

UNIVERSIDADE FEDERAL DE SÃO CARLOS– UFSCAR  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA– CCET  
DEPARTAMENTO DE COMPUTAÇÃO– DC  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DA COMPUTAÇÃO– PPGCC

**Rodrigo Garcia Abegão**

**Filtragem de ruído Poisson utilizando o  
algoritmo BM3D com distâncias  
estocásticas e transformações de  
estabilização de variância**



# UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia  
Programa de Pós-Graduação em Ciência da Computação

---

## Folha de Aprovação

---

Defesa de Dissertação de Mestrado do candidato Rodrigo Garcia Abegão, realizada em 04/12/2024.

### Comissão Julgadora:

Prof. Dr. Alexandre Luis Magalhães Levada (UFSCar)

Prof. Dr. André Ricardo Backes (UFSCar)

Prof. Dr. Diego Saqui (IFSULDEMG)

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Ciência da Computação.

**Rodrigo Garcia Abegão**

**Filtragem de ruído Poisson utilizando o  
algoritmo BM3D com distâncias  
estocásticas e transformações de  
estabilização de variância**

Qualificação de mestrado apresentada ao Programa de Pós-Graduação em Ciências da Computação do Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Área de concentração: Metodologias e Técnicas de Computação

Orientador: Alexandre Luis Magalhães Levada

São Carlos

2024

*Este trabalho é dedicado aos pesquisadores e entusiastas na área de redução de ruído em imagens.*

---

# Agradecimentos

---

Primeiramente, gratidão a Deus e a minha família, os quais me apoiaram e me acompanharam, passo a passo, nesta jornada de aprendizagem; mesmo em momentos de dificuldades estiveram comigo.

Também agradeço ao Alexandre Luis Magalhaes Levada, Cid Adinam Nogueira Santos e André de Andrade Bindilatti que ensinaram, além de darem todo o suporte necessário. Com toda certeza, sem eles, este trabalho não estaria completo.

Em especial, gratidão imensa aos mestres e doutores que contribuíram de forma direta ou indiretamente, no desenvolvimento do trabalho em questão e ao meu orientador Nelson Delfino d'Ávila Mascarenhas(In memoriam), ao qual presto homenagens pela grande importância que teve durante o período de sua orientação.

E, por fim, agradecimentos à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela bolsa concedida no período do programa.

*“Os que se encantam com a prática sem a ciência são como os timoneiros  
que entram no navio sem timão nem bússola,  
nunca tendo certeza do seu destino.”  
(Leonardo da Vinci)*

---

# Resumo

---

Ruído em imagens é um fenômeno presente em diversos campos da pesquisa acadêmica, devido ao fato de que sua presença nas mesmas pode prejudicar a análise e a interpretação de dados contidos nelas gerando, assim, implicações significativas em áreas como: medicina, ciências biológicas, astronomia e geologia, entre outras.

No campo da medicina, imagens geradas por tomógrafos são degradadas por um ruído denominado Poisson. Sendo este, um ruído estatístico e dependente de sinal, provocado pelos fenômenos de absorção e espalhamento ocasionados durante à interação entre o feixe de raios X e a matéria. Tal tipo de ruído é causado por diversas fontes, incluindo variações na intensidade da luz, erros de medição, interferências eletromagnéticas e ruído eletrônico.

Há diversos filtros para atenuar a presença do ruído Poisson em imagens. E, as técnicas mais utilizadas neste meio são as não-locais, como o *Block Matching 3D* (BM3D). As quais têm como finalidade a similaridade entre pequenos fragmentos equivalentes na imagem, denominados *patches* tais quais o estado da arte, geralmente, adota a distância Euclidiana em casos de *Additive White Gaussian Noise* (AWGN).

A proposta do presente trabalho de pesquisa é utilizar distâncias estocásticas dentro do algoritmo BM3D e obter melhores resultados em relação ao estado da arte. A adoção de distâncias estocásticas permite que os estudos explorem abordagens inovadoras e considerem diferentes características das distribuições de dados. Essa abordagem amplia significativamente as opções disponíveis para análise e comparação de variáveis aleatórias, proporcionando uma visão mais completa e detalhada das relações e padrões presentes nos dados. Para isto, foi necessário aplicar a técnica de estabilização de variância, conhecida *Variance-stabilizing Transformation* (VST), cuja função é transformar o ruído de Poisson em AWGN. São vários os artigos que mostram a eficácia do uso de diferentes distâncias.

**Palavras-chave:** BM3D, VST, Ruído Poisson, Distâncias Estocásticas.

---

# Abstract

---

Noise in images is a phenomenon present in several fields of academic research, due to the fact that its presence in them can impair the analysis and interpretation of data contained in them. Thus, generating significant implications in areas such as: medicine, biological sciences, astronomy and geology, among others.

In the medical field, images generated by tomographs are degraded by a noise called Poisson. This is a statistical and signal-dependent noise caused by the absorption and scattering phenomena caused during the interaction between the X-ray beam and matter. This type of noise is caused by several sources, including variations in light intensity, measurement errors, electromagnetic interference and electronic noise.

There are several filters to mitigate the presence of Poisson noise in images. And, the most used techniques in this environment are non-local, such as BM3D. The purpose of which is the similarity between small equivalent fragments in the image, called *patches* such that the state of the art generally adopts the Euclidean distance in cases of AWGN.

This research proposes the use of stochastic distances in the BM3D algorithm to achieve results superior to the current state of the art. The incorporation of stochastic distances enables the exploration of innovative approaches that take into account different characteristics of data distributions. This approach significantly expands the possibilities for analyzing and comparing random variables, providing a more comprehensive and detailed understanding of the relationships and patterns present in the data. To achieve these objectives, the variance-stabilizing technique known as VST was used to transform Poisson noise into AWGN. Several studies demonstrate the effectiveness of using different distances, although performance depends on the specific type of noise present in the data.

**Keywords:** BM3D, VST, Poisson Noise, Stochastic Distances.

---

# Lista de ilustrações

---

Figura 2.1 – Exemplo de agrupamento dos blocos de imagens contaminadas com AWGN. R é o bloco referenciado . . . . .	26
Figura 2.2 – Exemplo de agrupamento com blocos perfeitamente idênticos . . . . .	26
Figura 2.3 – Fluxograma do funcionamento do algoritmo BM3D . . . . .	27
Figura 2.4 – Transformação 3D em bloco de patches . . . . .	28
Figura 2.5 – Diagrama representativo da estimativa básica do algoritmo BM3D . . . . .	29
Figura 2.6 – Diagrama representativo da estimativa final do algoritmo BM3D . . . . .	30
Figura 2.7 – Imagem exemplo de microscopia de fluorescência . . . . .	31
Figura 4.1 – Imagens FZE Noisy FOV 1 . . . . .	39
Figura 4.2 – Imagens FZE Noisy FOV 2 . . . . .	39
Figura 4.3 – Diagrama de blocos da metodologia proposta . . . . .	43
Figura 5.1 – Resultados obtidos com as FZE FOV 1 . . . . .	45
Figura 5.2 – NLM+TA . . . . .	45
Figura 5.3 – BM3DSD+TA . . . . .	45
Figura 5.4 – Resultados obtidos com as FZE FOV 2 . . . . .	46
Figura 5.5 – NLM . . . . .	46
Figura 5.6 – BM3DSD+TA . . . . .	46
Figura 5.7 – Resultados SSIM FOV 1 . . . . .	46
Figura 5.8 – Resultados PSNR FOV 1 . . . . .	47
Figura 5.9 – Resultados SSIM FOV 2 . . . . .	47
Figura 5.10 – Resultados PSNR FOV 2 . . . . .	48

---

# Lista de tabelas

---

Tabela 1	–	$(h, \phi)$ -divergências e funções relacionadas $\phi$ e $h$ . . . . .	40
Tabela 2	–	Distâncias estocásticas para ruído Gaussiano com fórmulas fechadas . . . . .	41
Tabela 3	–	Resultados da FOV 1 . . . . .	47
Tabela 4	–	Resultados da FOV 2 . . . . .	48
Tabela 5	–	Tabela de médias e desvios padrão dos valores de SSIM FOV 1 em relação à variação do sigma ( $\sigma$ ) para diferentes distâncias . . . . .	48
Tabela 6	–	Tabela de médias e desvios padrão dos valores de PSNR FOV 1 em relação à variação do sigma ( $\sigma$ ) para diferentes distâncias . . . . .	48
Tabela 7	–	Tabela de médias e desvios padrão dos valores de SSIM FOV 2 em relação à variação do sigma ( $\sigma$ ) para diferentes distâncias . . . . .	49
Tabela 8	–	Tabela de médias e desvios padrão dos valores de PSNR FOV 2 em relação à variação do sigma ( $\sigma$ ) para diferentes distâncias . . . . .	49

---

# Lista de algoritmos

---

---

# Lista de siglas

---

**AWGN** *Additive White Gaussian Noise*

**ART** *Algebraic Reconstruction Technique*

**BM3D** *Block Matching 3D*

**CAPES** *Coordenação de Aperfeiçoamento de Pessoal de Nível Superior*

**CRP** *Convolution Reverse Projection*

**DCNN** *Deep Convolutional Neural Networks*

**DCT** *Discrete Cosine Transform*

**DDID** *Dual Domain Image Denoising*

**DFT** *Discrete Fourier Transform*

**EM** *Expectation Maximization*

**GAT** *Generalized Anscombe Transformation*

**MAP** *Maximum a Posteriori*

**MLE** *Maximum Likelihood Estimation*

**MRF** *Markov Random Field*

**MSE** *Mean Square Error*

**NLM** *Non Local Means*

**PET** *Positron Emission Tomography*

**POCS** *Projections Onto Convex Sets*

**PSNR** *Peak Signal-to-Noise Ratio*

**SPECT** *Single Photon Emission Computed Tomography*

**SSIM** *Structural SIMilarity Index*

**VST** *Variance-stabilizing Transformation*

---

# Sumário

---

1	INTRODUÇÃO . . . . .	14
1.1	Motivação . . . . .	15
1.2	Objetivos e Desafios da Pesquisa . . . . .	17
1.2.1	Objetivos Específicos . . . . .	17
1.3	Organização do Trabalho . . . . .	18
2	FUNDAMENTOS TEÓRICOS DO TRABALHO . . . . .	19
2.1	Visão geral . . . . .	19
2.2	Modelos de ruído . . . . .	19
2.2.1	Modelo de ruído aditivo . . . . .	20
2.2.2	Modelo de ruído Poisson . . . . .	20
2.3	<i>Variance-stabilizing Transformations (VSTs)</i> . . . . .	21
2.3.1	Transformada de Anscombe . . . . .	22
2.4	Distância Euclidiana . . . . .	23
2.5	Distância Estocástica . . . . .	23
2.6	Non-Local Means . . . . .	25
2.7	<i>Block Matching 3D (BM3D)</i> . . . . .	26
2.8	<i>Real Fluorescence Microscopy Images</i> . . . . .	31
3	TRABALHOS RELACIONADOS . . . . .	34
4	MATERIAIS E MÉTODOS . . . . .	38
4.1	Imagens <i>Fixed Zebrafish Embryo</i> . . . . .	38
4.2	Distâncias estocásticas para o ruído Poisson . . . . .	39
4.3	Modificação do algoritmo . . . . .	40
4.4	Medidas comparativas . . . . .	41
4.4.1	<i>Peak Signal-to-Noise Ratio (PSNR)</i> . . . . .	41

4.4.2	<i>Structural SIMilarity Index (SSIM)</i> . . . . .	42
4.5	<b>Resumo do método proposto</b> . . . . .	<b>42</b>
5	<b>RESULTADOS</b> . . . . .	<b>44</b>
5.1	<b>Parâmetros utilizados</b> . . . . .	<b>44</b>
5.2	<b>Experimentos com Fluorescência Imagens de Microscopia</b> . . .	<b>45</b>
	<b>Conclusão</b> . . . . .	<b>50</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>51</b>

---

# Capítulo 1

## Introdução

---

A obtenção de imagens digitais é um processo fundamental para diversos campos, como a fotografia, a medicina, a engenharia e a indústria. Esta técnica permite o registro visual de objetos físicos através do uso de sensores eletrônicos. No entanto, as imagens digitalizadas estão suscetíveis a uma série de fatores que podem afetar sua qualidade, como o ruído. Este fenômeno é característico de cada tipo de sensor, exigindo abordagens específicas para minimizá-lo e aprimorar a eficácia das aplicações. Com o avanço da tecnologia, as soluções para mitigar o ruído têm se tornado cada vez mais sofisticadas, o que contribui para o desenvolvimento de imagens digitais de alta qualidade.

A maioria dos algoritmos conhecidos pela literatura são tratados como AWGN; à vista disto, oferece uma facilidade na sua matemática, todavia, apresenta limitações na prática.(SALINA, 2007; BINDILATTI; MASCARENHAS, 2013).

A reconstrução tomográfica de imagens é uma técnica amplamente utilizada em diversas áreas, como medicina, engenharia e física, proporcionando informações tridimensionais precisas de um objeto. Entretanto, a exposição prolongada aos raios-x pode ser prejudicial à saúde humana devido à toxicidade da radiação torna-se, portanto, essencial a redução da exposição sob a radiação em procedimentos diagnósticos que utilizam raios-x, como a tomografia computadorizada e a radiografia.

Durante o processo de reconstrução, é comum a presença do ruído de Poisson, que surge devido à baixa contagem de fótons; e que pode, assim, afetar, significativamente, a qualidade da imagem reconstruída. Desta forma, compromete a visualização das estruturas anatômicas e reduz a precisão das informações obtidas. Por esta razão, a aplicação das técnicas adequadas de pós-processamento é fundamental para minimizar o ruído de Poisson e garantir a obtenção de uma reconstrução de alta qualidade.

Tais técnicas visam preservar a resolução e o contraste da imagem, aprimorando a

precisão e a confiabilidade da técnica de reconstrução tomográfica das imagens. Portanto, o estudo e o desenvolvimento dos métodos eficientes para lidar com o ruído de Poisson são essenciais para garantir uma reconstrução de alta qualidade e aumentar a aplicabilidade das referidas técnicas em diversas áreas.

São em grande número os autores das áreas, os quais têm apresentado diferentes técnicas, com o objetivo de reduzir a interferência do ruído Poisson em dados. Estas técnicas variam desde algoritmos com abordagens clássicas até transformadas mais avançadas que estão, atualmente, no estado da arte (RIBEIRO, 2010).

Avanços nas propostas em trabalhos científicos são de grande importância dentro do estado da arte. Um bom exemplo é o algoritmo *Block Matching 3D* (BM3D) (DABOV et al., 2007). O mesmo foi, inicialmente, proposto para remoção do *Additive White Gaussian Noise* (AWGN). Não obstante, em vista de sua ótima performance, foi utilizado em diversos outros ruídos, dentre eles, o Poisson. Esta técnica é baseada no método de filtragem não linear que utiliza um processo de correspondência de blocos (*Patches*) para remover o ruído de uma imagem. Tais *patches* semelhantes são agrupados e usados para estimar um bloco de origem. Desta maneira, ele funciona em duas etapas principais: a primeira é a *denoising* do bloco e a segunda é a agregação dos resultados de todos os blocos. Para o agrupamento, é utilizado a distância euclidiana, a fim de efetuar as comparações entre os blocos. Ainda assim, quando tratamos de ruídos estatísticos como o Poisson; não é possível uma boa qualidade na supressão devido a sua característica estocástica. Assim sendo, utiliza-se distâncias estocásticas como métrica de comparação.

Em nosso estudo, propomos a incorporação de distâncias estocásticas baseadas na distribuição gaussiana ao filtro BM3D original e o uso de uma transformada estabilizadora de variância para a redução de ruído de imagens Poisson-Gaussianas. Basicamente, as principais contribuições deste trabalho são duas: 1) melhorar o desempenho do filtro BM3D em relação a esse modelo de ruído misto, que pode ser observado em uma ampla gama de aplicações, como imagens de microscopia de fluorescência; 2) como o método proposto é um algoritmo de remoção de ruído de uma única imagem, ou seja, todas as informações necessárias para filtrar um pixel estão dentro da imagem observada, ele tem uma complexidade computacional reduzida em comparação com os métodos de aprendizagem profunda, que usam milhares de imagens para treinar as redes neurais.

## 1.1 Motivação

Como mencionado anteriormente neste capítulo, o ruído de Poisson é um fator significativo em várias áreas, o que levou ao desenvolvimento de diversos algoritmos para reduzi-lo. No entanto, a presença desse ruído pode prejudicar a interpretação e o processamento das informações contidas em uma imagem. Uma abordagem comumente utilizada para melhorar a relação sinal-ruído nas imagens é aumentar o tempo de exposição durante

a aquisição do sinal.

No entanto, o aumento do tempo de exposição traz consigo outros problemas. Por exemplo, em imageamento por raios-X, isso implica em expor o paciente a uma dose maior de radiação. Além disso, o movimento durante a exposição prolongada pode resultar em borramento na imagem (VONESCH et al., 2006). Estas são apenas algumas das considerações que devem ser levadas em conta ao lidar com o desafio do ruído de Poisson e encontrar um equilíbrio entre a qualidade da imagem e os possíveis efeitos indesejáveis.

Considerando que o aumento no tempo da aquisição pode não ser viável em algumas aplicações, a filtragem do ruído torna-se uma etapa de pós-processamento essencial. Algoritmos avançados, considerados como o estado da arte atual, têm demonstrado resultados excepcionais na redução de ruído, como é o caso do Poisson-NLM (DELEDALLE; TUPIN; DENIS, 2010), NL-Bayes (LEBRUN; BUADES; MOREL, 2013), *Dual Domain Image Denoising* (DDID) (KNAUS; ZWICKER, 2013), *Deep Convolutional Neural Networks* (DCNN) (ZHANG et al., 2017) e como mencionado anteriormente, o BM3D (DABOV et al., 2007).

Em 2009, um método inovador foi publicado na área de microscopia por fluorescência, focado na filtragem do ruído Poisson (BOULANGER et al., 2009). Esta técnica adota uma abordagem em duas etapas: De antemão, estabiliza a variância utilizando a VST Anscombe, eliminando a dependência entre a média e a variância dos valores de intensidade. Logo após, assumido que a imagem possui variância constante, reduz o ruído utilizando um novo modelo estatístico baseado em blocos similares. Esta metodologia é comum em outros trabalhos de filtros não-locais de destaque, como o conhecido algoritmo BM3D.

A Transformada de Anscombe é amplamente utilizada devido à sua eficácia na conversão dos ruídos dependentes do sinal, como o de Poisson e em ruídos independentes do sinal. Desta forma, uma imagem previamente afetada pelo ruído Poisson, no qual a variância do ruído depende da taxa média de fótons em cada região da imagem, converte-se independente do sinal. Esta técnica faz-se bastante prática, pois dispensa a necessidade de adaptar algoritmos para diferentes tipos de ruído; o que a torna uma área de pesquisa amplamente adotada por diversos autores no estado da arte. Inúmeros trabalhos apresentam VSTs inversas exatas e imparciais, inclusive para o ruído Poisson de baixa contagem (MAKITALO; FOI, 2009; MAKITALO; FOI, 2010; MAKITALO; FOI, 2011; MAKITALO; FOI, 2012a; MAKITALO; FOI, 2012b).

O presente estudo foi motivado pela pesquisa conduzida por (TARDIVO, 2021), que investigou a aplicação da técnica de filtragem *Non Local Means* (NLM) (LEBRUN; BUADES; MOREL, 2013) antes da utilização do filtro BM3D.

Este estudo foi motivado pela pesquisa de (TARDIVO, 2021), que explorou o uso de técnicas de filtragem, como o NLM (LEBRUN; BUADES; MOREL, 2013), antes da aplicação do filtro BM3D para redução de ruído. Inspirados por esse trabalho, utiliza-

mos imagens de microscopia de fluorescência confocal de embriões de zebrafish, conforme documentado por (ZHANG et al., 2019), que criaram um conjunto de dados de remoção de ruído de microscopia de fluorescência (*Fluorescence Microscopy - Noise Removal Dataset*, FMD), especificamente para remoção de ruído Poisson-Gaussiano em imagens de microscopia de fluorescência. A microscopia de fluorescência, especialmente na modalidade confocal, é fundamental na biomedicina, mas enfrenta desafios com altos níveis de ruído devido à baixa captura de fótons. Embora o aumento da potência do laser ou do tempo de exposição possa reduzir o ruído, essas soluções têm limitações práticas e biológicas.

## 1.2 Objetivos e Desafios da Pesquisa

A investigação em questão visa aprimorar o avanço dos estudos sobre a aplicação do BM3D em imagens de microscopia de fluorescência confocal de embriões de zebrafish dotadas ruído Poisson-Gaussiano, através da substituição da métrica euclidiana pelas distâncias estocásticas e da utilização das VSTs.

### 1.2.1 Objetivos Específicos

Tomando por base no objetivo geral estabelecido, os seguintes, específicos são apresentados nesta pesquisa:

- a) Adaptar a aplicação da redução de ruído Gaussiano Aditivo do BM3D para torná-la compatível com o ruído Poisson, utilizando técnicas de VSTs;
- b) Apresentar e descrever as quatro distâncias estocásticas estimadas para o ruído Poisson e demonstrar como aplicá-las no lugar da distância euclidiana original do BM3D;
- c) Comparar a efetividade das distâncias estocásticas entre si por meio de experimentos, avaliando a sua capacidade de medir a similaridade entre os blocos de imagens contaminadas pelo ruído Poisson;
- d) Avaliar a eficácia das distâncias estocásticas aplicadas ao BM3D em relação a outros algoritmos de supressão de ruído, tanto com o uso das VSTs quanto sem utilizá-las, por meio de métricas de desempenho, como a melhoria no PSNR, SSIM e a preservação de detalhes da imagem;
- e) Apresentar dados comparativos que evidenciem a superioridade do BM3D adaptado com distâncias estocásticas em relação aos demais algoritmos de redução de ruído testados, fornecendo uma análise abrangente de sua efetividade no contexto de imagens contaminadas por ruído Poisson;

- f) Contribuir para o avanço dos estudos sobre redução de ruído Poisson, facultando uma abordagem aprimorada do BM3D e das distâncias estocásticas, bem como uma avaliação comparativa com outros algoritmos; o que poderá resultar em aplicações mais eficazes de supressão de ruído em imagens contaminadas pelo ruído Poisson;
- g) Demonstrar a importância das VSTs como etapa preliminar para a redução de ruído Poisson. Deixa, desta maneira, em evidência seu papel na melhoria do desempenho do BM3D adaptado;
- h) Aplicar o trabalho em imagens de Microscopia de Fluorescência, o qual tem uma importância significativa no meio da biologia moderna;

### 1.3 Organização do Trabalho

A estrutura deste projeto de qualificação é organizada da seguinte maneira:

- O Capítulo 2 oferece uma base teórica sólida para embasar a pesquisa proposta.
- No Capítulo 3, são apresentados os trabalhos relacionados que serviram como referência bibliográfica para esta qualificação.
- No Capítulo 4, a proposta de pesquisa é detalhada minuciosamente e validada neste estudo.
- O Capítulo 5 aborda os experimentos realizados e a discussão dos resultados obtidos.
- Por fim, apresentamos as conclusões deste trabalho.

---

## Capítulo 2

# Fundamentos Teóricos Do Trabalho

---

### 2.1 Visão geral

Neste capítulo, apresentaremos os fundamentos teóricos que sustentam a pesquisa desenvolvida neste trabalho. Abordaremos as teorias, conceitos e modelos que servem como base para a compreensão do problema de pesquisa e a análise dos resultados.

### 2.2 Modelos de ruído

O ruído aleatório é um fenômeno estocástico, cujas características dependem do processo físico utilizado para a obtenção do sinal mensurado. Devido à complexidade potencial do processo de aquisição e formação de imagens, bem como à diversidade de técnicas de imageamento existentes, modelos teóricos de ruído são propostos para facilitar a formulação e o estudo de soluções para a redução de ruído. Embora esses modelos sejam simplificações de processos mais complexos, na prática, se mostram extremamente úteis e poderosos. Além de que, fornecem uma base teórica sólida e uma abordagem sistemática para o desenvolvimento de algoritmos de redução de ruído; permitindo uma compreensão mais profunda do problema e o desenvolvimento de técnicas eficazes para melhorar a qualidade das imagens afetadas pelo ruído.

O modelo mais amplamente conhecido é o AWGN. No entanto, em aplicações nas quais a imagem resultante é obtida por meio de um processo de contagem, o modelo de ruído Poisson é uma aproximação mais realista. Ainda assim, muitos algoritmos são formulados sob a hipótese do modelo AWGN (LEBRUN; BUADES; MOREL, 2013). Tal fato se dá devido ao uso das VSTs; o ruído Poisson passa assim, a se comportar de forma aproximada como AWGN. A referida abordagem é adotada devido à simplicidade e tratabilidade

matemática do modelo AWGN, que facilita a formulação teórica de algoritmos de redução de ruído. Ao utilizar as VSTs, é possível transformar o ruído Poisson em um ruído aditivo gaussiano branco, permitindo o uso de técnicas desenvolvidas para o modelo AWGN, na redução de ruído em imagens com ruído Poisson.

### 2.2.1 Modelo de ruído aditivo

No contexto do modelo AWGN, o ruído presente em cada pixel da imagem é modelado como uma realização de uma variável aleatória,  $z$ , que segue uma distribuição Gaussiana com média zero e variância arbitrária. O ruído em questão é, então, adicionado ao valor original do pixel; resultando no valor observado  $y_i$  para uma determinada coordenada  $i$ ,

$$y_i = x_i + z_i, \quad (2.1)$$

em que  $x_i$  é o valor do pixel livre de ruído e o  $z_i \sim \mathcal{N}(0, \sigma^2)$  é uma variável aleatória que segue uma distribuição normal (gaussiana), com média zero e variância  $\sigma^2$  e função de densidade de probabilidade definida pela equação:

$$f(z_i|0, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(z_i)^2}{2\sigma^2}\right) \quad (2.2)$$

Em suma, pode-se considerar que o valor observado  $Y$  corresponde a uma realização de um campo aleatório Gaussiano. Além disso, assume-se que as variáveis aleatórias  $\{z_i\}_{i \in I}$  não possuem correlação com o sinal e são independentes entre si. Em outras palavras, para todo par de índices  $i \neq j$ , a variável aleatória  $z_i$  é estatisticamente apartada da variável aleatória  $z_j$ .

Ademais, é importante ressaltar que, quanto maior for a variância do ruído, maior será a degradação do sinal observado. A relação direta entre a variância do ruído e a qualidade da imagem capturada é um aspecto crucial a ser considerado na análise de sistemas de redução de ruído. O modelo AWGN se destaca pela sua simplicidade e tratamento matemático, ocorrência que o torna altamente oportuno na formulação teórica de algoritmos para a redução de ruído. Destarte, sua abordagem matematicamente tractável permite o desenvolvimento de técnicas eficazes e eficientes para melhorar a qualidade das imagens afetadas pelo ruído; sendo amplamente explorada na área de processamento de imagens.

### 2.2.2 Modelo de ruído Poisson

A distribuição de probabilidade do ruído Poisson, desenvolvida originalmente por Simeon Denis Poisson, é fundamentada em uma variável aleatória que determina a probabilidade de eventos ocorrerem durante um intervalo de tempo específico. A adaptação e explanação dessa distribuição são discutidas no estudo de (FRERY; NASCIMENTO; CINTRA, 2010), como:

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

Na distribuição de probabilidade do ruído Poisson, o parâmetro  $\lambda$  representa a taxa média esperada de ocorrências, durante um determinado período de tempo; como o número médio de fótons em imagens. A variável  $x$  denota um valor inteiro que indica a quantidade exata de ocorrências observadas. Assim sendo, a função de probabilidade  $P(x; \lambda)$  calcula a probabilidade de ocorrerem exatamente  $x$  ocorrências com a taxa média  $\lambda$ . A base do logaritmo natural, representada por  $e$ , desempenha um papel fundamental nos cálculos e na modelagem matemática da distribuição de probabilidade do ruído Poisson.

A distribuição Poisson, apresenta propriedades distintas em relação ao modelo de AWGN. Conforme estabelecido por (ROSS, 2014), em seu trabalho introdutório, no ruído Poisson; a variância está relacionada diretamente à taxa média de fótons que chegam em cada célula de um arranjo de sensores. Esta característica peculiar torna o ruído Poisson dependente do sinal, pois a variância alterna conforme a intensidade do sinal capturado. Em contrapartida, o modelo AWGN mantém uma variância constante, independentemente do sinal.

## 2.3 Variance-stabilizing Transformations (VSTs)

As transformações de estabilização de variância, VSTs inglês, são técnicas usadas em estatística para lidar com dados que possuem heterocedasticidade, ou seja, quando a variância dos erros não é constante em todas as condições. Tais transformações são aplicadas aos dados originais, de forma a tornar a relação entre a média e a variância mais linear.

Quando os dados apresentam heterocedasticidade, é difícil aplicar análises estatísticas e fazer inferências precisas, pois a variância inconsistente pode distorcer os resultados. Por conseguinte, as transformações de estabilização de variância são usadas para lidar com o referido problema; ajustando os dados de forma a obter uma relação mais estável entre a média e a variância.

Há várias técnicas de VSTs disponíveis, as quais dependem da distribuição dos dados. Algumas das transformações comumente utilizadas, incluem a transformação logarítmica, a raiz quadrada, a transformação de arco-seno e a transformação de Anscombe, dentre outras.

As citadas transformações ajudam a reduzir a heterocedasticidade, o que torna a variância dos dados mais constante e melhora a qualidade das análises estatísticas. Outrossim, em muitos casos, elas também podem aproximar a composição dos dados para uma distribuição mais normal, o que é desejável em várias técnicas estatísticas. E, na presente laboração vamos trabalhar com a Transformada de Anscombe.

### 2.3.1 Transformada de Anscombe

No campo da transformada de Anscombe, é possível realizar uma aproximação de uma variável aleatória, a qual segue uma distribuição Poisson, através de uma variável aleatória que predispõe uma distribuição Gaussiana com variância unitária. A mencionada aproximação possibilita a utilização de algoritmos, originalmente formulados para o modelo de AWGN. A transformada de Anscombe é uma técnica empregada para realizar a modificação, e é definida pela seguinte expressão (ANSCOMBE, 1948):

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

A transformada de Anscombe é dada pela expressão em que  $y$  é uma variável aleatória Poisson e  $z$  pode ser considerada como uma variável aleatória normal com variância, perto de unitária.

No domínio de Anscombe, a variância do ruído é aproximadamente constante em todas as regiões da imagem, o que permite a aplicação de algoritmos formulados sob a hipótese de ruído aditivo para redução de ruído. Após o processo de atenuação do ruído é necessário aplicar uma transformada inversa, para que os dados retornem à sua representação original. A inversa algébrica de Anscombe pode ser calculada usando a seguinte equação:

$$y = \left(\frac{z}{2}\right)^2 - \frac{3}{8} \quad (2.5)$$

Devido ao fato de que nenhum algoritmo conhecido para redução de ruído é ideal, ou seja, nenhum algoritmo conhecido remove efetivamente a presença de ruído a ponto de recuperar exatamente o sinal livre de ruído. Além de que, devido à não-linearidade da transformada de Anscombe, a aplicação da Equação 2.5 como transformada inversa, introduz um viés. No entanto, para imagens obtidas com altas contagens de fótons, a transformada inversa assintoticamente não enviesada de Anscombe (ANSCOMBE, 1948), pode ser utilizada a Equação 2.6.

$$y = \left(\frac{z}{2}\right)^2 - \frac{1}{8} \quad (2.6)$$

A inversa descrita pela Equação 2.6 não apresenta viés para regiões da imagem com alta incidência de fótons. Para lidar com locais que possuem taxas de contagem abaixo de 20 fótons; (MAKITALO; FOI, 2011) propuseram uma transformada inversa exata, *Generalized Anscombe Transformation* (GAT), otimizada especificamente para imagens obtidas em regimes de baixa contagem de fótons, definida pela Equação 2.7:

$$y = \left(\frac{z}{2}\right)^2 + \frac{1}{4}\sqrt{\frac{3}{2}}z^{-1} - \frac{11}{8}z^{-2} + \frac{5}{8}\sqrt{\frac{3}{2}}z^{-3} - \frac{1}{8} \quad (2.7)$$

## 2.4 Distância Euclidiana

A distância euclidiana é um cálculo utilizado para medir a longitude entre dois pontos em um espaço euclidiano de dimensão finita. Devido à sua simplicidade e interpretação geométrica intuitiva, a supracitada métrica é amplamente utilizada na literatura em várias áreas aplicáveis da estatística. Para mais, a distância euclidiana é obtida através do teorema de Pitágoras, que consiste na raiz quadrada da soma dos quadrados das diferenças entre as coordenadas dos pontos. De mais a mais, a propriedade de simetria permite que a ordem dos pontos não afete o resultado final.

Formalmente, consideremos dois pontos  $\mathbf{x} = (x_1, x_2, \dots, x_n)$  e  $\mathbf{y} = (y_1, y_2, \dots, y_n)$  em um espaço euclidiano  $n$ -dimensional. A distância Euclidiana entre estes dois pontos é definida como a raiz quadrada da soma dos quadrados das diferenças entre suas coordenadas:

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n (y_i - x_i)^2} \quad (2.8)$$

A medida de distância euclidiana possui várias propriedades importantes. Primeiramente, é sempre não negativa, ou seja,  $d(\mathbf{x}, \mathbf{y}) \geq 0$  para quaisquer pontos  $\mathbf{x}$  e  $\mathbf{y}$ . Além de que, a distância euclidiana é simétrica, o que significa que  $d(\mathbf{x}, \mathbf{y}) = d(\mathbf{y}, \mathbf{x})$ . Ela também satisfaz a desigualdade triangular, que estabelece que a distância direta entre dois pontos é sempre menor ou igual à soma das distâncias, através de um terceiro ponto. As propriedades relatadas, tornam a distância euclidiana uma medida confiável e largamente utilizada em diversas aplicações. Nas filtragens de imagens a sua utilização é essencial, algoritmos avançados como NLM, K-means (MCQUEEN, 1967) e BM3D, detalhado na seção 2.7, empregam a distância Euclidiana como medida de comparação entre os patches, demonstra, portanto, ser uma abordagem eficaz.

## 2.5 Distância Estocástica

As distâncias estocásticas, de modo divergente da distância euclidiana, não se sujeitam a todas as regras formais que constitui o espaço métrico, sendo elas (SANTOS; MARTINS; MASCARENHAS, 2017):

1.  $d(x, y) > 0$  para  $x \neq y$  (Não-Negatividade)
2.  $d(x, y) = 0$  para  $x = y$  (Definitividade)
3.  $d(x, y) = d(y, x)$  (Simetria)
4.  $d(x, y) + d(y, z) \geq d(x, z)$  (Desigualdade Triangular)

Uma métrica é definida como uma medida de distância que satisfaz as regras do Item 1 ao Item 4, no entanto, é importante ressaltar que esta regra formal não é universal para todas as distâncias estatísticas baseadas em distribuições de probabilidade. O conceito de distâncias estocásticas tem sua origem na concepção de medidas de divergência (PARDO, 2018). Estas medidas são coeficientes que possuem a propriedade de aumentar à medida que a discrepância entre duas distribuições aumenta; o que acaba sendo uma propriedade importante para a comparação de variáveis aleatórias. Tais coeficientes, em geral, não possuem a propriedade de simetria e, logo, não são essencialmente métricas de distância. Quando essas medidas são modificadas para se tornarem simétricas, suas versões são chamadas de distâncias estocásticas (NASCIMENTO; CINTRA; FRERY, 2009). As divergências são calculadas através da seguinte fórmula:

$$D_{\phi}^h(x, y) = h \left( \int_I \phi \left( \frac{f_X(x; \theta_1)}{f_Y(x; \theta_2)} \right) f_Y(x; \theta_2) dx \right), \quad (2.9)$$

em que,  $\phi : (0, \infty) \rightarrow [0, \infty)$  é uma função convexa,  $h : (0, \infty) \rightarrow [0, \infty)$  é uma função estritamente crescente com  $h(0) = 0$ , e formas indeterminadas são atribuídas o valor zero.

Como mencionado, por meio da Equação 2.9 é possível obter expressões para distâncias entre distribuições de probabilidade denominadas distâncias estocásticas ou simplesmente distâncias. Uma distância estocástica é uma divergência que, além de satisfazer as propriedades de não negatividade e definitividade, satisfaz a propriedade de simetria. Assim, se considerarmos um cálculo de divergência  $d(x, y)$ , sua forma simétrica é dada de acordo com:

$$d_{\phi}^h(x, y) = \frac{D_{\phi}^h(x, y) + D_{\phi}^h(y, x)}{2} \quad (2.10)$$

A utilização de distâncias estocásticas representa uma ampliação significativa do escopo de possibilidades no estado da arte; permitindo que pesquisas explorem resultados além da tradicional distância Euclidiana. Ao adotar distâncias estocásticas, os estudos podem explorar novas abordagens e considerar diferentes aspectos das distribuições, o que pode resultar em avanços significativos em diversas áreas, como processamento de imagens, reconhecimento de padrões e análise de dados. Isso se dá ao fato das distâncias estocásticas considerar características intrínsecas das distribuições dos dados, como assimetria, dispersão e variações locais, tornando-as mais adequadas para cenários complexos. Essa flexibilidade é particularmente relevante em aplicações que envolvem ruído não aditivo ou padrões altamente heterogêneos. A demonstrada abordagem amplia as opções disponíveis para a análise e comparação de variáveis aleatórias, proporcionando uma compreensão mais completa e abrangente dos dados. Também, seu uso em abordagens de filtragem para ruído Poisson (BINDILATTI, 2018) e Speckle (SANTOS, 2017; PENNA, 2018) demonstrou resultados promissores, destacando o potencial das distâncias estocásticas como ferramentas eficazes no processamento de sinais e imagens.

Na seção 4.2, foi fornecido um amplo panorama das distâncias estocásticas utilizadas e da maneira como foram aplicadas. Na seção citada, discutimos as diversas medidas de distância estocástica empregadas, além de realizar uma análise das mesmas no contexto em específico.

## 2.6 Non-Local Means

O método Non-Local Means (NLM), introduzido por (BUADES; COLL; MOREL, 2005), é uma técnica de redução de ruído inovadora, amplamente utilizada em processamento de imagens, especialmente na remoção de ruídos de textura em imagens fotográficas e biomédicas. Ao contrário dos métodos tradicionais de filtragem, como o filtro de média e o filtro gaussiano, o NLM considera informações de regiões semelhantes em toda a imagem, não apenas em um entorno local. Esse método busca preservar detalhes finos, como bordas e texturas, enquanto reduz o ruído de maneira eficiente.

O conceito central do NLM é que, em uma imagem, existem muitas regiões que apresentam padrões semelhantes, mesmo que estejam fisicamente distantes. O método faz uso dessas similaridades, aplicando uma média ponderada dos pixels que apresentam alta semelhança com o pixel alvo. Essa abordagem "não local" permite preservar melhor as texturas e detalhes, pois considera a estrutura global da imagem.

A ideia principal do algoritmo NLM pode ser descrita pela seguinte fórmula:

$$\hat{u}(i) = \sum_{j \in \Omega} w(i, j) \cdot u(j) \quad (2.11)$$

onde:

- $\hat{u}(i)$  representa o valor estimado do pixel  $i$  após o processo de redução de ruído.
- $u(j)$  é o valor do pixel  $j$  na imagem original ruidosa.
- $\Omega$  é a vizinhança de pesquisa que abrange todos os pixels da imagem que podem contribuir para a estimativa do pixel  $i$ .
- $w(i, j)$  é o peso que mede a similaridade entre o pixel  $i$  e o pixel  $j$ .

Os pesos  $w(i, j)$  são definidos como:

$$w(i, j) = \frac{1}{Z(i)} \exp\left(-\frac{\|u(P_i) - u(P_j)\|^2}{h^2}\right) \quad (2.12)$$

onde:


- $u(P_i)$  e  $u(P_j)$  representam os vetores de intensidade dos blocos de pixels ao redor de  $i$  e  $j$ , respectivamente.

- $h$  é um parâmetro que controla o grau de filtragem (quanto maior  $h$ , maior a suavização).
- $Z(i)$  é um fator de normalização, garantindo que a soma dos pesos  $w(i, j)$  seja igual a 1 para cada pixel  $i$ .

## 2.7 *Block Matching 3D* (BM3D)


A técnica conhecida como *Block Matching 3D* (BM3D) (DABOV et al., 2007) é amplamente reconhecida na filtragem de imagens afetadas por ruído aditivo gaussiano. É uma abordagem não-local que utiliza um bloco tridimensional para agrupar blocos similares da imagem. Para encontrar esses blocos similares, a busca compara pequenos fragmentos de tamanho igual em toda a imagem ruidosa. Isso é ilustrado nas Figura 2.1 e Figura 2.2, resultando em vários agrupamentos que são utilizados no processo de filtragem do algoritmo.

Figura 2.1 – Exemplo de agrupamento dos blocos de imagens contaminadas com AWGN. R é o bloco referenciado



Fonte: (DABOV et al., 2007)

Figura 2.2 – Exemplo de agrupamento com blocos perfeitamente idênticos

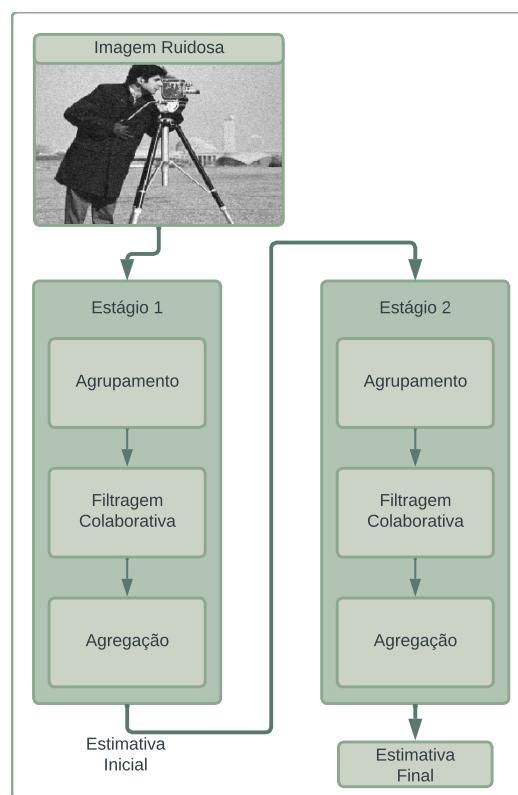


Fonte: (DABOV et al., 2007)

O algoritmo BM3D é composto por dois estágios principais: estimativa básica, nos quais os coeficientes wavelets são atenuados usando a técnica de hard-thresholding; e estimativa final, os coeficientes wavelets são atenuados usando o filtro de Wiener. No estágio

de estimativa básica, os patches da imagem são agrupados com base em sua similaridade, que é determinada pela distância Euclidiana entre os patches ruidosos. Nesse estágio, são identificados grupos de patches semelhantes em termos de conteúdo e características. Já, na etapa de estimativa final, a imagem pré-estimada obtida na etapa anterior é usada como um guia para um agrupamento mais preciso de patches e também como informação a priori para calcular o filtro de Wiener. A imagem pré-estimada serve como uma referência para refinar ainda mais a filtragem, melhora, assim, a qualidade final da imagem resultante. Ambos os estágios consistem em três etapas fundamentais, conforme ilustrado de forma simplificada na Figura 2.3: Agrupamento, filtragem colaborativa e agregação.

Figura 2.3 – Fluxograma do funcionamento do algoritmo BM3D



Fonte: O Autor

A etapa do Agrupamento tem como objetivo principal identificar blocos similares na imagem ruidosa e agrupá-los para posterior processamento, como foi dito anteriormente. Para realizar o agrupamento, a imagem ruidosa é dividida em blocos não sobrepostos de tamanho fixo. Por conseguinte, o algoritmo percorre a imagem ruidosa e seleciona um bloco de referência. Em seguida, ele compara pequenos fragmentos do bloco em questão, com fragmentos de outros, na vizinhança. Assim sendo, é encontrado os blocos mais semelhantes em termos de padrões e texturas. A similaridade entre os blocos é medida através do uso de uma métrica, a distância euclidiana, a qual é ponderada pelo tamanho dos patches:

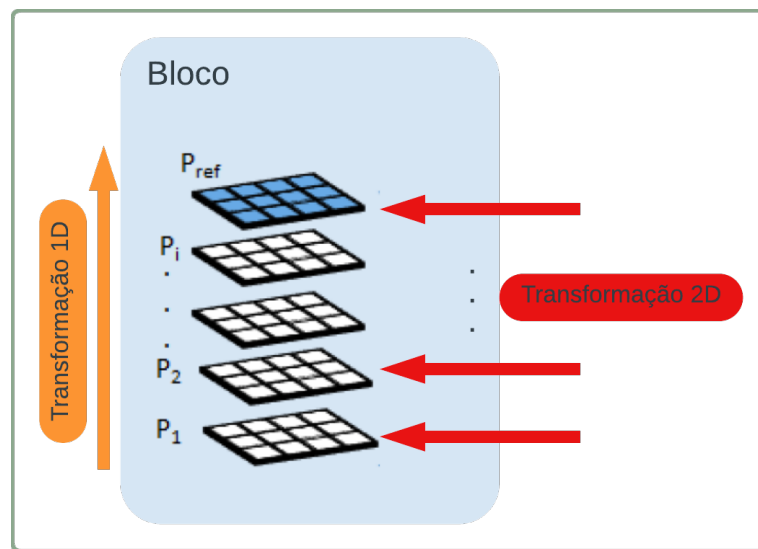
$$d(P_{ref}, P_i) = \frac{\|P_{ref} - P_i\|^2}{k^2}, \quad (2.13)$$

sendo que  $\|P_{ref} - P_i\|$  pode ser calculado como dado na Equação 2.8 na seção 2.4.

Os autores também especificam, no algoritmo, um limiar  $\tau$  a partir do qual, dois patches são considerados similares. Assim, um patch somente é empilhado no bloco de patches similares se  $d(P_{ref}, P_i) \leq \tau$ , processo demonstrado na Figura 2.2.

A próxima etapa, filtragem colaborativa é o procedimento desenvolvido pelos autores para tratar dos blocos 3D, construídos na etapa anterior, que consiste, basicamente, de uma transformação esparsa seguida de uma limiarização de coeficientes e da transformação inversa.

Figura 2.4 – Transformação 3D em bloco de patches



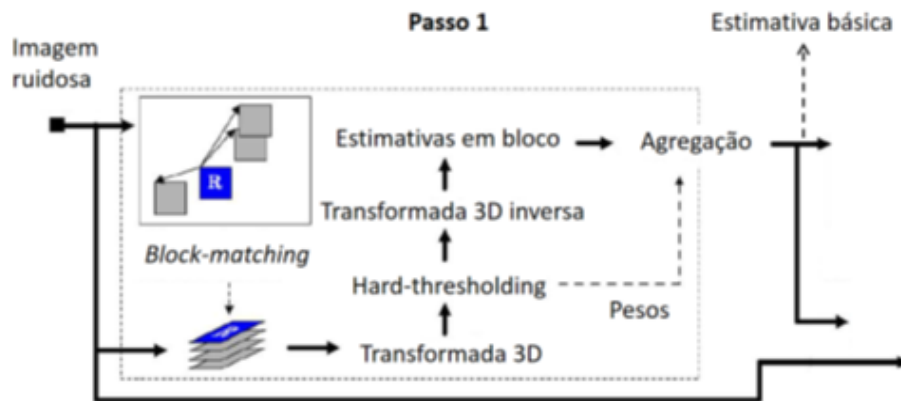
Fonte: O Autor

Os autores nomeiam a transformada esparsa de transformada esparsa 3D, pois consiste em uma transformação esparsa 2D aplicada em cada um dos patches do bloco e uma transformação esparsa 1D aplicada na terceira dimensão, como mostrado na Figura 2.4. Escolhas comuns para as transformações são as transformadas *wavelet* e *Discrete Cosine Transform* (DCT). Em (LEBRUN, 2012), se utilizam as transformadas *wavelet* biortogonal ou DCT como transformada 2D, e DCT ou a transformada de Walsh-Hadamard como transformada 1D.

Essa abordagem de filtragem colaborativa tem como objetivo explorar, de forma conjunta, tanto a correlação intra-patches resultante da suavidade presente em imagens naturais, quanto a correlação inter-patches resultante da autosimilaridade também encontrada em imagens naturais. No primeiro passo do algoritmo BM3D, a filtragem colaborativa consiste em uma limiarização dos coeficientes das transformadas, sendo o limiar determinado por um parâmetro específico do algoritmo.

Após a aplicação da filtragem colaborativa, em um bloco 3D, obtemos uma estimativa para cada patch e um número variável de estimativas para cada *pixel*. O processo de agregação consiste em combinar todas as estimativas de um *pixel* para formar sua estimativa final. Tal combinação é realizada por meio de uma soma ponderada de todas as estimativas do *pixel*, atribuindo-se maior peso às estimativas provenientes de áreas homogêneas da imagem. Para tanto, utiliza-se como peso o inverso do número de coeficientes não nulos presentes no bloco 3D, a qual a estimativa pertence. Vale ressaltar que, o número de coeficientes é obtido após a limiarização. Desta forma, podemos representar este primeiro passo resumidamente na Figura 2.5. A segunda parte do algoritmo, como foi mostrado na Figura 2.3, os processos gerais são:

Figura 2.5 – Diagrama representativo da estimativa básica do algoritmo BM3D



Fonte: Traduzido de (DABOV et al., 2007)

os mesmos, diferenciam-se em algumas coisas.

No segundo passo do algoritmo, o agrupamento é realizado de maneira semelhante ao primeiro, mas desta vez, os grupos 3D são formados utilizando-se da estimativa inicial obtida no passo 1. Com base na organização dos grupos 3D da estimativa inicial, a imagem ruidosa também é dividida em grupos, seguindo a mesma organização. Como resultado do processo de agrupamento no segundo passo, são gerados dois conjuntos de grupos de blocos 3D.

O primeiro conjunto é formado pelo agrupamento dos patches semelhantes da estimativa inicial, enquanto que, o segundo conjunto possui a mesma organização e é formado pelos blocos correspondentes da imagem ruidosa. A referida abordagem de agrupamento nos dois conjuntos permite a criação de grupos 3D, que representam regiões semelhantes, tanto na estimativa inicial, quanto na imagem ruidosa.

Na filtragem colaborativa do segundo passo, os dois conjuntos de grupos de blocos, obtidos na etapa anterior, passam por uma transformação 3D; seguindo o mesmo procedimento explicado no primeiro passo do algoritmo. A partir da transformada do grupo de blocos 3D extraídos da estimativa inicial, são gerados os coeficientes utilizados para

a filtragem de Wiener na transformada do grupo de blocos 3D extraídos da imagem ruidosa. Posteriormente, é aplicada a transformação inversa, a fim de obter a entrada, para a próxima etapa do processo.

A determinação dos coeficientes do filtro de Wiener ocorre por meio de uma abordagem empírica, baseada na relação

$$c_w(y) = \frac{T_{3D}(y)^2}{T_{3D}(y)^2 + \sigma^2}, \quad (2.14)$$

em que,  $T_{3D}(y)$  significa o valor da transformada na posição  $y$  do bloco tridimensional e  $\sigma^2$  é um parâmetro do filtro, representando a variância do ruído.

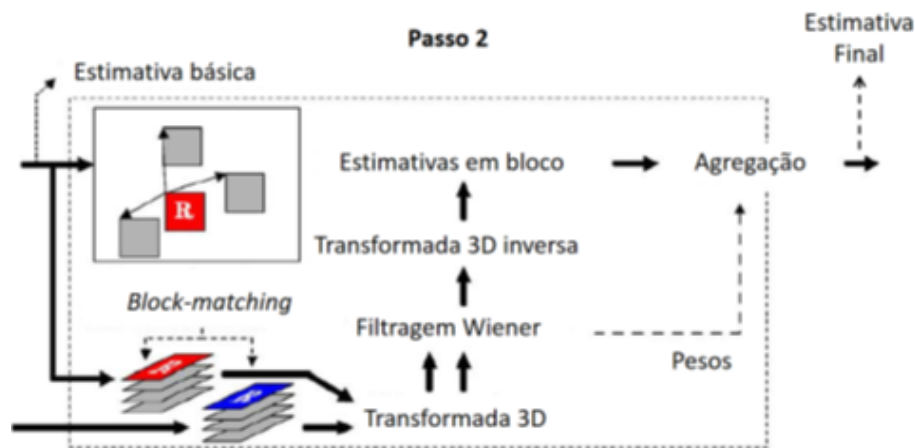
Ao calcular os coeficientes do filtro de Wiener para cada posição do bloco 3D, obtemos uma estrutura com as mesmas dimensões. Permite assim, a realização da filtragem de Wiener através da multiplicação de elemento por elemento entre a transformada do bloco 3D da imagem ruidosa e o bloco 3D contendo os coeficientes.

A fase de agregação é realizada como no passo anterior, cujo bloco 3D filtrado, correspondente à imagem ruidosa, e, é utilizado como entrada. No entanto, há uma exceção em relação aos pesos da soma ponderada, que são determinados como função do coeficiente do filtro de Wiener:

$$w = |c_w|^{-2} \quad (2.15)$$

Deste modo, podemos resumir o segundo passo conforme ilustrado na Figura 2.6.

Figura 2.6 – Diagrama representativo da estimativa final do algoritmo BM3D




Fonte: Traduzido de (DABOV et al., 2007)

## 2.8 *Real Fluorescence Microscopy Images*

A microscopia de fluorescência é uma técnica essencial na pesquisa biomédica moderna, amplamente utilizada para investigar estruturas celulares, compartimentos subcelulares e moléculas específicas, como proteínas. Essa técnica baseia-se na utilização de agentes fluorescentes que emitem luz ao serem excitados por um comprimento de onda específico, permitindo a visualização e análise detalhada de células e tecidos com resolução microscópica. A fluorescência ocorre quando uma substância absorve energia luminosa em um comprimento de onda e, em seguida, a reemite em um comprimento de onda maior. Esse fenômeno é conhecido como Stokes shift, e resulta da perda de energia durante a transição dos elétrons do material fluorescente para um estado de maior energia, antes de retornarem ao estado fundamental, liberando a energia na forma de luz visível.

Os microscópios de fluorescência são projetados para maximizar o aproveitamento desse fenômeno, sendo semelhantes aos microscópios ópticos convencionais, mas com sistemas adicionais de filtros para separar a luz de excitação da luz emitida pela amostra. A luz incidente passa por um filtro de excitação, que seleciona os comprimentos de onda adequados para excitar o fluoróforo, antes de atingir a amostra. Após a interação com a amostra, a luz fluorescente emitida é filtrada por um filtro de emissão, garantindo que apenas a luz emitida pela amostra seja detectada pelo sensor ou ocular do microscópio. Para melhorar a eficiência de separação da luz de excitação e da luz de emissão, é frequentemente utilizado um espelho dicróico, que reflete a luz de excitação enquanto permite a passagem da luz emitida, proporcionando uma análise mais precisa.

Figura 2.7 – Imagem exemplo de microscopia de fluorescência



Fonte: (ZHANG et al., 2019)

Embora a microscopia de fluorescência seja fundamental para a biologia moderna, as imagens geradas por essa técnica apresentam desafios significativos para a análise quantitativa. O ruído, especialmente devido à fraca intensidade do sinal óptico capturado pelos detectores, como tubos fotomultiplicadores (PMTs) ou câmeras de dispositivos acoplados de carga (CCD), é um problema comum. Esses detectores capturam cerca de 102 fótons por pixel, em comparação com os 105 fótons por pixel tipicamente registrados em câmeras fotográficas convencionais. Esse sinal fraco resulta em quantização da imagem, ou seja, discretização do sinal devido à natureza dos fótons, originando o ruído de Poisson. Esse tipo de ruído é mais prevalente na microscopia de fluorescência do que o ruído gaussiano, que é típico de câmeras fotográficas comuns.

Uma das abordagens para mitigar o ruído nas imagens de fluorescência é aumentar a potência do laser de excitação ou a intensidade da luz da lâmpada. Embora essa estratégia possa aumentar a quantidade de fótons capturados, ela apresenta limitações biológicas. A intensidade de luz excessiva pode causar danos à amostra biológica e, além disso, o aumento da potência pode resultar em saturação do sinal de fluorescência, sem aumento significativo na emissão de luz após um certo ponto. Outra alternativa seria prolongar o tempo de aquisição das imagens, aumentando o tempo de exposição, o tempo de permanência dos pixels ou o número de médias de linha ou quadro. Contudo, essa abordagem também é limitada, pois pode causar fotodano nas amostras. Em experimentos dinâmicos ou de imagem em tempo real, aumentar o tempo de aquisição pode ser inviável, já que as imagens precisam ser adquiridas em uma janela de tempo extremamente curta, frequentemente da ordem de milissegundos.

Para superar essas limitações, uma solução promissora reside no desenvolvimento de algoritmos avançados de denoising, capazes de reduzir eficazmente o ruído nas imagens de fluorescência sem comprometer a qualidade da informação. O uso desses algoritmos é crucial para melhorar a clareza das imagens e permitir uma análise quantitativa mais precisa. Contudo, um desafio significativo para o avanço desses algoritmos é a escassez de conjuntos de dados reais que considerem o ruído de Poisson predominante nas imagens de microscopia de fluorescência. A maioria dos algoritmos e conjuntos de dados existentes foi desenvolvida para imagens dominadas por ruído gaussiano, comuns em câmeras fotográficas, smartphones e câmeras DSLR.

No trabalho de (ZHANG et al., 2019), foi introduzido o conjunto de dados Fluorescence Microscopy Denoising (FMD), composto por 12.000 imagens reais de microscopia de fluorescência ruidosas. Este conjunto abrange as três modalidades de microscopia de fluorescência mais utilizadas — confocal, de dois fótons e de campo largo — e inclui três tipos representativos de amostras biológicas: células, zebrafish e tecidos cerebrais de camundongos. As imagens de referência (ground truth) e as imagens ruidosas, com diferentes níveis de ruído, foram obtidas por meio de um processo de média de imagens, que se demonstrou eficaz na criação de dados com alta fidelidade.

O conjunto FMD oferece uma plataforma valiosa para a avaliação de algoritmos clássicos de denoising, bem como para modelos de deep learning, permitindo a comparação do desempenho dessas técnicas em cenários de redução de ruído, tanto com quanto sem o uso de imagens de referência. Dado seu grande valor para a pesquisa em redução de ruído em imagens de microscopia de fluorescência, o conjunto de dados FMD foi utilizado neste trabalho.

---

## Capítulo 3

# Trabalhos Relacionados

---

No presente capítulo, apresentamos uma revisão abrangente da literatura relacionada ao escopo desta pesquisa de mestrado. Nosso objetivo é analisar o estado da arte no que diz respeito às estratégias empregadas para mitigar o ruído em imagens, com ênfase especial no tratamento do ruído de Poisson. Essa revisão inclui abordagens clássicas que possuem fundamentação matemática sólida, fornecendo uma base teórica para o desenvolvimento de métodos robustos e eficientes. Para cada trabalho analisado, destacamos as propostas principais, as técnicas utilizadas e os avanços alcançados, visando evidenciar as contribuições e as limitações de cada abordagem no contexto da redução de ruído.

O estudo conduzido por (FURUIE, 1990) teve como principal finalidade, introduzir uma técnica de reconstrução de imagens afetadas pelo ruído de Poisson de alta velocidade. Para alcançar tal objetivo, o estudo comparou essa técnica com métodos já estabelecidos, como *Convolution Reverse Projection* (CRP), *Algebraic Reconstruction Technique* (ART) e *Expectation Maximization* (EM), por meio da análise de projeções simuladas de *Positron Emission Tomography* (PET) e *Single Photon Emission Computed Tomography* (SPECT). A proposta central envolvia a estimativa das projeções antes da reconstrução, utilizando um modelo de ruído realista, um modelo de formação de projeções e um modelo estatístico do sistema. Foram empregados estimadores diretamente nas projeções afetadas pelo ruído de Poisson, bem como estimadores, após a aplicação da transformação de Anscombe, inclui-se assim, o estimador Bayesiano *Maximum a Posteriori* (MAP), para as projeções e o estimador de menor erro médio quadrático, conhecido como filtro de Wiener.

O modelo proposto, demonstrou que a abordagem de estimar as projeções antes da reconstrução pode ser mais eficaz para lidar com o desafio da reconstrução de imagens em cenários com presença de ruído de Poisson. Isto deve-se, em grande parte, à disponibilidade de uma variedade de filtros desenvolvidos especificamente para combater o

ruído de Poisson. Além do mais, o estudo enfatiza a aplicação da *Discrete Fourier Transform* (DFT) como uma técnica que pode acelerar o processo de reconstrução. Um aspecto relevante é a eficácia da Transformação de Anscombe, que converte o ruído de Poisson, o qual está intrinsicamente ligado ao sinal, em ruído aditivo e independente. Esta abordagem transformacional oferece uma maneira valiosa de melhorar a qualidade das imagens reconstruídas em contextos, nos quais o ruído de Poisson é predominante.

Por conseguinte, Sanchez (PORTAL; ALENS, 1991) fez um aprimoramento do trabalho de Furuie, propondo novos estimadores; concluiu-se que a filtragem das projeções com ruído de Poisson seguida da convolução-retroprojeção é um bom método para reconstrução tomográfica de imagens de tomógrafos por emissão, chega, portanto, a ser comparado com o *Maximum Likelihood Estimation* (MLE). E, ainda, com tempo inferior.

No entanto, o trabalho de Salina (SALINA, 2001; SALINA, 2007) trouxe uma abordagem distinta para a reconstrução, em comparação com os estudos mencionados anteriormente. Salina propôs a utilização de *Projections Onto Convex Sets* (POCS), juntamente com quatro estimatórios de métodos das projeções originais: MAP, filtragem dos coeficientes wavelets, Filtro de Wiener pontual e Filtro de Goodman-Belsher. Os resultados obtidos demonstraram eficácia na melhoria da relação sinal-ruído na imagem final, pois o pré-processamento torna os conjuntos impostos pelas projeções mais restritivos.

Em 2010, Ribeiro conduziu uma investigação minuciosa sobre o desempenho de diversas técnicas de filtragem aplicadas à projeções tomográficas afetadas pelo ruído de Poisson. As técnicas examinadas incluíram a estimação Bayesiana, a filtragem de Wiener e a limiarização no domínio da Wavelet. Outrossim, em cada uma destas abordagens, foram utilizados dez estimadores de Máxima A Posteriori (MAP), cada um incorporando uma densidade de probabilidade, como informação, a priori (RIBEIRO, 2010).

Os resultados da pesquisa evidenciaram um desempenho notável dos filtros, cada um deles destacando-se em cenários específicos. Por conseguinte, evidencia a relevância de selecionar a técnica adequada, de acordo com o contexto da aplicação. Complementarmente, Eduardo apontou como perspectiva futura a realização de testes de desempenho dos métodos de filtragem empregados no estudo, visando sua aplicação em uma filtragem 2D do conjunto de projeções.

Nesse conjunto de circunstância, o estudo conduzido por Geraldo (GERALDO, 2011) concentrou-se em uma abordagem de filtragem 2-D, baseada em estimadores de MAP pontuais, comparando-a com o filtro de Wiener Pontual. Os resultados obtidos, evidenciaram que os estimadores MAP 2D desenvolvidos no presente trabalho, demonstraram um desempenho sólido, com os melhores resultados, sendo ligeiramente superiores aos alcançados pelo filtro de Wiener Pontual. Consequentemente, concluiu-se que esses filtros desempenham um papel crucial na redução da dose de radiação à qual os pacientes são submetidos; durante exames de tomografia computadorizada.

Uma visão alternativa para abordar o desafio do ruído de Poisson consistiu em realizar

a filtragem da imagem reconstruída, após o processo de reconstrução (pós-filtragem), aplicando um modelo, a priori, contextual baseado-se em *Markov Random Field* (MRF). Além de utilizar a técnica do NLM com o objetivo de aprimorar a qualidade visual da imagem; conforme descrito por Salvadeo em seu trabalho (SALVADEO, 2013). O emprego do NLM demonstrou melhorias significativas no desempenho final da filtragem, realçando assim, a importância dessa técnica na mitigação do ruído e na melhoria da qualidade das imagens resultantes.

O excelente desempenho do NLM impulsionou o reconhecimento das abordagens não locais, na comunidade científica. Como resultado, diversos estudos foram conduzidos, explorando essa técnica em uma variedade de contextos e aplicações (PENNA, 2014; BINDILATTI, 2014; PINHEIRO, 2017; EVANGELISTA; MASCARENHAS, 2017; SANTOS, 2017; BINDILATTI, 2018; PENNA, 2018).

Em particular, em (PENNA, 2014) e (PENNA, 2018), explorou-se o uso do NLM com base na utilização de distâncias estocásticas para a filtragem de imagens SAR de intensidade, que são, frequentemente, afetadas pelo ruído "speckle". A escolha em utilizar distâncias estocásticas é justificada pelo fato de que, o NLM foi, originalmente, desenvolvido para tratar o ruído branco aditivo gaussiano (AWGN); o mesmo ensejo que motivou sua aplicação, no presente estudo.

De maneira similar, em (BINDILATTI, 2014), (EVANGELISTA; MASCARENHAS, 2017) e (BINDILATTI, 2018), a mesma estratégia foi empregada, utilizando o NLM em conjunto com distâncias estocásticas. Porém, desta vez, para abordar o ruído de Poisson. Mais uma vez, tal abordagem mostrou-se promissora em comparação às técnicas do estado da arte, ressaltando, desta forma, a versatilidade e eficácia do NLM em uma variedade de contextos de processamento de imagens; afetadas por diferentes tipos de ruído.

Além do mais, vale destacar que, a utilização da transformação de Anscombe foi aplicada para converter o ruído de Poisson em ruído branco aditivo gaussiano (AWGN). Esta transformação é uma técnica valiosa, a qual contribui para simplificar o tratamento do ruído poissoniano; tornando-o mais compatível com o NLM e permitindo resultados ainda mais robustos.

O trabalho apresentado em (PINHEIRO, 2017) teve como objetivo realizar o processo de filtragem no domínio das projeções, sob condições de baixa contagem de fótons. A escolha deste método, deve-se ao fato de que a aplicação de técnicas de filtragem, na imagem reconstruída, pode levar a artefatos. No estudo, foram utilizados dois métodos de filtragem, ambos baseados na decomposição do sinograma, por meio de Wavelets anisotrópicas. O primeiro método, envolveu a limiarização dos coeficientes das Wavelets (Curvelet, Contourlet, Shearlet), enquanto o segundo método seguiu uma abordagem semelhante, mas adicionou um pré-processamento no qual o sinograma foi filtrado por algumas das principais técnicas de atenuação de ruído, como BM3D, NLM e Filtro de Wiener. O objetivo era demonstrar que o uso de Wavelets anisotrópicas, juntamente com

o pré-processamento, poderia, assim, proporcionar resultados competitivos em relação ao estado da arte, particularmente com o uso da técnica BM3D.

E por fim, o trabalho de Santos (SANTOS, 2017), como mencionado anteriormente, desempenhou um papel fundamental e inspirador para o presente estudo. Na tese de Santos, foram estabelecidos objetivos de estudo e validação de modelos estatísticos teóricos para o ruído de speckle em imagens de ultrassom; considerando tanto o domínio original quanto o do logaritmo. De mais a mais, a pesquisa incluiu a dedução de distâncias estocásticas e a realização de testes estatísticos com base em diversas divergências, tais como Bhattacharyya, Havrda-Charvát, Hellinger, Kullback-Leibler, Rényi, Sharma-Mittal, triangular e média harmônica. Os devidos procedimentos foram repetidos com base em distribuições de Nakagami.

O estudo de Santos também empregou a técnica de derivação de distâncias geodésicas, em espaços probabilísticos, para deduzir distâncias estocásticas derivadas de várias entropias; que incluem Arimoto, Havrda-Charvát, Rényi, Shannon, Sharma-Mittal, Tsallis e Varma. Assim, sendo aplicadas as distribuições de Rayleigh e Fisher-Tippett.

O resultado final da pesquisa foi a implementação de filtros de redução de speckle, os quais utilizam essas distâncias como medida de similaridade entre patches, nos métodos NLM e BM3D. Por fim, o estudo comparou e avaliou o desempenho dos filtros propostos em comparação com suas versões originais e com outras abordagens da literatura. As comparações foram realizadas considerando-se o método de geração das distâncias estocásticas utilizadas e o modelo de distribuição (Rayleigh ou Nakagami) aplicado no domínio original.

---

# Capítulo 4

## Materiais e Métodos

---

Neste capítulo, apresentamos uma análise detalhada dos materiais empregados nas experiências realizadas para o estudo em questão, bem como a descrição completa da metodologia adotada.

### 4.1 Imagens *Fixed Zebrafish Embryo*

Em nosso estudo, utilizamos duas imagens de microscopia de fluorescência confocal de embriões de zebrafish fixados, conforme documentado no artigo (ZHANG et al., 2019). Este artigo descreve a criação do conjunto de dados de remoção de ruído de microscopia de fluorescência (*Fluorescence Microscopy - Noise Removal Dataset*, FMD), projetado especificamente para lidar com o ruído Poisson-Gaussiano. Notavelmente, o conjunto de dados FMD representa o primeiro conjunto de dados de imagem de microscopia real dedicado à remoção de ruído Poisson-Gaussiano, servindo como um recurso crucial para aplicativos que exigem redução de ruído de alta qualidade.

A microscopia de fluorescência é uma técnica amplamente utilizada na pesquisa biomédica, com modalidades como a confocal, a de dois fótons e a de campo amplo. Apesar de sua função fundamental na biologia moderna, essa técnica produz imagens com níveis elevados de ruído devido ao número restrito de fótons capturados pelos detectores, resultando no ruído de Poisson. O aumento da potência do laser ou do tempo de exposição pode melhorar a qualidade da imagem; no entanto, esses métodos são restringidos por limitações como saturação de fluorescência, fotodanos à amostra e desafios na geração de imagens dinâmicas, em que o tempo de captura é crucial.

As duas imagens utilizadas em nosso estudo retratam campos de visão diferentes de embriões de peixe-zebra fixados dois dias após a fertilização. Para fins de conveniência,





Figura 4.1 – Imagens FZE Noisy FOV 1

Figura 4.2 – Imagens FZE Noisy FOV 2

vamos nos referir a essas imagens como FZE (*Fixed Zebrafish Embryo Images*). Neste trabalho, também fornecemos a imagem *Ground Truth*, que pode ser comparada com as imagens filtradas para avaliar visualmente o desempenho do filtro.

## 4.2 Distâncias estocásticas para o ruído Poisson

Conforme discutido na seção 2.5, as distâncias estocásticas são divergências métricas que derivam sua propriedade simétrica (NASCIMENTO; CINTRA; FRERY, 2009).

O algoritmo BM3D a ser explorado e implementado neste estudo (seção 2.7), utiliza a distância euclidiana (Equação 2.8) como sua métrica de distância original. A métrica em referência não se classifica como uma distância estocástica, o que a torna altamente eficaz para lidar com ruído AWGN, porém, menos apropriada para a incorporação de outros modelos paramétricos de ruído.

No estudo de (FRERY; NASCIMENTO; CINTRA, 2010), foram introduzidas oito divergências métricas que, posteriormente, foram adaptadas para o contexto de distâncias estocásticas relacionadas ao ruído Speckle. A adaptação destas métricas foi realizada por meio da exploração da propriedade de simetria, conforme detalhado na Equação 2.10, que é apresentada na seção 2.5 deste trabalho.

As divergências métricas exploradas incluem as distâncias de Kullback-Leibler, Hellinger, Rényi, Bhattacharyya, Aritmética-Geométrica, Triangular, Média-Harmônica e Jensen-Shannon (KULLBACK; LEIBLER, 1951; DIACONIS; ZABELL, 1982; RÉNYI, 1961; BHATTACHARYYA, 1946; TANEJA, 1995; TANEJA, 2005; BURBEA; RAO, 1982). Também foi utilizada a distância de Havrda and Charvat (HAVRDA; CHARVÁT, 1967).

Tabela 1 –  $(h, \phi)$ -divergências e funções relacionadas  $\phi$  e  $h$ 

$(h, \phi)$ -divergência	$h(y)$	$\phi(x)$
Kullback-Leibler	$y/2$	$(x-1)\log(x)$
Rényi (ordem $\beta$ )	$\frac{1}{\beta-1} \log((\beta-1)y+1), 0 \leq y < \frac{1}{1-\beta}$	$\frac{x^{1-\beta} + x^\beta - \beta(x-1) - 2}{2(\beta-1)}, 0 < \beta < 1$
Hellinger	$y/2, 0 \leq y < 2$	$(\sqrt{x}-1)^2$
Bhattacharyya	$-\log(-y+1), 0 \leq y < 1$	$-\sqrt{x} + \frac{x+1}{2}$
Jensen-Shannon	$y/2$	$x \log(\frac{2x}{x+1}) + \log(\frac{2}{x+1})$
Aritmética-Geométrica	$y$	$(\frac{x+1}{2}) \log(\frac{x+1}{2x}) + (\frac{x-1}{2})$
Triangular	$y, 0 \leq y < 2$	$\frac{(x-1)^2}{x+1}$
Média-Harmônica	$-\log(-y/2+1), 0 \leq y < 2$	$\frac{(x-1)^2}{x+1}$
Havrda and Charvát	$y$	$\frac{(x-x^s)}{(1-s)}, s > 0, s \neq 1$

No estudo conduzido por (BINDILATTI; MASCARENHAS, 2013), as medidas de divergência foram adaptadas para lidar com o ruído do tipo Poisson, no contexto deste trabalho, uma vez que estamos empregando a VST para converter o ruído Poisson em AWGN, tornou-se uma necessidade premente adaptar essas mesmas métricas de divergência para o domínio do ruído Gaussiano.

Assim, o processo de ajuste das divergências para a distribuição Normal, também conhecida como Gaussiana, foi realizado por meio da aplicação das equações Equação 2.9 e 2.10, utilizando o software **Wolfram Mathematica** para realizar essa adaptação de fórmulas.

No entanto, foi viável identificar apenas cinco distâncias com fórmulas fechadas para a distribuição desejada, sendo elas: Kullback-Leibler (KULLBACK; LEIBLER, 1951), Rényi (RÉNYI, 1961), Hellinger (DIACONIS; ZABELL, 1982), Bhattacharyya (BHATTACHARYYA, 1946) e Havrda and Charvát (HAVRDA; CHARVÁT, 1967), apresentadas em Tabela 2.

### 4.3 Modificação do algoritmo

A presente pesquisa promove uma alteração específica no algoritmo BM3D, se concentrando, particularmente, na seleção de patches similares durante duas etapas cruciais. A primeira etapa emprega o *hard thresholding*, enquanto a segunda incorpora o filtro de Wiener. Para a concretização desse desenvolvimento, aproveitou-se a implementação de código aberto do BM3D disponibilizada por (LEBRUN, 2012).

Conforme exposto de maneira detalhada na seção 2.7 que aborda o funcionamento do algoritmo BM3D, a Equação 2.13 desempenha um papel crucial como métrica de agrupamento em tal contexto. Como próxima etapa, foi substituído a distância euclidiana empregada no algoritmo por aquelas distâncias previamente apresentadas na Tabela 2.

Tabela 2 – Distâncias estocásticas para ruído Gaussiano com fórmulas fechadas

Distâncias	Fórmulas Fechadas
Kullback-Leibler	$\frac{1}{2} \left[ \frac{(\mu_1 - \mu_2)^2}{\sigma_2^2} + \frac{\sigma_1^2}{\sigma_2^2} - \ln \left( \frac{\sigma_1^2}{\sigma_2^2} \right) - 1 \right]$
Rényi (ordem $\alpha$ )	$\log \left( \frac{\sigma_2}{\sigma_1} \right) + \frac{1}{2(\alpha-1)} \log \left( \frac{\sigma_2^2}{\sigma_1^2} \right) + \frac{1}{2} \left( \frac{\alpha(\mu_1 - \mu_2)^2}{\sigma_1^2} \right)$
Hellinger	$1 - \sqrt{\frac{2\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2}} e^{-\frac{1}{4} \frac{(\mu_1 - \mu_2)^2}{\sigma_1^2 + \sigma_2^2}}$
Bhattacharyya	$-\log \left( \sqrt{2} \sqrt{\frac{\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2}} \cdot e^{-\frac{(\mu_1 - \mu_2)^2}{4(\sigma_1^2 + \sigma_2^2)}} \right)$
Havrda and Charvát	$\frac{\sigma_1 \left( \frac{\sigma_2}{\sigma_1} \right)^s \exp \left( -\frac{(s-1)s(\mu_1 - \mu_2)^2}{2\sigma_1^2(s-1) - 2\sigma_2^2 s} \right) + \sigma_2 \left( \frac{\sigma_1}{\sigma_2} \right)^s \exp \left( -\frac{(s-1)s(\mu_1 - \mu_2)^2}{2\sigma_2^2(s-1) - 2\sigma_1^2 s} \right)}{\frac{\sqrt{\sigma_2^2 s - \sigma_1^2(s-1)}}{2(s-1)} + \frac{\sqrt{\sigma_1^2 s - \sigma_2^2(s-1)}}{2(s-1)}} - 2$

## 4.4 Medidas comparativas

### 4.4.1 *Peak Signal-to-Noise Ratio (PSNR)*

O PSNR, também conhecido como "*Peak Signal-to-Noise Ratio*" (Relação Sinal-Ruído de Pico), é um indicador de qualidade que se fundamenta na comparação entre uma imagem restaurada e uma imagem de referência, sendo empregado no presente estudo como um critério de avaliação. Esta métrica, introduzida por (WANG; BOVIK, 2009), essencialmente estabelece a relação máxima entre o sinal original e o ruído que o afetou. A determinação do PSNR envolve a normalização do Erro Médio Quadrático (MSE), o qual é expresso pela fórmula:

$$MSE = \frac{1}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \|I(i, j) - K(i, j)\|^2, \quad (4.1)$$

sendo  $I$  uma imagem livre de ruído e por  $K$  a sua correspondente versão corrompida por um ruído não especificado. Além do mais,  $M$  e  $N$  representam as dimensões de largura e altura das imagens, respectivamente, em situações como a abordada neste trabalho, em que os valores de  $M$  e  $N$  são idênticos. É possível reescrever o Erro Médio Quadrático (MSE) da seguinte forma:

$$MSE = \sum_{i=1}^N (I_i - K_i)^2 \quad (4.2)$$

Com base nisto, PSNR pode ser descrita como:

$$PSNR = 10 \cdot \log_{10} \left( \frac{MAX_I^2}{MSE} \right), \quad (4.3)$$

sendo  $MAX_I^2$  o valor máximo possível do sinal, correspondendo ao valor padrão de  $255^2$  em imagens de 8 bits, conforme utilizado neste trabalho. Ademais, o tamanho da imagem bidimensional é de  $256 \times 256$  *pixels*.

#### 4.4.2 *Structural SIMilarity Index (SSIM)*

O termo SSIM, cuja abreviação corresponde ao Índice de Similaridade Estrutural, representa uma métrica comparativa entre imagens que considera a percepção visual humana, permitindo quantificar, numericamente, o grau de semelhança entre duas imagens. Aspectos como: contraste, estrutura e iluminação são elementos cruciais que influenciam a avaliação de similaridade. Introduzido, inicialmente por (WANG; BOVIK, 2002) e, posteriormente, refinado por estudos subsequentes, o SSIM é formalizado pela seguinte formulação:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}, \quad (4.4)$$

onde  $C_1 = (0,01r)^2$  e  $C_2 = (0,03r)^2$ .

Como resultado é gerado um valor numérico que reflete a similaridade entre as imagens, em análise, com -1 indicando total dissimilaridade e 1 representando uma correspondência absoluta. (WANG; BOVIK, 2002)

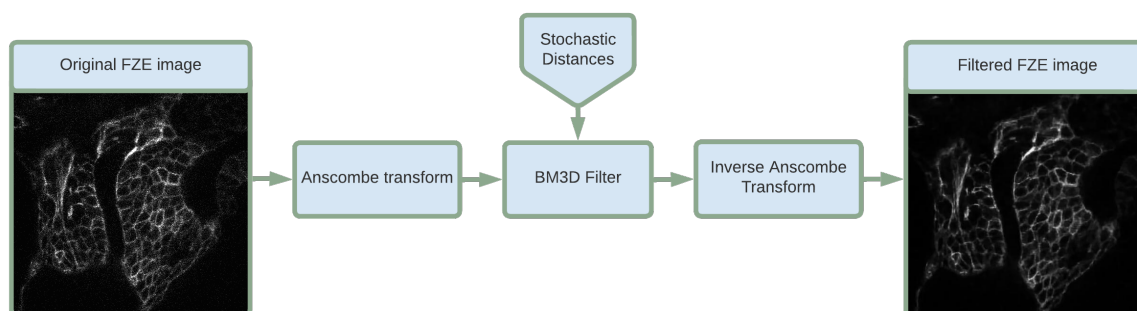
Assim sendo, o conceito de SSIM possibilita a obtenção de uma medida comparativa entre duas imagens, como no contexto deste estudo, no qual a imagem livre de ruído é contrastada com o resultado após a aplicação de pós-filtragem. Isto viabiliza a incorporação da percepção visual humana como um fator substancial nas avaliações comparativas entre diferentes algoritmos.

## 4.5 Resumo do método proposto

Neste estudo, imagens de embriões fixos de peixe-zebra capturadas por microscopia de fluorescência confocal foram empregadas para examinar a remoção do ruído Poisson-Gaussiano, um problema generalizado em imagens de microscopia de fluorescência decorrente da natureza discreta da captura de fótons. As imagens constituem o conjunto de dados de Microscopia de Fluorescência - Remoção de Ruído (FMD), o primeiro conjunto de dados de imagens de microscopia dedicado à remoção desse tipo de ruído. Para atenuar os efeitos do ruído de Poisson, foi aplicada a Transformada de Estabilização de Variância (VST), convertendo-o efetivamente em ruído gaussiano.

Nesse contexto, as divergências estocásticas foram adaptadas, incluindo as métricas de Kullback-Leibler, Hellinger e Bhattacharyya, usando fórmulas fechadas desenvolvidas com base na simetria das divergências. O Figura 4.3 fornece uma representação diagramática em blocos dos trabalhos subjacentes.

Figura 4.3 – Diagrama de blocos da metodologia proposta



Para avaliar a eficácia dos filtros empregados, foi utilizada a métrica PSNR (Peak Signal-to-Noise Ratio), que quantifica a relação entre o sinal original e o ruído, e o SSIM (Structural Similarity Index), que considera aspectos perceptivos como contraste, estrutura e iluminação para avaliar a semelhança entre as imagens restauradas e as de referência.

---

# Capítulo 5

## Resultados

---

### 5.1 Parâmetros utilizados

O algoritmo BM3D é composto por diversos parâmetros que precisam ser ajustados individualmente em cada execução. Isso ocorre porque os resultados do algoritmo podem variar devido a diferenças nas texturas da imagem e nos níveis de ruído. Tais variações podem resultar em artefatos visuais, borramento ou perda de detalhes na imagem processada. Os parâmetros específicos no BM3D, descritos com suas respectivas notações e funções, foram detalhados por (LEBRUN, 2012):

1.  $k^{hard}$  e  $k^{wien}$ : Tamanho dos patches.
2.  $N^{hard}$  e  $N^{wien}$ : Quantidade máxima de patches armazenados.
3.  $p^{hard}$  e  $p^{wien}$ : Parâmetros para acelerar o processamento, pulando uma quantidade inteira de pixels nas linhas e colunas na imagem para cada iteração.
4.  $n^{hard}$  e  $n^{wien}$ : Tamanho da janela de busca.
5.  $\tau$ : Distância mínima para comparação entre dois patches similares.
6.  $\lambda_{3D}^{Hard}$ : Coeficiente de thresholding dos grupos de 3 dimensões do BM3D utilizado na pré-filtragem.
7.  $\sigma$ : Parametro padrão do filtro BM3D que representa quantidade de ruído assumido na imagem a ser filtrada.

Com a exceção dos dois últimos parâmetros  $\tau$  e  $\lambda_{3D}^{Hard}$  apresentados na lista anterior, todos os outros parâmetros mantiveram os seus valores padrões apresentados na aplicação

explorada por (LEBRUN, 2012). O  $\tau$  utilizado em cada distância é calculado através da própria fórmula da distância dada Tabela 2. Quanto ao valor de  $\lambda_{3D}^{Hard}$ , foi necessária uma série de experimentos para a identificação de um valor ótimo, devido ao seu comportamento ser relativamente empírico. O parâmetro  $\sigma$  no BM3D desempenha um papel crucial, pois ele ajusta a intensidade do filtro para acomodar diversos níveis de ruído. Normalmente, seu valor está relacionado ao desvio padrão da imagem, e pode aumentar o efeito de desfoque em situações de ruído intenso. Foi feita uma variação do  $\sigma$  para obter o melhor resultado de cada distância, em relação a SSIM e PSNR.

## 5.2 Experimentos com Fluorescência Imagens de Microscopia

Como descrito anteriormente, todas as imagens experimentais apresentadas na seção 4.1 foram filtradas pelo método BM3D, variando o parâmetro  $\sigma$  entre 0,5 e 2 para controlar o nível de suavização. Utilizamos duas versões principais de cada filtro como medidas comparativas neste estudo: (1) o filtro BM3D aplicado isoladamente, referenciado na tabela como **BM3D**, e (2) o filtro BM3D combinado com a transformação de Anscombe, indicado como **BM3D+TA**. De forma semelhante, aplicamos o filtro *Non Local Means* (NLM) tanto em sua forma original quanto associado à transformação de Anscombe, designados como **NLM** e **NLM+TA**, respectivamente. Para o filtro proposto neste projeto — que utiliza o BM3D com distâncias estocásticas e a transformação de Anscombe — adotamos a nomenclatura **BM3DSD+TA** para simplificar as referências ao longo do trabalho.

Figura 5.1 – Resultados obtidos com as FZE FOV 1




Figura 5.2 – NLM+TA




Figura 5.3 – BM3DSD+TA

Figura 5.4 – Resultados obtidos com as FZE FOV 2




Figura 5.5 – NLM

Figura 5.6 – BM3DSD+TA

Ao variar o valor de  $\sigma$ , foram gerados os resultados apresentados nas Figura 5.7, Figura 5.8, Figura 5.9 e Figura 5.10, permitindo assim que o desempenho das distâncias seja analisado e que uma melhora na qualidade da imagem seja notada quando comparada à imagem original contaminada pelo ruído Poisson. Através desta variação do  $\sigma$  é possível analisar melhor os resultados e retirar algumas informações como a média e o desvio padrão do  $\sigma$  Tabela 5, Tabela 6, Tabela 7 e Tabela 8.




Figura 5.7 – Resultados SSIM FOV 1

As imagens apresentadas nesta seção foram selecionadas com base nos valores extremos de SSIM, correspondendo aos melhores e piores resultados, conforme indicados nas tabelas Tabela 3 e Tabela 4, ou seja, os maiores e menores valores de SSIM. O valor de

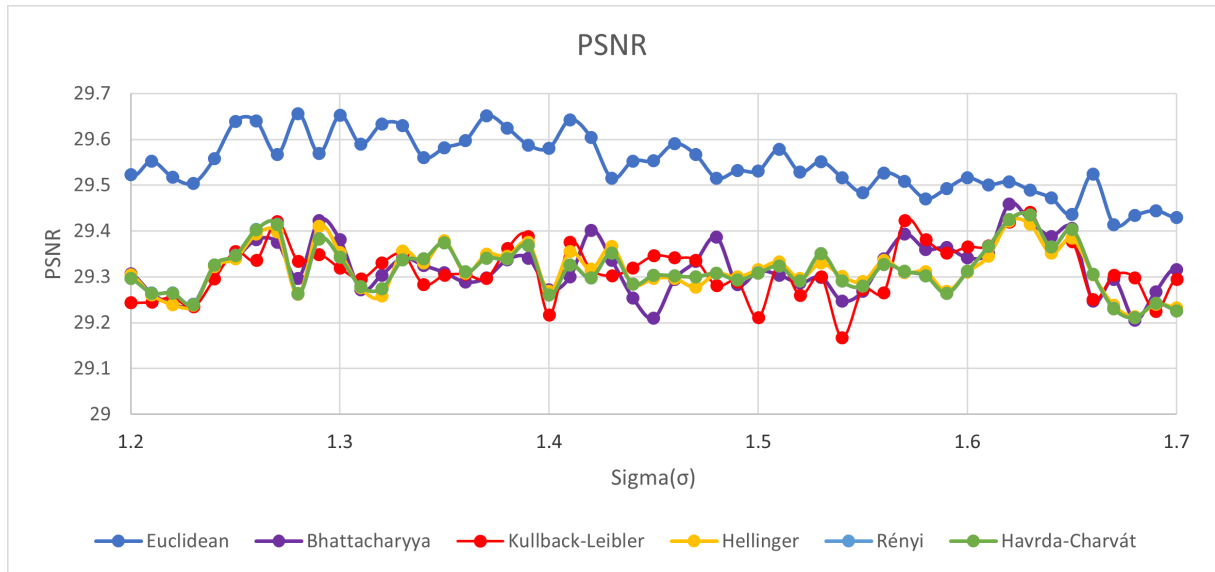


Figura 5.8 – Resultados PSNR FOV 1

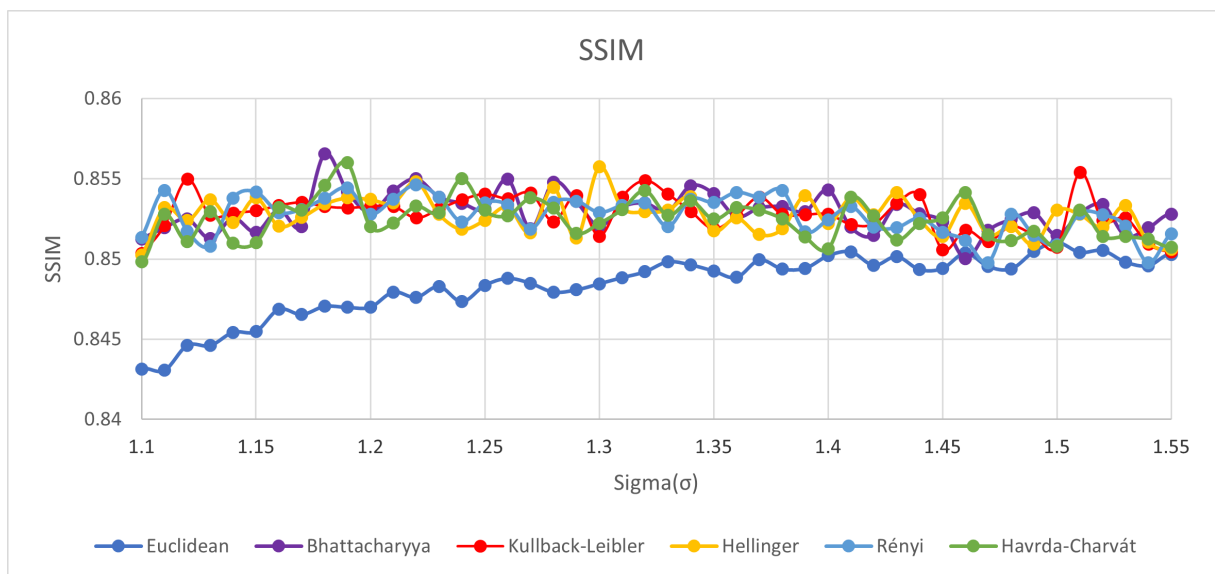


Figura 5.9 – Resultados SSIM FOV 2

**BM3DSD+TA** mostrado nessas tabelas representa o melhor desempenho obtido para as variações dos valores de  $\sigma$  em relação às distâncias estocásticas.

Tabela 3 – Resultados da FOV 1

Índice	BM3D	BM3D+TA	BM3DSD+TA	NLM	NLM+TA
SSIM	0.836	0.840	0.854	0.796	0.789
PSNR	30.420	29.656	29.459	24.732	25.952

A análise dos resultados revelou que a distância de Bhattacharyya apresenta um desempenho ligeiramente superior em comparação com outras medidas quando avaliada pela




Figura 5.10 – Resultados PSNR FOV 2

Tabela 4 – Resultados da FOV 2

Índice	BM3D	BM3D+TA	BM3DSD+TA	NLM	NLM+TA
SSIM	0.824	0.851	0.857	0.725	0.767
PSNR	29.776	31.599	31.513	24.320	26.956

Tabela 5 – Tabela de médias e desvios padrão dos valores de SSIM FOV 1 em relação à variação do sigma ( $\sigma$ ) para diferentes distâncias

	Euclidean	Bhattacharyya	KL	Hellinger	Rényi	Havrda-Charvát
Maior SSIM	0.840	0.854	0.826	0.839	0.839	0.838
Sigma ( $\sigma$ )	0.820	0.830	0.840	0.960	0.790	0.930
Média	0.813	0.809	0.807	0.810	0.809	0.809
Desvio	0.025	0.031	0.028	0.029	0.029	0.029

métrica SSIM, embora essa vantagem seja pequena.

Em contrapartida, a distância euclidiana obteve desempenho significativamente melhor ao ser comparada pelo PSNR, o que já era esperado. Esse comportamento pode ser atribuído ao fato de que o PSNR é uma métrica baseada na média do erro quadrático médio (*Mean Square Error* (MSE)), que tende a favorecer a distância euclidiana devido

Tabela 6 – Tabela de médias e desvios padrão dos valores de PSNR FOV 1 em relação à variação do sigma ( $\sigma$ ) para diferentes distâncias

	Euclidean	Bhattacharyya	KL	Hellinger	Rényi	Havrda-Charvát
Maior PSNR	29.656	29.459	29.441	29.422	29.436	29.435
Sigma ( $\sigma$ )	1.280	1.620	1.630	1.620	1.630	1.630
Média	28.716	28.424	28.396	28.410	28.409	28.408
Desvio	1.352	1.373	1.384	1.384	1.383	1.384

Tabela 7 – Tabela de médias e desvios padrão dos valores de SSIM FOV 2 em relação à variação do sigma ( $\sigma$ ) para diferentes distâncias

	Euclideana	Bhattacharyya	KL	Hellinger	Rényi	Havrda-Charvát
Maior SSIM	0.851	0.857	0.855	0.856	0.855	0.856
Sigma ( $\sigma$ )	1.500	1.180	1.510	1.300	1.220	1.190
Média	0.820	0.818	0.819	0.818	0.818	0.818
Desvio	0.053	0.064	0.064	0.064	0.064	0.064

Tabela 8 – Tabela de médias e desvios padrão dos valores de PSNR FOV 2 em relação à variação do sigma ( $\sigma$ ) para diferentes distâncias

	Euclideana	Bhattacharyya	KL	Hellinger	Rényi	Havrda-Charvát
Maior PSNR	31.599	31.513	31.532	31.512	31.501	31.501
Sigma ( $\sigma$ )	1.500	1.550	1.510	1.430	1.520	1.510
Média	30.082	29.884	29.882	29.883	29.881	29.881
Desvio	2.389	2.492	2.490	2.491	2.488	2.488

à sua própria natureza matemática.

Em resumo, a escolha da métrica influencia diretamente o desempenho de cada distância, ressaltando que a distância de Bhattacharyya é preferida para uma avaliação baseada na similaridade estrutural, enquanto a distância euclidiana se mostra mais eficaz para uma análise baseada no erro médio dos pixels.

---

## Conclusão

---

Neste trabalho, introduzimos uma abordagem inovadora para a remoção de ruído Poisson ao integrar a técnica de correspondência de blocos e filtragem 3D (BM3D) com distâncias estocásticas e transformações de estabilização de variância (VST). Nosso método proposto aproveita as vantagens inerentes de cada componente para lidar de forma eficaz com os desafios associados ao ruído Poisson, comum em diversas aplicações científicas e médicas de imagem.

A integração de distâncias estocásticas e VST no framework BM3D representa uma contribuição inovadora, que conecta os avanços teóricos em estatísticas de ruído com aplicações práticas de remoção de ruído. Essa sinergia não apenas aprimora o desempenho do BM3D no contexto de ruído Poisson, mas também abre caminho para novas explorações que combinem transformações estatísticas com algoritmos de remoção de ruído sofisticados.

Embora os resultados apresentados neste trabalho sejam promissores, diversas possibilidades para pesquisas futuras permanecem abertas. Estas incluem: 1) Distâncias estocásticas adaptativas para selecionar dinamicamente a distância mais apropriada para cada par de blocos na imagem; 2) Otimização da eficiência computacional para possibilitar a remoção de ruído em tempo real; 3) Extensão para outros modelos de ruído, como o ruído Poisson-Gaussiano misto; 4) Integração com aprendizado profundo para melhorar ainda mais o desempenho da remoção de ruído.

Em conclusão, nosso trabalho demonstra que a combinação de BM3D com distâncias estocásticas e transformações de estabilização de variância constitui uma estratégia poderosa e eficaz para a remoção de ruído Poisson. Acreditamos que essa pesquisa não apenas avança o estado da arte em remoção de ruído de imagem, mas também oferece uma estrutura robusta que pode ser expandida e adaptada para uma ampla gama de cenários de imagem e condições de ruído.

---

## Referências

---

- ANSCOMBE, F. J. The transformation of poisson, binomial and negative-binomial data. **Biometrika**, JSTOR, v. 35, n. 3/4, p. 246–254, 1948.
- BHATTACHARYYA, A. On a measure of divergence between two multinomial populations. **Sankhyā: the indian journal of statistics**, JSTOR, p. 401–406, 1946.
- BINDILATTI, A. A.; MASCARENHAS, N. D. A. A nonlocal poisson denoising algorithm based on stochastic distances. **IEEE Signal Processing Letters**, v. 20, n. 11, p. 1010–1013, 2013.
- BINDILATTI, A. d. A. Abordagens não-locais para filtragem de ruído poisson. Universidade Federal de São Carlos, 2014.
- \_\_\_\_\_. Algoritmos para a redução de ruído poisson e estimativa de parâmetros utilizando distâncias estocásticas. 2018.
- BOULANGER, J. et al. Patch-based nonlocal functional for denoising fluorescence microscopy image sequences. **IEEE transactions on medical imaging**, IEEE, v. 29, n. 2, p. 442–454, 2009.
- BUADES, A.; COLL, B.; MOREL, J.-M. A non-local algorithm for image denoising. In: **2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)**. [S.l.: s.n.], 2005. v. 2, p. 60–65 vol. 2.
- BURBEA, J.; RAO, C. On the convexity of some divergence measures based on entropy functions. **IEEE Transactions on Information Theory**, IEEE, v. 28, n. 3, p. 489–495, 1982.
- DABOV, K. et al. Image denoising by sparse 3-d transform-domain collaborative filtering. **IEEE Transactions on image processing**, IEEE, v. 16, n. 8, p. 2080–2095, 2007.
- DELEDALLE, C.-A.; TUPIN, F.; DENIS, L. Poisson nl means: Unsupervised non local means for poisson noise. In: IEEE. **2010 IEEE international conference on image processing**. [S.l.], 2010. p. 801–804.
- DIACONIS, P.; ZABELL, S. L. Updating subjective probability. **Journal of the American Statistical Association**, Taylor & Francis, v. 77, n. 380, p. 822–830, 1982.

- EVANGELISTA, R. C.; MASCARENHAS, N. D. Abordagens bayesianas não-locais para filtragem de ruído poisson utilizando distâncias estocásticas. v. 3, p. 63–67, 2017.
- FRERY, A. C.; NASCIMENTO, A. D.; CINTRA, R. J. Contrast in speckled imagery with stochastic distances. In: IEEE. **2010 IEEE International Conference on Image Processing**. [S.l.], 2010. p. 69–72.
- FURUIE, S. **Reconstrucao tomografica de imagens com ruído Poisson: estimativa das projeções. 1990. 150p.** Tese (Doutorado) — Tese (Doutorado em Engenharia Elétrica)-Universidade de São Paulo, São Paulo, 1990.
- GERALDO, R. J. Filtragem map 2-d de imagens ct ruidosas. 2011.
- HAVRDA, J.; CHARVÁT, F. Quantification method of classification processes. concept of structural  $\alpha$ -entropy. **Kybernetika**, Institute of Information Theory and Automation AS CR, v. 3, n. 1, p. 30–35, 1967.
- KNAUS, C.; ZWICKER, M. Dual-domain image denoising. In: IEEE. **2013 IEEE International Conference on Image Processing**. [S.l.], 2013. p. 440–444.
- KULLBACK, S.; LEIBLER, R. A. On information and sufficiency. **The annals of mathematical statistics**, JSTOR, v. 22, n. 1, p. 79–86, 1951.
- LEBRUN, M. An analysis and implementation of the bm3d image denoising method. **Image Processing On Line**, v. 2012, p. 175–213, 2012.
- LEBRUN, M.; BUADES, A.; MOREL, J.-M. A nonlocal bayesian image denoising algorithm. **SIAM Journal on Imaging Sciences**, SIAM, v. 6, n. 3, p. 1665–1688, 2013.
- MAKITALO, M.; FOI, A. On the inversion of the anscombe transformation in low-count poisson image denoising. In: IEEE. **2009 International Workshop on Local and Non-Local Approximation in Image Processing**. [S.l.], 2009. p. 26–32.
- \_\_\_\_\_. Optimal inversion of the anscombe transformation in low-count poisson image denoising. **IEEE transactions on Image Processing**, IEEE, v. 20, n. 1, p. 99–109, 2010.
- \_\_\_\_\_. A closed-form approximation of the exact unbiased inverse of the anscombe variance-stabilizing transformation. **IEEE transactions on image processing**, IEEE, v. 20, n. 9, p. 2697–2698, 2011.
- \_\_\_\_\_. Optimal inversion of the generalized anscombe transformation for poisson-gaussian noise. **IEEE transactions on image processing**, IEEE, v. 22, n. 1, p. 91–103, 2012.
- \_\_\_\_\_. Poisson-gaussian denoising using the exact unbiased inverse of the generalized anscombe transformation. In: IEEE. **2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. [S.l.], 2012. p. 1081–1084.
- MCQUEEN, J. Some methods for classification and analysis of multivariate observations. In: **Proc. Fifth Berkeley Symposium on Mathematical Statistics and Probability, 1967**. [S.l.: s.n.], 1967. p. 281–297.

- NASCIMENTO, A. D.; CINTRA, R. J.; FRERY, A. C. Hypothesis testing in speckled data with stochastic distances. **IEEE Transactions on geoscience and remote sensing**, IEEE, v. 48, n. 1, p. 373–385, 2009.
- PARDO, L. **Statistical inference based on divergence measures**. [S.l.]: CRC press, 2018.
- PENNA, P. A. d. A. Filtragem de ruído speckle em imagens de radar de abertura sintética por filtros de média não local com transformação homomórfica e distâncias estocásticas. 2014.
- \_\_\_\_\_. Filtragem não-local do ruído speckle em imagens sar com modelagem estatística dos coeficientes da wavelet de haar e distâncias estocásticas. 2018.
- PINHEIRO, A. M. Filtragem de sinograma tomográfico afetado por ruído poisson utilizando wavelets anisotrópicas. 2017.
- PORTAL, A. L. S.; ALENS, N. Refinamentos nos métodos de estimação das projeções para a reconstrução tomográfica de imagens com ruído poisson. 1991.
- RÉNYI, A. On measures of entropy and information. In: UNIVERSITY OF CALIFORNIA PRESS. **Proceedings of the Fourth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Contributions to the Theory of Statistics**. [S.l.], 1961. v. 4, p. 547–562.
- RIBEIRO, E. d. S. Novas propostas em filtragem de projeções tomográficas sob ruído poisson. 2010.
- ROSS, S. M. **Introduction to probability models**. [S.l.]: Academic press, 2014.
- SALINA, F. V. Reconstrução tomográfica de imagens utilizando técnicas pocs sequenciais e paralelas. 2001.
- SALINA, F. V. **Métodos híbridos para reconstrução tomográfica de imagens usando POCS e teoria da estimação**. Tese (Doutorado) — Tese (Doutorado em Ciências — Física Computacional)-Universidade de São Paulo, 2007.
- SALVADEO, D. H. P. Filtragem de ruído em imagens tomográficas com baixa taxa de contagem utilizando uma abordagem bayesiana contextual. 2013.
- SANTOS, C. A.; MARTINS, D. L.; MASCARENHAS, N. D. Ultrasound image despeckling using stochastic distance-based bm3d. **IEEE Transactions on Image Processing**, IEEE, v. 26, n. 6, p. 2632–2643, 2017.
- SANTOS, C. A. N. Redução de ruído speckle em imagens de ultrassom com filtragem não-local e distâncias estocásticas. 2017.
- TANEJA, I. J. New developments in generalized information measures. In: **Advances in imaging and electron physics**. [S.l.]: Elsevier, 1995. v. 91, p. 37–135.
- \_\_\_\_\_. Bounds on triangular discrimination, harmonic mean and symmetric chi-square divergences. **arXiv preprint math/0505238**, 2005.
- TARDIVO, L. Redução de ruído poisson com o algoritmo bm3d utilizando distâncias estocásticas. Universidade Federal de São Carlos, 2021.

- VONESCH, C. et al. The colored revolution of bioimaging. **IEEE signal processing magazine**, IEEE, v. 23, n. 3, p. 20–31, 2006.
- WANG, Z.; BOVIK, A. C. A universal image quality index. **IEEE signal processing letters**, IEEE, v. 9, n. 3, p. 81–84, 2002.
- \_\_\_\_\_. 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.
- ZHANG, K. et al. Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising. **IEEE Transactions on Image Processing**, v. 26, n. 7, p. 3142–3155, 2017.
- ZHANG, Y. et al. A poisson-gaussian denoising dataset with real fluorescence microscopy images. In: **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**. [S.l.: s.n.], 2019. p. 11710–11718.