et al., 2013). O valor do PSNR é expresso em decibéis (dB) e, quanto maior o valor, melhor a qualidade da imagem reconstruída.

Já o *Structural similarity index measure* (SSIM) é uma métrica utilizada para avaliar a qualidade de reconstrução de uma imagem, comparando-a com uma imagem de referência. O cálculo do SSIM considera três componentes principais: luminância, contraste e estrutura, os quais são estimados a partir das médias e desvios padrão das imagens analisadas (SETIADI, 2022). O valor do SSIM varia no intervalo de 0 a 1, sendo que um valor próximo a 1 indica alta similaridade entre as imagens, enquanto valores menores representam maior degradação na qualidade da reconstrução.

A Tabela 1 apresenta os valores de PSNR e de SSIM entre as imagens ruidosas e as imagens originais, utilizadas como referência. Esses valores refletem a qualidade inicial das imagens antes da aplicação de qualquer filtro. Observa-se que tanto o PSNR quanto o SSIM diminui de forma consistente à medida que o nível de ruído aumenta, indicando a degradação da qualidade da imagem causada pela adição de ruído. Entre as imagens analisadas, a imagem ct6 apresenta os maiores valores de PSNR em todos os níveis de ruído.

Métrica	Imagem	Nível de ruído		
		Baixo	Médio	Alto
PSNR	ct3	22.86	21.77	20.19
	ct4	22.18	21.69	20.45
	ct6	24.87	23.52	21.45
SSIM	ct3	0.85	0.81	0.75
	ct4	0.82	0.81	0.77
	ct6	0.87	0.85	0.80

Tabela 1 – Valores do PSNR, em decibéis, e do SSIM da imagem ruidosa para diferentes imagens e tipos de ruído.

A Tabela 2 apresenta o ganho percentual no PSNR após a aplicação dos filtros NLM e BM3D, comparando os resultados com e sem a Transformada de Anscombe (TA). Cada valor na tabela corresponde à razão entre o PSNR da imagem filtrada e o PSNR da imagem ruidosa, cujos valores foram previamente apresentados na Tabela ???. Para níveis mais altos de ruído, os ganhos percentuais são mais expressivos, evidenciando que os algoritmos recuperam maior qualidade em cenários de maior degradação. Vale ressaltar que o BM3D, de forma geral, apresenta maior ganho percentual, especialmente quando a TA é aplicada. No entanto, para níveis baixos e médios de ruído na imagem ct4, o algoritmo NLM supera o BM3D, sugerindo uma maior eficácia nesse caso específico.

Imagem	Algoritmo	Nível de Ruído		
		Baixo	Médio	Alto
ct3	NLM	1.26 / 1.43	1.72 / 1.82	2.72 / 2.76
	BM3D	0.23 / 1.80	0.69 / 2.30	2.06 / 3.55
ct4	NLM	0.04 / 0.00	0.08 / 0.01	0.31 / 0.26
	BM3D	0.04 / 0.00	0.11 / 0.07	0.18 / 0.49
ct6	NLM	0.70 / 0.93	1.21 / 1.34	2.13 / 2.13
	BM3D	0.07 / 1.05	0.15 / 1.54	0.18 / 2.57

Tabela 2 – Ganho percentual do valor do PSNR da imagem filtrada em relação ao PSNR da imagem ruidosa para diferentes imagens e tipos de ruído. Cada nível de ruído apresenta o resultado sem aplicação da TA na coluna da esquerda e o resultado usando TA na coluna da direita (em negrito).

Os ganhos no SSIM também foram analisados e apresentados na Tabela 3. Nesta tabela, cada valor corresponde à razão entre o SSIM da imagem filtrada e o SSIM da imagem ruidosa. Tal como no PSNR, os ganhos em SSIM aumentam com o nível de ruído, reforçando a eficiência dos filtros em melhorar a qualidade estrutural das imagens degradadas.

A Figura 7 ilustra os resultados visuais da filtragem para a imagem ct3. Cada subfigura representa uma etapa do processo, desde a imagem original até os resultados após a aplicação dos filtros com e sem a TA. Observa-se que a aplicação da TA contribui

Imagem	Algoritmo	Nível de Ruído		
		Baixo	Médio	Alto
ct3	NLM	5.94 / 6.01	7.78 / 7.86	10.73 / 10.84
	BM3D	6.80 / 7.49	8.92 / 9.66	12.76 / 13.50
ct4	NLM	0.00 / 0.00	0.01 / 0.00	0.00 / 0.00
	BM3D	-0.16 / 0.00	-0.09 / 0.00	0.00 / 0.01
ct6	NLM	0.89 / 1.28	1.84 / 2.16	3.94 / 4.18
	BM3D	1.00 / 1.85	1.77 / 2.97	4.02 / 5.44

Tabela 3 – Ganho percentual do valor do SSIM da imagem filtrada em relação ao SSIM da imagem ruidosa para diferentes imagens e tipos de ruído. Cada nível de ruído apresenta o resultado sem aplicação da TA na coluna da esquerda e o resultado usando TA na coluna da direita (em negrito).

para uma melhor recuperação de detalhes finos, especialmente no BM3D. Essa diferença é evidente tanto em métricas quantitativas quanto na inspeção visual.

A Tabela 4 apresenta o tempo de execução (em segundos) dos algoritmos NLM e BM3D para as diferentes imagens analisadas. Cada célula mostra o tempo sem TA seguido pelo tempo com TA em negrito. Como esperado, a aplicação da TA aumenta o tempo de processamento, especialmente no caso do BM3D, devido à maior complexidade computacional.

Imagem	Tempo em segundos	
	NLM	BM3D
ct3	1.1 / 2.6	9.4 / 16.2
ct4	0.9 / 1.0	8.2 / 8.9
ct6	1.0 / 1.4	8.0 / 8.2

Tabela 4 – Tempo de execução (em segundos) dos algoritmos NLM e BM3D para diferentes imagens. A coluna à esquerda apresenta o tempo sem TA, enquanto a coluna à direita (em negrito) apresenta o tempo com a aplicação da TA.



Figura 7 – Resultados visuais da filtragem para a imagem ct3.

5 Conclusão

Neste trabalho, foram investigados métodos de filtragem não local para a remoção de ruído em imagens de tomografia computadorizada (TC). Foram realizados experimentos utilizando os filtros NLM e BM3D em imagens reais, avaliando o desempenho desses métodos com base nas métricas PSNR e SSIM. Além disso, analisamos o impacto da Transformada de Anscombe como uma ferramenta de melhoria da eficácia dos filtros. Os resultados mostram que a aplicação de TA contribui positivamente nos resultados de filtragem para a maioria dos casos, e também que o BM3D em conjunto com o uso da TA obtém os melhores resultados tanto do PSNR quanto do SSIM, mostrando-se mais eficiente neste cenário.

Os experimentos realizados permitiram identificar importantes características dos métodos estudados. A principal vantagem dos filtros NLM e BM3D é a sua eficiência como métodos de *single-image denoising*, o que resulta em um custo computacional baixo e na facilidade de aplicação sem a necessidade de grandes bases de dados para treinamento. Por outro lado, métodos baseados em aprendizado profundo, apesar de exigirem um processo de treinamento computacionalmente custoso, possuem a capacidade de generalizar para diferentes tipos de ruído, o que representa uma limitação significativa dos filtros utilizados neste trabalho, que foram projetados especificamente para lidar com ruído Poisson ou Poisson-Gaussiano.

Como trabalhos futuros, é possível ampliar a análise realizada, incluindo a utilização de um maior número de imagens de TC, bem como a aplicação de outros filtros não locais, como a adaptação Poisson Non-Local Means. Além disso, uma comparação mais aprofundada entre os métodos estudados e algoritmos baseados em aprendizado profundo pode ser realizada, a fim de explorar as vantagens e desvantagens de cada abordagem em diferentes cenários. Por fim, a metodologia desenvolvida neste trabalho pode ser adaptada e aplicada a outros domínios, como o processamento de imagens de microscopia de fluorescência, o que abriria novas oportunidades para explorar e avaliar o desempenho dos filtros não locais em contextos variados.

Referências

- ALBERTINA, B. et al. *Radiology Data from The Cancer Genome Atlas Lung Adenocarcinoma [TCGA-LUAD] collection*. The Cancer Imaging Archive, 2016. Accessed: 2024-10-08. Disponível em: <<http://doi.org/10.7937/K9/TCIA.2016.JGNIHEP5>>. Citado na página 25.
- ANSCOMBE, F. J. The transformation of poisson, binomial and negative-binomial data. *Biometrika*, JSTOR, v. 35, n. 3/4, p. 246–254, 1948. Citado na página 17.
- BEATTY, J. *The radon transform and the mathematics of medical imaging*. Tese (Honors Thesis) — Colby College, 2012. Disponível em: <<https://digitalcommons.colby.edu/honorstheses/646>>. Citado na página 13.
- BRAZ, D. *Tomografia computadorizada no estudo da mecânica da fratura em misturas asfálticas*. Tese (Doutorado) — Tese de D. Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 1997. Citado na página 9.
- BUADES, A.; COLL, B.; MOREL, J.-M. A review of image denoising algorithms, with a new one. *Multiscale modeling & simulation*, SIAM, v. 4, n. 2, p. 490–530, 2005. Citado 2 vezes nas páginas 9 e 19.
- COMMUNITY, K. *Chest CT-Scan images Dataset*. 2020. Disponível em: <<https://www.kaggle.com/datasets/kmader/siim-medical-images/data>>. Acesso em: 8 out. 2024. Citado na página 25.
- DABOV, K. et al. Image denoising with block-matching and 3d filtering. In: SPIE. *Image processing: algorithms and systems, neural networks, and machine learning*. [S.l.], 2006. v. 6064, p. 354–365. Citado 3 vezes nas páginas 9, 21 e 23.
- DELEDALLE, C.-A. et al. Exploiting patch similarity for sar image processing: The nonlocal paradigm. *IEEE Signal Processing Magazine*, IEEE, v. 31, n. 4, p. 69–78, 2014. Citado na página 19.
- DONOHO, D. L.; JOHNSTONE, I. M. Ideal spatial adaptation by wavelet shrinkage. *biometrika*, Oxford University Press, v. 81, n. 3, p. 425–455, 1994. Citado na página 22.
- GOLDMAN, L. W. Principles of ct and ct technology. *Journal of Nuclear Medicine Technology*, Society of Nuclear Medicine, v. 35, n. 3, p. 115–128, 2007. ISSN 0091-4916. Disponível em: <<https://tech.snmjournals.org/content/35/3/115>>. Citado na página 12.
- GONZALEZ, R. C. *Digital image processing*. [S.l.]: Pearson education india, 2009. Citado na página 17.
- HADID, A.; PIETIKÄINEN, M. Local image filters. In: _____. *Encyclopedia of Biometrics*. Boston, MA: Springer US, 2009. p. 943–949. ISBN 978-0-387-73003-5. Disponível em: <https://doi.org/10.1007/978-0-387-73003-5_298>. Citado na página 19.
- HELLIWELL, J. R. et al. Applications of x-ray computed tomography for examining biophysical interactions and structural development in soil systems: a review. *European*

Journal of Soil Science, Wiley Online Library, v. 64, n. 3, p. 279–297, 2013. Citado na página 9.

HERMAN, G. T. *Fundamentals of computerized tomography: image reconstruction from projections*. [S.l.]: Springer Science & Business Media, 2009. Citado 2 vezes nas páginas 14 e 16.

HOUNSFIELD, G. N. Computerized transverse axial scanning (tomography): Part 1. Description of system. *British Journal of Radiology*, v. 46, n. 552, p. 1016–1022, 01 2014. Citado na página 12.

HSIEH, J. *Computed tomography: principles, design, artifacts, and recent advances*. [S.l.]: SPIE press, 2003. Citado na página 16.

JEROME, N. T. et al. Real-time local noise filter in 3-d visualization of ct data. *IEEE Transactions on Nuclear Science*, v. 66, n. 7, p. 1296–1303, 2019. Citado na página 9.

JUNEJA, M. et al. Denoising of computed tomography using bilateral median based autoencoder network. *International Journal of Imaging Systems and Technology*, Wiley Online Library, v. 32, n. 3, p. 935–955, 2022. Citado na página 10.

JUNG, H. Basic physical principles and clinical applications of computed tomography. *Progress in Medical Physics*, Korean Society of Medical Physics, v. 32, n. 1, p. 1–17, 2021. Citado na página 12.

KIM, W. et al. Wavelet subband-specific learning for low-dose computed tomography denoising. *Plos one*, Public Library of Science San Francisco, CA USA, v. 17, n. 9, p. e0274308, 2022. Citado na página 10.

LEPCHA, D. C. et al. A constructive non-local means algorithm for low-dose computed tomography denoising with morphological residual processing. *Plos one*, Public Library of Science San Francisco, CA USA, v. 18, n. 9, p. e0291911, 2023. Citado na página 10.

SETIADI, D. R. I. M. Improved payload capacity in lsb image steganography uses dilated hybrid edge detection. 2022. Citado na página 26.

SILVA, R. A. d. *Filragem não Local de ruídos em imagens de tomografia computadorizada*. 2024. Disponível em: <<https://github.com/rad-silva/ct-filter.git>>. Citado na página 26.

SZELISKI, R. *Computer vision: algorithms and applications*. [S.l.]: Springer Nature, 2022. Citado na página 19.

TAN, H. L. et al. A perceptually relevant mse-based image quality metric. *IEEE Transactions on Image Processing*, IEEE, v. 22, n. 11, p. 4447–4459, 2013. Citado na página 26.

WANG, Y. et al. A novel singular value decomposition-based similarity measure method for non-local means denoising. *Signal, Image and Video Processing*, Springer, p. 1–8, 2022. Citado na página 10.

WANG, Z.; BOVIK, A. C. Mean squared error: Love it or leave it? a new look at signal fidelity measures. *IEEE signal processing magazine*, IEEE, v. 26, n. 1, p. 98–117, 2009. Citado na página 26.

WEVERS, M. et al. Applications of ct for non-destructive testing and materials characterization. *Industrial X-ray computed tomography*, Springer, p. 267–331, 2018. Citado na página [9](#).

WIENER, N. *Extrapolation, interpolation, and smoothing of stationary time series: with engineering applications*. [S.l.]: The MIT press, 1949. Citado na página [22](#).