

Universidade Federal de São Carlos
Centro de Ciências Exatas e de Tecnologia
Departamento de Engenharia Elétrica

Felipe de Luca Visioli

Restauração de Imagens de Sensoriamento Remoto por
Métodos de Deconvolução Não Linear Restrita

São Carlos
2025

Felipe de Luca Visioli

**Restauração de Imagens de Sensoriamento Remoto
por Métodos de Deconvolução Não Linear Restrita**

Trabalho de Conclusão de Curso apresentado à Universidade Federal de São Carlos como parte dos requisitos necessários para a obtenção do grau de Engenheiro Eletricista.

Orientadora: Profa. Dra. Tatiana F. P. A. T. Pazelli

Universidade Federal de São Carlos
Centro de Ciências Exatas e de Tecnologia
Departamento de Engenharia Elétrica

São Carlos
2025

Visioli, Felipe de Luca

Restauração de imagens de sensoriamento remoto por métodos de deconvolução não linear restrita / Felipe de Luca Visioli -- 2025.
98f.

TCC (Graduação) - Universidade Federal de São Carlos, campus São Carlos, São Carlos

Orientador (a): Tatiana de Figueiredo Pereira Alves Taveira Pazelli

Banca Examinadora: Cesar Comin, Igor Guerrero

Bibliografia

1. Deconvolução. 2. Sensoriamento remoto. 3. Processamento digital de imagem. I. Visioli, Felipe de Luca. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Arildo Martins - CRB/8 7180



FUNDAÇÃO UNIVERSIDADE FEDERAL DE SÃO CARLOS

COORDENAÇÃO DO CURSO DE ENGENHARIA ELÉTRICA - CCEE/CCET

Rod. Washington Luís km 235 - SP-310, s/n - Bairro Monjolinho, São Carlos/SP, CEP 13565-905

Telefone: (16) 33519701 - <http://www.ufscar.br>

DP-TCC-FA nº 19/2025/CCEE/CCET

Graduação: Defesa Pública de Trabalho de Conclusão de Curso

Folha Aprovação (GDP-TCC-FA)

FOLHA DE APROVAÇÃO

FELIPE DE LUCA VISIOLI

RESTAURAÇÃO DE IMAGENS DE SENSORIAMENTO REMOTO POR MÉTODOS DE DECONVOLUÇÃO
NÃO LINEAR RESTRITA

Trabalho de Conclusão de Curso

Universidade Federal de São Carlos – Campus São Carlos

São Carlos, 08 de julho de 2025

ASSINATURAS E CIÊNCIAS

| Cargo/Função | Nome Completo |
|-------------------|---|
| Orientadora | Prof. ^a Dr. ^a Tatiana de Figueiredo Pereira Alves Taveira Pazelli |
| Membro da Banca 1 | Prof. Dr. Cesar Comin |
| Membro da Banca 2 | MSc. Igor Guerrero |



Documento assinado eletronicamente por **Tatiana de Figueiredo Pereira Alves Taveira Pazelli, Professor(a)**, em 17/03/2026, às 11:29, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Cesar Henrique Comin, Docente**, em 31/03/2026, às 10:52, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufscar.br/autenticacao>, informando o código verificador **1918175** e o código CRC **A7575D11**.

Referência: Caso responda a este documento, indicar expressamente o Processo nº 23112.021063/2025-02

SEI nº 1918175

Modelo de Documento: Grad: Defesa TCC: Folha Aprovação, versão de 02/Agosto/2019



Documento assinado digitalmente
IGOR GUERRERO
Data: 05/04/2026 11:25:22-0300
Verifique em <https://validar.iti.gov.br>

Agradecimentos

À Deus por ter me sustentado em todos os momentos desta caminhada.

Aos meus pais Vivian e Edmilson, ao meu irmão Augusto, à minha avó Dalila, aos meus avós Oscar e Leonora, e à toda minha família pelo incondicional amparo.

À minha orientadora pela constante dedicação, motivação e generosidade. Seu papel é fundamental na minha formação como engenheiro.

Aos amigos que compartilharam comigo dessa jornada. Sou grato por tê-los tido ao meu lado e por ter compartilhado das alegrias e dos percalços do caminho trilhado.

Aos professores e funcionários do Departamento de Engenharia Elétrica da Universidade Federal de São Carlos pelo nobre trabalho.

Tudo de mim é feito do que aprendi com vocês.

Resumo

Visioli, Felipe de Luca, **Restauração de Imagens de Sensoriamento Remoto por Métodos de Deconvolução Não Linear Restrita**. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica). Centro de Ciências Exatas e de Tecnologia, Universidade Federal de São Carlos. 101 p. São Carlos, 2025.

Este trabalho propõe um estudo detalhado sobre a deconvolução de imagens orbitais, abordando suas justificativas, métodos e desafios. A deconvolução é uma técnica fundamental para a recuperação da qualidade de imagens, especialmente para aquelas provenientes de satélites de imageamento terrestre, frequentemente afetadas por fatores como dispersão atmosférica, difração óptica e borramento por movimento relativo. Essas distorções reduzem a precisão e a utilidade das imagens em aplicações críticas como monitoramento ambiental, gestão de recursos naturais e resposta a desastres. A metodologia adotada nessa obra envolve a modelagem dos mecanismos de degradação por meio da função de espalhamento de ponto (PSF), a implementação de algoritmos de deconvolução clássicos, iterativos e baseados em aprendizado profundo, e a avaliação comparativa de seus desempenhos. São analisados os métodos Filtro Inverso, Wiener, Richardson-Lucy com e sem regularização por *Total variation*, e *Deep Image Prior*, considerando cenários com PSF conhecida e desconhecida. Para apoiar a experimentação, foi desenvolvida a ferramenta computacional IDIA, que integra os módulos de pré-processamento, restauração e análise métrica das imagens. Os algoritmos foram implementados e testados em um conjunto de imagens de sensoriamento remoto degradadas sinteticamente, a fim de avaliar a eficácia de cada método em termos de melhoria da resolução espacial, aumento do contraste e redução de artefatos. Os resultados indicam que métodos iterativos com regularização oferecem maior estabilidade frente a ruídos, enquanto o *Deep Image Prior* apresenta capacidade de reconstrução sem amplificação de artefatos. A análise métrica, baseada em PSNR, SSIM, NRMSE e FWHM, corroboram as conclusões visuais obtidas. A viabilidade da execução do projeto foi assegurada pela disponibilidade de ferramentas avançadas de processamento de imagens e pela crescente necessidade de dados satelitais de alta qualidade. Este estudo versa, portanto, sobre as técnicas de processamento de imagens no campo da observação terrestre, destacando suas vantagens e limitações. O estudo contribui para o aprimoramento das técnicas de restauração aplicadas à observação da Terra, oferecendo uma base prática e extensível para futuros desenvolvimentos.

Palavras-Chave: 1. Deconvolução. 2. Sensoriamento Remoto. 3. Processamento de Imagem.

Abstract

Visioli, Felipe de Luca, **Restoration of Remote Sensing Images Using Constrained Nonlinear Deconvolution Methods**. Final year thesis (Bachelor degree in Electrical Engineering). Exact and Technology Sciences Center, Federal University of São Carlos. 101 p. São Carlos, 2025.

This work presents a comprehensive study on the deconvolution of orbital images, addressing its motivations, methodologies, and inherent challenges. Deconvolution is a fundamental technique for restoring image quality, particularly in satellite imagery of the Earth's surface, which is often degraded by atmospheric scattering, optical diffraction, and motion blur. Such distortions compromise the accuracy and utility of images in critical applications, including environmental monitoring, natural resource management, and disaster response. The methodology adopted in this research involves modeling the degradation mechanisms through the point spread function (PSF), implementing classical, iterative, and deep learning-based deconvolution algorithms, and conducting a comparative performance analysis. The evaluated methods include Inverse Filtering, Wiener filtering, Richardson-Lucy with and without *Total Variation* regularization, and *Deep Image Prior*, under both known and blind PSF conditions. To support experimentation, the IDIA software tool was developed, integrating modules for image preprocessing and restoration, and metric-based image analysis. The algorithms were implemented and tested on synthetically degraded remote sensing images, with the objective of assessing each method's effectiveness in enhancing spatial resolution, increasing contrast, and minimizing artifacts. The results demonstrate that iterative methods with regularization provide greater robustness against noise, while DIP offers stronger reconstruction capabilities without amplifying visual artifacts. Metric-based evaluation using PSNR, SSIM, NRMSE, and FWHM corroborates the visual assessments. The feasibility of this project was supported by the availability of advanced image processing tools and the growing demand for high-quality satellite imagery. Overall, this study contributes to the advancement of restoration techniques applied to Earth observation, offering a practical and extensible foundation for future developments.

Keywords: 1. Deconvolution. 2. Remote Sensing. 3. Image processing.

Lista de Figuras

| | |
|--|----|
| Figura 1 – Visualização do processo de convolução unidimensional. | 25 |
| Figura 2 – Visualização do processo de convolução bidimensional. | 26 |
| Figura 3 – Esquema de medição da PSF utilizando uma fonte de luz pontual. | 28 |
| Figura 4 – Representação da função de espalhamento de borda (ESF). | 29 |
| Figura 5 – Representação da função de espalhamento de linha (LSF). | 30 |
| Figura 6 – Modelo de formação de imagem em sistemas de sensoriamento remoto. | 32 |
| Figura 7 – Exemplos de imagens degradadas por diferentes tipos de <i>motion blur</i> | 33 |
| Figura 8 – Representação dos modos de Zernike (aberrações ópticas) na pupila e seus efeitos correspondentes na PSF. | 36 |
| Figura 9 – Representação do problema de borda em operações de convolução 2D. | 42 |
| Figura 10 – Diagrama de blocos do processo de degradação e recuperação por deconvolução via filtro inverso. | 44 |
| Figura 11 – Fluxo iterativo da deconvolução cega por Richardson-Lucy. | 47 |
| Figura 12 – Fluxo iterativo do algoritmo de Richardson-Lucy com regularização por <i>Total Variation</i> | 50 |
| Figura 13 – Esquema conceitual do processo de deconvolução com <i>Deep Image Prior</i> , com base na implementação utilizada. | 52 |
| Figura 14 – Estrutura funcional do menu principal da ferramenta IDIA. | 58 |
| Figura 15 – Estrutura dos elementos de exibição e visualização métrica da ferramenta IDIA. | 59 |
| Figura 16 – Organização da barra de ferramentas e ajuda da ferramenta IDIA. | 59 |
| Figura 17 – Tela inicial da interface. | 60 |
| Figura 18 – Menu <i>File</i> com suas opções para gerenciamento dos projetos. | 61 |
| Figura 19 – Controles do menu principal. a) Menu colapsável <i>Preprocessing</i> . b) Menu colapsável <i>Patch Selection</i> . c) Menu colapsável <i>Deconvolution</i> | 62 |
| Figura 20 – Aba de visualização da etapa de pré-processamento. | 62 |
| Figura 21 – Aba de visualização da etapa de deconvolução | 63 |
| Figura 22 – Aba <i>Metrics</i> , com indicadores quantitativos por iteração da deconvolução. | 64 |
| Figura 23 – Aba <i>Visual Comparison</i> , com controle de iteração e seleção de imagem para inspeção visual. | 64 |
| Figura 24 – Aba <i>Complementary Plots</i> com visualização tridimensional de intensidade e mapa de diferença entre imagens. | 65 |
| Figura 25 – Aba <i>Notes</i> , dedicada ao registro de observações do usuário com suporte a formatação básica. | 66 |

| | |
|---|----|
| Figura 26 – Tela de exportação. a) Estado inicial da tela. b) Seletor da fonte de dados aberto c) Seletor do tipo de extensão do arquivo. | 66 |
| Figura 27 – Janela de propriedade intelectual. | 67 |
| Figura 28 – Janela de ajuda com instruções resumidas de uso do sistema. | 67 |
| Figura 29 – Tooltip com explicação resumida e suporte à tecla <i>F1</i> para informações adicionais. | 67 |
| Figura 30 – Janela de ajuda contextual detalhada. | 68 |
| Figura 31 – Fluxos possíveis de operação da ferramenta IDIA. | 69 |
| Figura 32 – Possíveis escolhas corretas de <i>patches</i> | 69 |
| Figura 33 – Imagem original (a) e imagens degradadas por diferentes tipos de desfoque: (b) Gaussiano, (c) horizontal, (d) vertical e (e) diagonal. | 72 |
| Figura 34 – Imagem original (a) e imagens degradadas por diferentes tipos de ruído: (b) Gaussiano, (c) Sal e Pimenta, (d) Poisson e (e) Listras verticais. | 73 |
| Figura 35 – Imagens degradadas por associação de desfoque e ruído: (a) Desfoque Gaussiano e ruído gaussiano, (b) Desfoque vertical e ruído Sal e Pimenta, (c) Desfoque horizontal e ruído Poisson, (d) Desfoque diagonal e listras verticais. | 73 |
| Figura 36 – Imagem original, imagem pré-processada com desfoque leve e resultado da deconvolução por Filtro Inverso. | 74 |
| Figura 37 – Imagem original, imagem pré-processada com desfoque leve e resultado da deconvolução por Wiener. | 75 |
| Figura 38 – Imagem original, imagem pré-processada com desfoque leve e resultado da deconvolução por RL. | 76 |
| Figura 39 – Imagem original, imagem pré-processada com desfoque leve e resultado da deconvolução por RL+TV. | 76 |
| Figura 40 – Imagem original, imagem pré-processada com desfoque leve e resultado da deconvolução por DIP (iteração 1855). | 77 |
| Figura 41 – Comparativo visual entre os resultados dos cinco métodos de deconvolução. | 77 |
| Figura 42 – Imagem original, imagem degradada e resultado da deconvolução por Filtro Inverso na presença de ruído aditivo. | 79 |
| Figura 43 – Imagem original, imagem degradada e resultado da deconvolução por Wiener com ruído aditivo. | 79 |
| Figura 44 – Imagem original, imagem degradada e resultado da deconvolução por RL com ruído aditivo. | 80 |
| Figura 45 – Imagem original, imagem degradada e resultado da deconvolução por RL+TV com ruído aditivo. | 80 |
| Figura 46 – Imagem original, imagem degradada e resultado da deconvolução por DIP com ruído aditivo. | 81 |

| | |
|---|----|
| Figura 47 – Comparativo visual entre os resultados dos cinco métodos com desfoque leve e ruído aditivo. | 81 |
| Figura 48 – Imagem original (a) e versão degradada com desfoque isotrópico intenso (b). | 83 |
| Figura 49 – Resultado da deconvolução com Filtro Inverso. | 83 |
| Figura 50 – Resultado da deconvolução com método de Wiener. | 84 |
| Figura 51 – Resultado da deconvolução com método de Richardson-Lucy. | 84 |
| Figura 52 – Resultado da deconvolução com método RL + TV (iteração 19). | 85 |
| Figura 53 – Resultado da deconvolução com método DIP (iteração 1847). | 85 |
| Figura 54 – Comparativo visual entre os resultados dos cinco métodos de deconvolução no caso de desfoque intenso. | 86 |
| Figura 55 – Resultados do Filtro Inverso para desfoque direcional leve e intenso. . . | 87 |
| Figura 56 – Resultados do método de Wiener para desfoque direcional leve e intenso. . . | 88 |
| Figura 57 – Resultados do método de Richardson-Lucy para desfoque direcional leve e intenso. | 89 |
| Figura 58 – Resultados do método de RL+TV para desfoque direcional leve e intenso. . . | 89 |
| Figura 59 – Resultados do método DIP para desfoque direcional leve e intenso. . . | 90 |
| Figura 60 – Imagem original, imagem degradada e resultado da deconvolução com RL partindo de PSF aleatória. | 92 |
| Figura 61 – Imagem original, imagem degradada e resultado da deconvolução com DIP partindo de PSF aleatória. | 92 |
| Figura 62 – Imagem original, imagem degradada e resultado do DIP (1672 iterações) com PSF estimada via RL. | 93 |
| Figura 63 – Comparativo visual entre os resultados dos três métodos com PSF desconhecida. | 93 |
| Figura 64 – Comparativo entre PSFs: real, chute inicial, PSF estimada pelo RL, e PSF usada no DIP. | 94 |

Lista de Tabelas

| | |
|--|----|
| Tabela 1 – Comparativo geral das métricas para o caso de desfoque isotrópico leve. | 78 |
| Tabela 2 – Comparativo geral das métricas para o caso de desfoque isotrópico leve com ruído aditivo. | 82 |
| Tabela 3 – Comparativo geral das métricas para o caso de desfoque isotrópico intenso. | 86 |
| Tabela 4 – Comparativo geral das métricas para desfoque direcional leve e intenso. | 91 |
| Tabela 5 – Comparativo geral das métricas para métodos com PSF desconhecida. | 94 |

Lista de Siglas e Abreviaturas

| | |
|-------|--|
| ADC | <i>Analog-to-Digital Converter</i> |
| AWFI | <i>Advanced Wide Field Imager</i> |
| CBERS | <i>China-Brazil Earth Resources Satellite</i> |
| CCD | <i>Charge-Coupled Device</i> |
| CMOS | <i>Complementary Metal-Oxide-Semiconductor</i> |
| CNSA | <i>China National Space Administration</i> |
| EAP | <i>Estrutura Analítica do Projeto</i> |
| ESA | <i>European Space Agency</i> |
| ESF | <i>Edge Spread Function</i> |
| FFT | <i>Fast Fourier Transform</i> |
| FSIM | <i>Feature Similarity Index</i> |
| FI | <i>Filtro Inverso</i> |
| FWHM | <i>Full Width at Half Maximum</i> |
| IDIA | <i>Integrated Deconvolution and Image Analysis</i> |
| INPE | <i>Instituto Nacional de Pesquisas Espaciais</i> |
| LPIPS | <i>Learned Perceptual Image Patch Similarity</i> |
| LSF | <i>Line Spread Function</i> |
| MAD | <i>Mediana Absoluta das Diferenças</i> |
| MSE | <i>Mean Squared Error</i> |
| MTF | <i>Modulation Transfer Function</i> |
| NASA | <i>National Aeronautics and Space Administration</i> |
| NDVI | <i>Normalized Difference Vegetation Index</i> |
| NDWI | <i>Normalized Difference Water Index</i> |
| NRMSE | <i>Normalized Root Mean Squared Error</i> |
| OLI | <i>Operational Land Imager</i> |
| PSF | <i>Point Spread Function</i> |
| PSNR | <i>Peak Signal-to-Noise Ratio</i> |
| SSIM | <i>Structural Similarity Index</i> |
| TDI | <i>Time Delay and Integration</i> |
| TIRS | <i>Thermal Infrared Sensor</i> |
| USGS | <i>United States Geological Survey</i> |

Lista de Publicações

Felipe de Luca Visioli, Tatiana F. P. A. T. Pazelli, **Comparative Analysis of Deconvolution Methods for Remote Sensing Image Restoration**, In: III Brazilian Aerospace Congress (CAB), Brasília, Brazil, 2025, ISBN 978-65-272-2079-4. DOI: 10.29327/9786527220794.1443106. Disponível em: <https://www.even3.com.br/anais/iii-congresso-aeroespacial-brasileiro/1443106-comparative-analysis-of-deconvolution-methods-for-remote-sensing-image-restoration>.

Sumário

| | | |
|-------|---|----|
| 1 | INTRODUÇÃO | 16 |
| 1.1 | Contribuições | 18 |
| 2 | REVISÃO DE LITERATURA | 19 |
| 3 | DADOS DE SENSORIAMENTO REMOTO | 22 |
| 4 | A CONVOLUÇÃO | 24 |
| 4.1 | Convolução no espaço da frequência | 26 |
| 5 | REPRESENTAÇÃO DOS MODELOS DE DISTORÇÃO | 27 |
| 5.1 | Kernel de convolução | 27 |
| 5.2 | Função de Espalhamento de Ponto (PSF) | 28 |
| 5.2.1 | Função de Espalhamento de Borda (ESF) | 29 |
| 5.2.2 | Função de Espalhamento de Linha (LSF) | 30 |
| 6 | DEGRADAÇÃO DE IMAGENS DE SENSORIAMENTO RE- MOTO | 32 |
| 6.1 | Degradações atmosféricas | 33 |
| 6.2 | Distorções ópticas | 34 |
| 6.3 | Distorções por movimento e instabilidades dinâmicas | 36 |
| 6.4 | Ruídos eletrônicos | 37 |
| 6.5 | Implementação dos algoritmos de pré-processamento | 37 |
| 6.5.1 | Algoritmos de desfoque | 37 |
| 6.5.2 | Algoritmos de adição de ruídos | 39 |
| 6.5.3 | Reamostragem | 40 |
| 7 | A DECONVOLUÇÃO | 41 |
| 7.1 | Problema da deconvolução | 41 |
| 7.2 | Deconvolução cega e não cega | 43 |
| 7.3 | Filtro inverso | 43 |
| 7.3.1 | Implementação do filtro inverso | 44 |
| 7.4 | Método de Wiener | 45 |
| 7.4.1 | Implementação do método de Wiener | 46 |
| 7.5 | Método de Richardson-Lucy | 47 |
| 7.5.1 | Implementação do método de Richardson-Lucy | 48 |

| | | |
|--------|---|----|
| 7.6 | Método de Richardson-Lucy com regularização por <i>Total Variation</i> | 49 |
| 7.6.1 | Implementação do método de Richardson-Lucy com regularização por <i>Total Variation</i> | 50 |
| 7.7 | Deconvolução por <i>Deep Image Prior</i> | 51 |
| 7.7.1 | Implementação da deconvolução por <i>Deep Image Prior</i> | 53 |
| 8 | MÉTRICAS | 55 |
| 8.1 | Índice de similaridade estrutural (SSIM) | 55 |
| 8.2 | Relação sinal-ruído de pico (PSNR) | 55 |
| 8.3 | Erro quadrático médio normalizado (NRMSE) | 56 |
| 8.4 | Variância do Laplaciano | 56 |
| 8.5 | Largura a meia altura (FWHM) | 56 |
| 9 | CONSTRUÇÃO DE FERRAMENTA INTEGRADA DE PROCESSAMENTO DE IMAGEM | 57 |
| 9.1 | Interface gráfica | 59 |
| 9.2 | Guia rápido do usuário | 68 |
| 10 | ANÁLISE DOS RESULTADOS | 72 |
| 10.1 | Efetividade dos algoritmos de pré-processamento | 72 |
| 10.2 | Deconvolução com PSF conhecida (caso não cego) | 74 |
| 10.2.1 | Desfoque isotrópico leve | 74 |
| 10.2.2 | Desfoque isotrópico leve com ruído aditivo | 78 |
| 10.2.3 | Desfoque isotrópico intenso | 82 |
| 10.2.4 | Desfoque direcional | 87 |
| 10.3 | Deconvolução com PSF desconhecida (caso cego e semi-cego) | 91 |
| 10.4 | Limites dos métodos de deconvolução | 94 |
| 10.5 | Ferramenta de processamento integrada | 95 |
| 11 | CONCLUSÕES | 97 |
| 11.1 | Trabalhos futuros | 98 |
| | REFERÊNCIAS BIBLIOGRÁFICAS | 99 |

1 Introdução

A deconvolução de imagens satelitais é uma área de pesquisa de crescente importância, dado o aumento exponencial na quantidade de dados gerados por satélites de imageamento terrestre. Esses satélites são empregados em uma ampla gama de atividades, incluindo monitoramento ambiental, gestão de recursos naturais, agricultura de precisão, planejamento urbano e resposta a desastres. No entanto, a qualidade das imagens obtidas por sensores ópticos embarcados em satélites é frequentemente degradada por diversos fatores físicos e operacionais, como a dispersão atmosférica, efeitos de difração nos sistemas ópticos e o movimento relativo entre a plataforma orbital e a superfície terrestre. Tais degradações reduzem a resolução e a nitidez das imagens, limitando sua aplicabilidade em análises que demandam alta precisão e resolução (HAJLAOUI et al., 2010).

A dispersão atmosférica ocorre devido à interação da luz com partículas suspensas na atmosfera, resultando em espalhamento e absorção que diminuem o contraste e a nitidez das imagens. Já a difração óptica é consequência das limitações físicas inerentes às lentes e aos sistemas de captura, resultando na focalização imperfeita dos raios de luz, portanto, em perda de definição (JANSSON, 2012). Adicionalmente, o movimento do satélite, em conjunto com o tempo de exposição dos sensores, pode causar borramentos direcionais devido à sobreposição de diferentes posições da cena no instante da captura (GONG et al., 2016). Esses efeitos podem ser modelados por meio de uma função de espalhamento de ponto (PSF, *Point Spread Function*).

A deconvolução de imagens é uma técnica fundamental para recuperar a qualidade visual original, mitigando esses efeitos. Ela busca reverter o processo de degradação, estimando uma imagem mais próxima da ideal a partir da imagem real e, eventualmente, da PSF associada (JANSSON, 2012). Existem diferentes abordagens para esse problema. Dentre os principais destacam-se os métodos não iterativos, como o filtro de Wiener e o filtro inverso, que fornecem soluções rápidas e diretas, mas são sensíveis ao ruído e à modelagem da PSF. Por outro lado, os métodos iterativos, como o algoritmo de Richardson-Lucy e suas variantes com regularização, oferecem maior flexibilidade e controle sobre o processo de restauração. Recentemente, surgiram também técnicas baseadas em redes neurais, como o método *Deep Image Prior* (DIP), que exploram as propriedades estruturais das redes convolucionais para realizar restauração sem exigir dados de treinamento ou conhecimento explícito da PSF (LEMPITSKY; VEDALDI; ULYANOV, 2018).

Apesar dos avanços, a deconvolução apresenta desafios práticos notáveis. A amplificação de ruído, a sensibilidade à PSF e a introdução de artefatos visuais após o processo de restauração são limitações recorrentes. O desempenho dos algoritmos depende fortemente da qualidade da estimativa da PSF, da escolha de parâmetros e do tipo de degradação

envolvida (SOUZA et al., 2021). Tais fatores tornam essencial a existência de ferramentas que permitam testar, comparar e ajustar metodologias de forma controlada, sistemática e visualmente assistida, tal como a que será apresentada nessa obra.

Este trabalho propõe a análise comparativa de diferentes métodos de deconvolução, com foco na aplicação prática e na avaliação de desempenho em diversas condições que emulam contextos reais. Além do desenvolvimento e da aplicação de uma ferramenta computacional integrada para a realização dos testes. O foco está em avaliar o desempenho dos algoritmos sob diferentes condições de borramento e ruído, considerando tanto cenários com PSF conhecida, caso clássico (não cego), quanto PSF desconhecida (caso cego e semi-cego). Para isso, são analisados algoritmos clássicos, regularizados e modernos, incluindo a associação híbrida entre métodos iterativos e redes neurais.

Ao longo da execução do projeto, foi possível aprofundar conceitos fundamentais de processamento digital de imagens, sistemas de aquisição de dados em sensoriamento remoto, e técnicas de restauração baseadas em convolução e aprendizado profundo. Além disso, a implementação da ferramenta promoveu o enriquecimento prático em programação científica, manipulação de imagens e desenvolvimento de interfaces interativas voltadas à experimentação e análise comparativa.

O trabalho está organizado em onze capítulos, que juntos constroem a base para a compreensão e aplicação das técnicas de deconvolução em imagens de sensoriamento remoto. O Capítulo 2 apresenta a revisão bibliográfica, abordando os principais conceitos e avanços relacionados ao sensoriamento remoto, formação de imagens e métodos de restauração. O Capítulo 3 trata especificamente das características dos dados obtidos por sensores orbitais, destacando seus formatos, resoluções e peculiaridades. Em seguida, o Capítulo 4 introduz os fundamentos da convolução no contexto da formação de imagens, estabelecendo a base matemática para os modelos de distorção apresentados no Capítulo 5.

O Capítulo 6 discute os principais mecanismos responsáveis pela degradação de imagens no sensoriamento remoto, contextualizando fisicamente os modelos abordados anteriormente. A partir disso, o Capítulo 7 concentra-se nos métodos de deconvolução propriamente ditos, com ênfase em algoritmos clássicos, iterativos e modernos. As métricas utilizadas para avaliação objetiva da restauração são discutidas no Capítulo 8, que estabelece critérios quantitativos para análise comparativa. O Capítulo 9 descreve a ferramenta computacional desenvolvida, destacando sua estrutura modular, funcionalidades e importância prática para os testes realizados.

No Capítulo 10, apresenta-se uma análise sistemática dos resultados obtidos com a aplicação dos métodos em diferentes cenários de degradação, contemplando casos com e sem ruído, com PSF conhecida ou estimada. Por fim, o Capítulo 11 reúne as conclusões obtidas, discutindo as limitações dos métodos analisados, a relevância da ferramenta desenvolvida e sugestões de trabalhos futuros que podem expandir e aprofundar a presente

pesquisa.

1.1 Contribuições

Considerando o contexto apresentado, nesse trabalho:

- Implementou-se e testou-se algoritmos clássicos, regularizados e baseados em aprendizado profundo, adaptando seus parâmetros para diferentes condições de desfoque e ruído;
- Realizou-se análises comparativas fundamentadas em métricas quantitativas e observações visuais, investigando o desempenho e os limites de cada método em diferentes cenários de aplicação;
- Avaliou-se a eficácia dos métodos de deconvolução em termos de melhoria da resolução espacial, aumento do contraste e existência de artefatos, comparando-os.

2 Revisão de Literatura

A restauração de imagens degradadas por desfoque e ruído constitui um desafio clássico na área de processamento de imagens, com aplicações que vão desde a astronomia até a tomografia médica. Diversas estratégias têm sido propostas nas últimas décadas, com ênfase particular em métodos iterativos, técnicas de regularização e abordagens bayesianas para deconvolução cega. Esta seção apresenta um panorama crítico dos principais trabalhos e avanços sobre o tema.

Fish, Brinicombe e Pike (1995) propuseram uma extensão do algoritmo de Richardson–Lucy voltada à deconvolução cega. O trabalho se destacou por demonstrar que, mesmo sem conhecimento exato da função de espalhamento do ponto (PSF), é possível obter resultados comparáveis aos de métodos com PSF conhecida, desde que se imponham restrições apropriadas ao modelo. Esse estudo teve impacto relevante ao mostrar que, mesmo em ambientes ruidosos, a abordagem iterativa é robusta e fornece estimativas satisfatórias da imagem original e da PSF.

Já o trabalho de UmaDevi e Sudhamathi (2014), no contexto da restauração de imagens com ruído aditivo branco e desfoque por movimento, propõe a combinação da deconvolução de Richardson–Lucy com técnicas de desfocagem difusa baseada em lógica Fuzzy. A proposta é especialmente relevante em situações em que há movimentos reticulares complexos e sobreposição de múltiplas fontes de ruído, como ocorre frequentemente em sistemas de aquisição com sensores de baixa fidelidade. Os autores ainda discutem métodos híbridos de aquisição, evidenciando a crescente integração entre *hardware* e *software* para viabilizar processos de restauração mais eficientes.

Outra contribuição relevante está no artigo de Shan, Jia e Agarwala (2008), que propôs um modelo probabilístico unificado para a estimativa simultânea do núcleo de desfoque e da imagem latente não desfocada. O trabalho é particularmente importante por abordar um dos principais problemas em deconvolução cega, o surgimento de artefatos visuais como *ringing*. Os autores introduzem termos adicionais no modelo probabilístico, inspirados na análise da distribuição do ruído e na suavidade local da imagem. Como resultado, obtiveram reconstruções de alta qualidade com baixo tempo computacional, comparáveis a técnicas que exigem múltiplas imagens ou dispositivos auxiliares.

No que tange à regularização, o trabalho de Beck e Teboulle (2009) oferece uma análise abrangente da aplicação da penalização por variação total (*Total Variation* – TV) com penalização L_1 adaptativa. Essa abordagem tem se mostrado eficaz na preservação de bordas e detalhes finos da imagem, ao mesmo tempo em que promove a supressão de ruído em regiões homogêneas. A aplicabilidade da técnica é confirmada por sua integração a diversos algoritmos de deconvolução, incluindo o próprio Richardson–Lucy, como

mostrado por Temerinac-Ott et al. (2011).

No campo da estimativa de PSF, destacam-se os trabalhos de Penalosa, Koay e Song (2015) e Viallefont-Robinet et al. (2018), que discutem abordagens baseadas em aprendizado de máquina e análise de perfis de borda para inferência da PSF em imagens científicas e astronômicas. Essas técnicas têm ganhado espaço devido à dificuldade de obtenção direta da PSF, especialmente em sistemas com óptica complexa ou sujeitos a perturbações ambientais.

Ainda na linha de avaliação da qualidade das imagens restauradas, o artigo de Baraldi et al. (2004) propõe o uso da MTF como métrica para comparar diferentes técnicas de fusão e restauração. Os autores sugerem que a distância entre curvas de MTF pode servir como um critério quantitativo para avaliar a qualidade geométrica de imagens restauradas. Essa abordagem se diferencia de métricas tradicionais como PSNR ou SSIM, por estar mais alinhada com a percepção humana de nitidez espacial.

Outro trabalho que merece destaque é o de Gong et al. (2016), que realiza uma análise comparativa entre métodos iterativos de deconvolução com foco em imagens degradadas por desfoque de movimento. Os autores exploram o uso de regularização espacialmente adaptativa para mitigar o problema da superestimação do ruído em regiões homogêneas. A principal contribuição do artigo está na proposta de uma estrutura iterativa que integra suavização adaptativa e regularização baseada em estatísticas locais, melhorando a precisão da reconstrução mesmo sob condições de ruído não estacionário.

Huang e al. (2022) propõem um novo método baseado em superamostragem adaptativa para a extração precisa da MTF a partir de perfis de borda em imagens reais. A técnica diferencia-se por permitir a avaliação da qualidade espacial de sistemas ópticos sem a necessidade de alvos específicos ou ambientes controlados. Essa proposta se mostra relevante para validar algoritmos de restauração aplicados a imagens adquiridas em campo, como as obtidas por satélites de observação da Terra ou dispositivos médicos móveis.

Outro avanço significativo está descrito em Hajlaoui, Krichen e Bouhleb (2010), onde é introduzido um método de restauração iterativa com base Bayesiana que incorpora conhecimento prévio sobre o conteúdo da imagem e da PSF. A inovação do trabalho reside na formulação probabilística do problema, permitindo estimativas mais robustas da imagem mesmo quando a PSF está sujeita a variações significativas ao longo da imagem (caso de borramento espacialmente variante).

Finalmente, Cho e Lee (2015) apresentam um levantamento detalhado das técnicas de remoção de desfoque por movimento, categorizando os métodos em duas classes principais: *deblurring* espacialmente invariante e espacialmente variante. O estudo destaca que métodos invariantes assumem um único kernel para toda a imagem, o que é limitante em casos de desfoque causado por tremores complexos de câmera. Por outro lado, os métodos variantes, embora mais robustos e acurados, exigem maior poder computacional

e informações adicionais, como sensores inerciais ou múltiplas exposições.

A literatura revisada evidencia a complexidade do problema de restauração de imagens e a multiplicidade de técnicas aplicáveis, especialmente no contexto da deconvolução cega. Os avanços recentes combinam técnicas clássicas com inovações baseadas em aprendizado, otimização bayesiana e modelos físicos rigorosos.

Nos Capítulos a seguir, serão discutidas as abordagens metodológicas adotadas, seus desdobramentos práticos e, posteriormente, a avaliação e comparação das técnicas de deconvolução adotadas.

3 Dados de Sensoriamento Remoto

O acesso a coleções de dados satelitais é essencial para aplicações de sensoriamento remoto, especialmente na área de restauração de imagens, em que se busca recuperar informações degradadas por fatores físicos, ópticos ou atmosféricos. Satélites equipados com sensores de alta precisão monitoram continuamente a superfície terrestre, e os dados coletados são armazenados por agências espaciais e instituições privadas em plataformas, por vezes de acesso gratuito. Essas plataformas fornecem uma base de imagens fundamentais para análises científicas em diversas áreas, como agricultura, geoprocessamento, climatologia e detecção de mudanças ambientais.

Entre os principais provedores de dados destaca-se o Sentinel Hub EO Browser, uma ferramenta interativa e acessível que permite a visualização e o processamento de imagens satelitais diretamente no navegador. Essa plataforma integra dados das missões Sentinel, permitindo o acesso a imagens históricas e atuais, com visualização em diferentes bandas espectrais, aplicação de índices (como NDVI, NDWI, entre outros) e exportação de imagens em múltiplos formatos. Sua interface intuitiva democratiza o uso de dados de sensoriamento remoto, antes restrito a bancos de dados privados.

Complementarmente, destaca-se a *Satellite Imaging Corporation*, que oferece uma ampla variedade de produtos geoespaciais de alta resolução. A empresa disponibiliza imagens provenientes de satélites renomados como WorldView, GeoEye, Pleiades e KOMPSAT, com resoluções que podem atingir até 30 centímetros. Além da aquisição de imagens atualizadas sob demanda, a plataforma fornece serviços especializados como ortorretificação, mosaico, classificação e análise multitemporal. Seu portfólio gratuito atende às demandas de diversas aplicações, como a desse trabalho.

Compreender as características dos satélites que originam essas imagens é crucial para compreender as limitações impostas por cada sistema de imageamento. Fatores como a finalidade da missão, a arquitetura óptica dos sensores, a resolução espacial, espectral, radiométrica e temporal, bem como o tipo de telescópio e o padrão orbital, influenciam diretamente a qualidade e o tipo de degradação presente nas imagens adquiridas. Assim, familiarizar-se com as missões satelitais mais relevantes é uma etapa essencial para fundamentar estudos de restauração e realce de imagens degradadas.

No contexto internacional, diversas missões se destacam por sua longevidade, abrangência e qualidade de dados:

- **Landsat:** Operado pela NASA (*National Aeronautics and Space Administration*) em parceria com o USGS (*United States Geological Survey*), o programa Landsat fornece imagens desde 1972. As versões mais recentes, Landsat 8 e 9, estão equipadas com os sensores OLI (*Operational Land Imager*) e TIRS (*Thermal Infrared Sensor*),

que possibilitam a captura de imagens multiespectrais com resolução espacial de 30 metros e pancromáticas de 15 metros. As bandas térmicas são adquiridas a 100 metros e reamostradas para 30 metros nos produtos finais. A série Landsat é considerada referência global em dados contínuos de uso da terra, com revisita de 16 dias e amplo acervo histórico (USGS, 2021).

- **Sentinel-2:** Parte do programa europeu Copernicus, coordenado pela ESA (*European Space Agency*), abrange satélites com propósitos distintos. O Sentinel-2 é equipado com o sensor MSI (*MultiSpectral Instrument*), que captura 13 bandas espectrais com resoluções espaciais de 10, 20 e 60 metros, cobrindo desde o visível até o infravermelho de ondas curtas. Esses satélites apresentam alta frequência de revisita (até 5 dias) e cobertura global sistemática (COPERNICUS DATA SPACE ECOSYSTEM, 2023).
- **WorldView-3:** Série de satélites operada pela empresa norte-americana DigitalGlobe, destaca-se por oferecer as imagens comerciais de mais alta resolução disponíveis, atingindo até 31 centímetros no modo pancromático, 1,24 metros nas bandas multiespectrais e 3,7 metros no infravermelho de ondas curtas (SWIR). Essa resolução permite aplicações precisas em áreas urbanas, planejamento territorial, segurança e inteligência geoespacial (MAXAR TECHNOLOGIES, 2023).

No cenário nacional, o Brasil tem ampliado sua atuação no setor espacial por meio de missões próprias e acordos de cooperação internacional:

- **CBERS** (*China-Brazil Earth Resources Satellite*): Fruto da parceria entre o INPE (Instituto Nacional de Pesquisas Espaciais) e a CNSA (*China National Space Administration*), a série CBERS visa ao monitoramento de recursos naturais e uso da terra. O CBERS-4 está equipado com câmeras multiespectrais (MUX, WFI e PAN) com resoluções variando entre 5 e 64 metros (CEOS, 2023).
- **Amazônia-1:** Lançado em 2021, representa o primeiro satélite de observação da Terra completamente projetado, integrado e operado pelo Brasil. Conta com a câmera AWFII (*Advanced Wide Field Imager*), que oferece imagens com resolução espacial de 60 metros e ampla largura de faixa (850 km), permitindo cobrir o território nacional em poucos dias. O satélite visa monitorar o desmatamento da Amazônia e apoiar aplicações ambientais e agrícolas (INPE, 2021).

A qualidade das imagens oriundas desses satélites pode variar conforme as condições atmosféricas, a geometria de aquisição e a resposta espectral dos sensores. Essas variabilidades afetam diretamente a aplicação de algoritmos de restauração, como os baseados em deconvolução cega, os quais dependem do correto conhecimento ou da correta estimativa da PSF associada ao sistema de aquisição.

4 A convolução

A operação de convolução é uma ferramenta central da análise matemática e do processamento de sinais. No contexto unidimensional contínuo, a convolução entre duas funções $f(x)$ e $h(x)$, denotada por $f \otimes h$ neste trabalho, é definida pela Eq. (4.1) como a integral do produto entre uma das funções e a versão refletida da outra em torno da origem (JANSSON, 2012).

$$(f \otimes h)(x) = \int_{-\infty}^{+\infty} f(x') \cdot h(x - x') dx' \quad (4.1)$$

Essa operação pode ser interpretada como um processo de ponderação. Isso ocorre porque o valor de saída em um ponto x da convolução incorpora não apenas o valor de f naquele ponto, mas também valores de sua vizinhança, ponderados pela forma de h (JANSSON, 2012). Sumariamente, em termos práticos, convoluir é agregar informações locais de forma ponderada.

A convolução possui propriedades matemáticas fundamentais, entre elas a comutatividade, que garante a igualdade mostrada pela Eq. (4.2):

$$f \otimes h = h \otimes f \quad (4.2)$$

Além disso, ela é associativa e distributiva, o que permite composições de operações convolucionais com flexibilidade algébrica.

A Figura 1 ilustra visualmente o processo de convolução de dois sinais unidimensionais, sendo eles um retângulo (em vermelho) e um triângulo (em azul). Nas etapas inferiores da figura, observa-se o deslocamento de um dos sinais e o cálculo da área de sobreposição, mostrado em verde. A curva verde gerada representa o valor da convolução $(f \otimes h)(t)$ ao longo do tempo. O gráfico evidencia como a integral do produto entre os dois sinais, à medida que um é transladado, resulta em uma nova função.


De modo análogo à definição unidimensional, a convolução bidimensional entre uma função $f(x, y)$, como uma imagem, e um núcleo $h(x, y)$, como um filtro ou operador de suavização, é expressa como na Eq. (4.3) (JANSSON, 2012).

$$(f \otimes h)(x, y) = \iint_{-\infty}^{+\infty} f(x', y') \cdot h(x - x', y - y') dx' dy' \quad (4.3)$$

No contexto do processamento digital de imagens, essa operação é aplicada de forma discreta. A função $f(x, y)$ representa uma imagem bidimensional, enquanto o núcleo $h(x, y)$, também chamado de kernel, é uma matriz de pesos que determina como os valores vizinhos influenciam a produção do novo valor no ponto (x, y) (JANSSON, 2012).

A Figura 2 ilustra esse processo. À esquerda, a matriz $f(x, y)$ representa uma imagem e o bloco $h(x, y)$ representa o kernel de convolução já refletido (inverso em ambos os


Figura 1 – Visualização do processo de convolução unidimensional.



Fonte: Zhang e Wu (2011).

eixos). O núcleo $h(x, y)$ é transladado sobre a imagem e multiplicado ponto a ponto com a vizinhança correspondente de $f(x, y)$. A soma dos produtos fornece o valor da nova imagem $g(x, y)$ no pixel correspondente, neste caso, o valor 15 no pixel central. Esse processo é repetido para todos os pixels da imagem de entrada, gerando uma nova imagem convoluída.

Figura 2 – Visualização do processo de convolução bidimensional.



Fonte: Autoria Própria.

4.1 Convolução no espaço da frequência

A convolução no domínio espacial possui uma importante equivalência no domínio da frequência, formalizada pelo Teorema da Convolução (JANSSON, 2012). Segundo ele, a convolução de duas funções no espaço é transformada na multiplicação dos espectros no domínio da frequência. Sejam $f(x)$ e $h(x)$ duas funções com transformadas de Fourier $F(\omega)$ e $H(\omega)$, respectivamente, logo, é verdadeira a Eq. (4.4).

$$\mathcal{F}\{f \otimes h\} = \mathcal{F}\{f\} \cdot \mathcal{F}\{h\} = F(\omega) \cdot H(\omega) \quad (4.4)$$

No caso bidimensional, essa relação generaliza-se como na Eq. (4.5):

$$\mathcal{F}\{f \otimes h\}(u, v) = F(u, v) \cdot H(u, v) \quad (4.5)$$

Essa propriedade é amplamente explorada em aplicações computacionais, pois permite que a operação de convolução, originalmente laboriosa e com alta complexidade computacional, seja realizada de maneira muito mais eficiente por meio da Transformada Rápida de Fourier (FFT) (JANSSON, 2012).

5 Representação dos modelos de distorção

A degradação de imagens obtidas por sensores remotos pode ser formalmente representada por meio de modelos convolucionais (HAJLAOUI et al., 2010). Tais modelos assumem que o processo de aquisição pode ser descrito como um sistema linear e invariante no espaço, no qual a energia de um ponto da cena é espalhada sobre uma vizinhança local (JANSSON, 2012).

Esse espalhamento é governado por uma função específica que caracteriza a natureza da distorção, seja ela óptica, atmosférica ou cinemática. No domínio discreto, esse papel é assumido por um kernel, enquanto no contínuo, por uma função de espalhamento, como a PSF. Em ambos os casos, a modelagem permite encapsular matematicamente os efeitos de borramento, perda de contraste e suavização que ocorrem durante a formação da imagem no sensor (JANSSON, 2012).

5.1 Kernel de convolução

O *kernel* é uma matriz discreta que representa um operador linear aplicado a uma imagem digital. No processamento digital de imagens, os kernels são amplamente utilizados para simular operações como suavização, realce, detecção de bordas e introdução de desfoque (*blur*). Essas operações podem ser executadas por meio da convolução discreta entre o kernel e a imagem-alvo, conforme a Eq. 5.1:

$$g[m, n] = \sum_{i=-a}^a \sum_{j=-b}^b f[m-i, n-j] \cdot k[i, j] \quad (5.1)$$

onde $f[m, n]$ representa a imagem original, $k[i, j]$ o kernel aplicado, e $g[m, n]$ o resultado convoluído. O tamanho do kernel é geralmente pequeno em relação à imagem, e os índices a e b definem sua extensão nas direções horizontal e vertical, respectivamente.

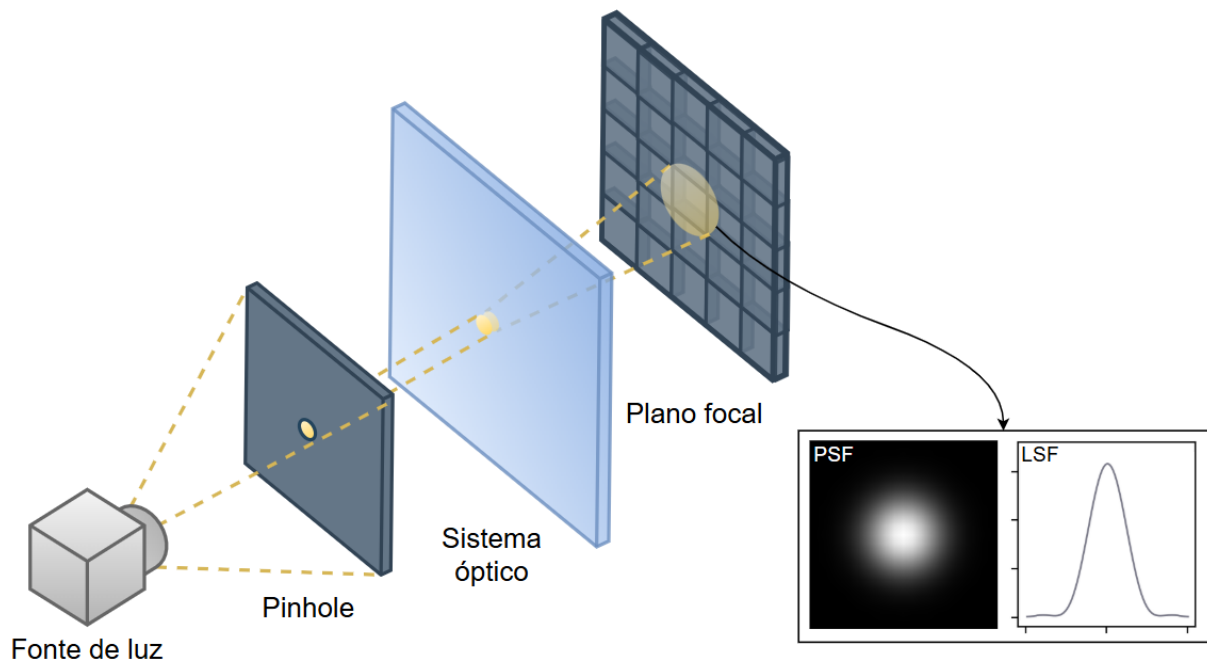
A escolha do kernel determina a natureza da operação. Um kernel Gaussiano, por exemplo, promove suavização com preservação de bordas suaves. Já kernels Laplacianos ou de Sobel são utilizados para realce e detecção de bordas. Para tarefas específicas como ajuste de PSF, o uso de kernels experimentais ou teóricos padronizados, permite simular as distorções induzidas (PixeDFit, 2023).

5.2 Função de Espalhamento de Ponto (PSF)

A *Point Spread Function* (PSF) é uma representação contínua do efeito de espalhamento causado por um sistema óptico real sobre um ponto ideal da cena. Em outras palavras, ela descreve como a energia luminosa proveniente de um ponto é distribuída na imagem capturada, como resultado de limitações do sistema de formação de imagem, incluindo difração, aberrações ópticas, desfoques e características do detector utilizado (HAJLAOUI et al., 2010).

Idealmente, um ponto infinitesimal da cena seria projetado como um único ponto no plano da imagem. No entanto, devido à natureza imperfeita dos sistemas ópticos e às condições de observação, esse ponto é difundido, originando uma função de espalhamento. A PSF é, portanto, o núcleo de convolução que modela essa degradação contínua, como ilustrado na Figura 3, em que uma fonte de luz pontual (pinhole menor que o pixel do detector) é projetada através de um sistema óptico e registrada no plano focal.

Figura 3 – Esquema de medição da PSF utilizando uma fonte de luz pontual.



Fonte: Autoria Própria.

Na prática, a PSF pode ser estimada diretamente por métodos ópticos ou indiretamente a partir de bordas e linhas da imagem (VIALLEFONT-ROBINET et al., 2018). Com base na forma, extensão e simetria da PSF, é possível avaliar a nitidez, a presença de aberrações e a fidelidade da reconstrução espacial realizada pelo sensor. Além disso, a PSF permite estimar métricas quantitativas como a função de transferência de modulação (MTF, *Modulation Transfer Function*), utilizada na caracterização da resolução espacial do sistema (BURTON; LALOR, 2015). Assim, a PSF fornece as bases para o desenvol-

vimento de algoritmos de restauração de imagem, como os de deconvolução, além de ser indispensável para processos de calibração, simulação e correção de sistemas ópticos.


A avaliação quantitativa da qualidade espacial de sistemas de aquisição de imagem se beneficia de funções métricas capazes de descrever com precisão o comportamento do sistema frente a estruturas ideais. Entre essas métricas, destacam-se a *Edge Spread Function* (ESF) e a *Line Spread Function* (LSF), que permitem caracterizar a resposta do sistema a estímulos pontuais ou de borda (VIALLEFONT-ROBINET et al., 2018).

5.2.1 Função de Espalhamento de Borda (ESF)

A *Edge Spread Function* (ESF), ou função de espalhamento de borda, é uma medida útil para a caracterização da resposta espacial de um sistema de aquisição de imagem. Ela descreve como uma transição abrupta de intensidade (borda ideal) é registrada pelo sensor, considerando os efeitos de degradação (VIALLEFONT-ROBINET et al., 2018). Na prática, a ESF é obtida a partir da resposta do sistema a uma borda de alto contraste, como a que ocorre entre uma região clara e uma região escura.

A ESF é representada como uma curva que expressa a variação da intensidade digital (DN) dos pixels ao longo de uma linha perpendicular à borda. Como ilustrado na Figura 4, a imagem apresenta uma borda vertical, e a função resultante (em laranja) representa os valores de intensidade ao longo da linha escolhida.

Figura 4 – Representação da função de espalhamento de borda (ESF).



Fonte: Autoria própria.

Idealmente, um sistema óptico perfeito registraria a borda como uma transição instantânea entre dois níveis de intensidade, resultando em uma ESF no formato de degrau. No entanto, limitações físicas produzem uma transição suavizada. Quanto maior a capacidade do sistema de transmitir contraste em diferentes frequências espaciais, mais abrupta será essa transição, e mais próxima do perfil de um degrau será a ESF obtida.

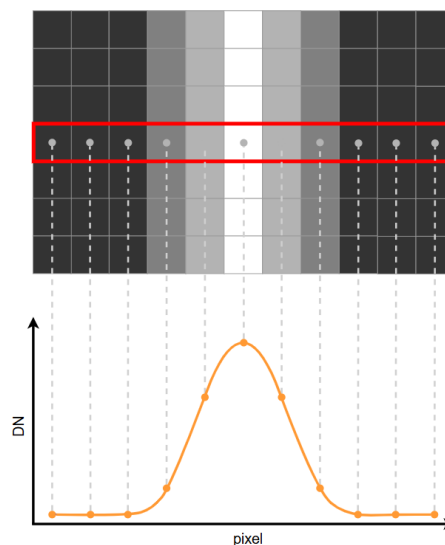
A transição suave observada na curva ESF é resultado da convolução da borda ideal com a função de espalhamento de ponto (PSF) do sistema. Por esse motivo, a ESF serve como base para o cálculo de outras métricas fundamentais. Sua derivada fornece a *Line Spread Function* (LSF), e a transformada de Fourier da LSF define a *Modulation Transfer Function* (MTF), que quantifica a capacidade do sistema de preservar diferentes frequências espaciais. Assim, a ESF é frequentemente utilizada como etapa intermediária para a estimativa da resolução espacial e da nitidez de sensores ópticos (VIALLEFONT-ROBINET et al., 2018).

5.2.2 Função de Espalhamento de Linha (LSF)

A *Line Spread Function* (LSF), ou função de espalhamento de linha, descreve como um sistema de imagem responde à presença de uma linha infinitamente fina de intensidade luminosa sobre um fundo escuro (VIALLEFONT-ROBINET et al., 2018). Na prática, essa função representa a distribuição espacial da energia de uma linha ao longo do eixo perpendicular a ela, revelando diretamente a influência da PSF sobre estruturas lineares da imagem (BURTON; LALOR, 2015).

A LSF é obtida como a derivada espacial da ESF, sendo, portanto, sensível à inclinação da transição de borda (VIALLEFONT-ROBINET et al., 2018). Ela fornece uma representação mais direta da dispersão espacial causada pelo sistema, indicando com precisão a largura da resposta a uma transição abrupta. A Figura 5 ilustra esse conceito, em que a resposta luminosa de uma linha estreita se distribui sobre diversos pixels adjacentes. A curva laranja representa a intensidade medida ao longo da linha selecionada, evidenciando a dispersão lateral do sinal.

Figura 5 – Representação da função de espalhamento de linha (LSF).



Fonte: Autoria própria.

Quanto mais estreita e simétrica for a LSF, maior será a capacidade do sistema de preservar detalhes espaciais finos, como linhas, contornos e texturas (BURTON; LALOR, 2015). Uma LSF alargada indica perda de nitidez e maior grau de borramento. A análise da LSF permite, portanto, avaliar diretamente a resolução espacial efetiva de um sistema óptico.

A LSF também constitui a base para o cálculo da MTF, sendo sua transformada de Fourier. Como a LSF está associada à resposta pontual do sistema a uma linha, sua forma é diretamente impactada por distorções, ruídos e características da PSF (VIALLEFONT-ROBINET et al., 2018).

6 Degradação de Imagens de Sensoriamento Remoto


Imagens obtidas por satélites de observação da Terra estão sujeitas a diversos tipos de degradações que comprometem sua qualidade e limitam seu uso em aplicações analíticas. Essas degradações podem ter origem em fatores ópticos, atmosféricos, eletrônicos ou mecânicos, afetando atributos como nitidez, contraste, resolução espacial e espectral. A compreensão dos mecanismos de degradação é fundamental para o desenvolvimento de técnicas eficazes de restauração.

Independentemente de sua origem física, as degradações podem ser formalizadas matematicamente como o resultado da convolução da imagem ideal $f(x, y)$ com um *kernel* de degradação $h(x, y)$, comumente referido como PSF. Esse modelo assume que o sistema de formação da imagem é linear e invariante no espaço, ao menos em primeira aproximação (JANSSON, 2012). Assim, a imagem observada $g(x, y)$ pode ser expressa como na Eq. 6.1.

$$g(x, y) = f(x, y) \otimes h(x, y) + n(x, y) \quad (6.1)$$

onde \otimes denota a operação de convolução bidimensional e $n(x, y)$ representa o ruído aditivo, geralmente de natureza eletrônica ou estatística. De forma visual, a formação de uma imagem pode ser apresentada como na Figura 6.

Figura 6 – Modelo de formação de imagem em sistemas de sensoriamento remoto.




Fonte: Autoria própria.

As degradações atmosféricas provocam distorções cromáticas e suavização de bordas. Essas distorções são espacialmente distribuídas e podem ser representadas por um *kernel* atmosférico, que, em aplicações práticas, costuma ser assumido como homogêneo em pequenas regiões da imagem (RUCCI et al., 2022). A PSF atmosférica resultante incorpora tais efeitos de espalhamento e, por vezes, assume formato anisotrópico (espalhamento varia dependendo da direção em que é medido).

Degradações de natureza cinemática orbital, como o *motion blur*, ocorrem devido ao deslocamento relativo entre o sensor e a cena durante o tempo de exposição (TAN; LIM;

TAN, 1991). Esse tipo de desfoque é comum em satélites com sensores do tipo *push-broom*, em que instabilidades na trajetória da plataforma ou vibrações mecânicas podem induzir deslocamentos na cena capturada. O *kernel* associado ao desfoque por movimento geralmente assume a forma de uma função retangular ou gaussiana alongada, alinhada com a direção do deslocamento aparente. A Figura 7 ilustra alguns casos de *kernels* que resultam em desfoque de movimento.

Figura 7 – Exemplos de imagens degradadas por diferentes tipos de *motion blur*.



Fonte: Autoria própria.

Portanto, a modelagem da imagem observada como uma convolução entre a imagem ideal e uma PSF agregada permite encapsular os efeitos de degradação atmosférica, cinemática e óptica, tratadas mais a fundo a seguir. Essa representação é a base para o desenvolvimento de algoritmos de deconvolução, que visam estimar a imagem ideal $f(x, y)$ a partir do conhecimento ou estimativa da PSF $h(x, y)$.

6.1 Degradações atmosféricas

A interação da radiação eletromagnética com os constituintes atmosféricos é um dos principais fatores responsáveis pela degradação das imagens adquiridas por sensores orbitais. Fenômenos como absorção e dispersão atmosférica modificam a intensidade e a direção da luz que chega ao sensor, comprometendo atributos essenciais da imagem, como

contraste, nitidez e fidelidade espectral. O entendimento detalhado desses efeitos é fundamental para o correto processamento e interpretação dos dados obtidos por satélites de sensoriamento remoto.

A absorção atmosférica ocorre quando a radiação eletromagnética interage com moléculas de gases como oxigênio (O_2), ozônio (O_3), dióxido de carbono (CO_2) e vapor d'água (H_2O), sendo parcialmente absorvida e convertida em outras formas de energia, como calor. Esse processo reduz a intensidade da luz que atinge a superfície terrestre e, posteriormente, o sensor. O grau de absorção depende do comprimento de onda λ , da composição atmosférica e do ângulo de incidência θ . Essa atenuação pode ser quantificada pelo coeficiente de absorção $\tau(\lambda, \theta)$, o qual varia espacial e temporalmente (KAUFMAN, 1984).

A dispersão atmosférica, por sua vez, refere-se ao espalhamento da luz quando esta interage com partículas atmosféricas cujas dimensões são comparáveis ou menores que o comprimento de onda da radiação incidente. A dispersão de Rayleigh, dominante em atmosferas limpas, ocorre com partículas muito menores que o comprimento de onda, afetando principalmente as bandas do azul e do ultravioleta. Já a dispersão de Mie, relevante em ambientes com maior concentração de aerossóis, atua em faixas mais amplas do espectro e é menos dependente do comprimento de onda. Ambos os mecanismos desviam a luz da trajetória original, provocando perda de contraste, perda de brilho e suavização de detalhes finos da cena (KAUFMAN, 1984).

A compensação desses efeitos pode ser feita por meio de modelos de correção atmosférica, como os baseados na equação de transferência radiativa. Tais modelos estimam a quantidade de radiação absorvida e dispersada ao longo do caminho óptico, permitindo recuperar a reflectância de superfície a partir da radiância medida no topo da atmosfera (KAUFMAN, 1984). Alternativamente, técnicas de restauração por deconvolução, como as abordadas neste trabalho, tratam as distorções como o resultado de uma convolução espacial com uma função de espalhamento (PSF) associada. Ao aplicar algoritmos iterativos de deconvolução, é possível recuperar a imagem original, mitigando os efeitos degradantes impostos pelo meio atmosférico (JANSSON, 2012).

6.2 Distorções ópticas

As imagens capturadas por sensores orbitais estão sujeitas a diversas degradações de natureza óptica, que comprometem a formação da imagem no plano do detector. Essas degradações incluem principalmente os efeitos de difração e aberrações ópticas, e podem ser modeladas por meio da Função de Espalhamento de Ponto (JANSSON, 2012).

A PSF depende diretamente da geometria e da qualidade do sistema óptico. No caso ideal, sem imperfeições, a PSF seria uma função centralizada e simétrica, como o padrão de Airy. No entanto, aberrações introduzidas por desalinhamentos, imprecisões na fabricação

óptica ou limitações físicas inevitáveis, como difração em bordas, provocam distorções sistemáticas na PSF. Essas aberrações podem ser descritas por uma base ortonormal de funções chamadas de modos de Zernike, amplamente utilizadas em óptica adaptativa e análise de frente de onda (WYANT; CREATH, 1992).

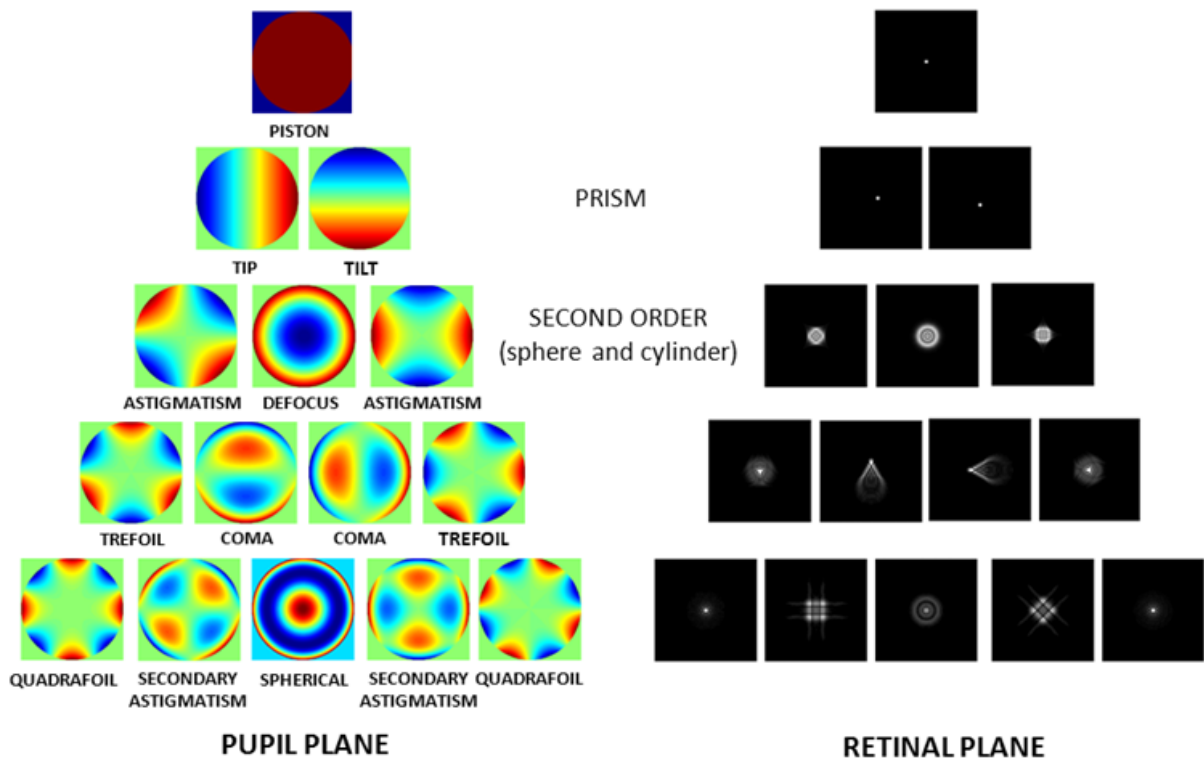
Dentre as principais aberrações ópticas, destacam-se:

- **Aberração Esférica:** causada pela incapacidade de lentes esféricas em focar raios periféricos e centrais no mesmo ponto, resultando em perda de foco radial (WYANT; CREATH, 1992).
- **Aberração Cromática:** ocorre quando diferentes comprimentos de onda são refratados com intensidades distintas, fazendo com que cada cor focalize em diferentes distâncias ao longo do eixo óptico (WYANT; CREATH, 1992).
- **Astigmatismo:** manifesta-se quando os meridianos ortogonais de uma lente ou espelho possuem curvaturas distintas, fazendo com que linhas horizontais e verticais focalizem separadamente (WYANT; CREATH, 1992).
- **Coma:** gera distorções assimétricas que transformam pontos de luz em figuras semelhantes a cometas, sendo mais acentuada em regiões fora do eixo óptico (WYANT; CREATH, 1992).
- **Trefoil, Quadrifoil e Coma Secundária:** aberrações de ordens superiores que afetam simetrias específicas do feixe incidente, causando padrões complexos na PSF (WYANT; CREATH, 1992).

Os coeficientes de Zernike permitem decompor a frente de onda distorcida em componentes independentes, o que é extremamente útil tanto na simulação quanto na correção de imagens. Cada modo contribui para um tipo específico de distorção causada, afetando de maneira distinta a distribuição de intensidade da PSF no plano de imagem.

A Figura 8 ilustra a correspondência entre os modos de Zernike no plano da pupila (à esquerda) e os respectivos padrões de PSF resultantes no plano da imagem (à direita). Pode-se observar como cada aberração modifica a distribuição da energia luminosa, revelando padrões de difusão que degradam a definição espacial.

Figura 8 – Representação dos modos de Zernike (aberrações ópticas) na pupila e seus efeitos correspondentes na PSF.



Fonte: Adaptado de Liang e Zeng (2012).

6.3 Distorções por movimento e instabilidades dinâmicas

Imagens adquiridas por sensores orbitais estão sujeitas a distorções induzidas por movimentos relativos entre o sensor e a cena observada. Essas distorções, de caráter cinemático e dinâmico, incluem principalmente o desfoque por movimento (*motion blur*), que ocorre quando há variação na posição ou orientação do sistema sensor durante o tempo de exposição. Tal efeito é particularmente evidente em plataformas em alta velocidade ou quando há instabilidades mecânicas, vibrações estruturais ou imperfeições nos sistemas de rastreamento e estabilização (*jitter*) (SHAN; JIA; AGARWALA, 2008).

O desfoque por movimento pode ser modelado como uma convolução entre a imagem ideal e uma função de espalhamento associada ao traçado do movimento durante o tempo de integração do sensor. Essa função, chamada de PSF cinemática ou função de arraste, reflete o vetor de deslocamento médio do sensor em cada ponto da cena durante a exposição. Sua forma pode variar desde perfis lineares simples (como ocorre em deslocamentos retilíneos uniformes) até funções complexas associadas a vibrações ou oscilações irregulares (SHAN; JIA; AGARWALA, 2008).

6.4 Ruídos eletrônicos

Os aspectos eletrônicos desempenham um papel importante na qualidade das imagens capturadas por satélites. Os detectores de imagem, como CCDs (*Charge-Coupled Devices*) e CMOS (*Complementary Metal-Oxide-Semiconductor*), são fundamentais para converter a luz recebida em sinais elétricos. No entanto, esses detectores introduzem ruídos eletrônicos que afetam a precisão e a qualidade das imagens.

Os principais tipos de ruídos que acometem imagens de sensoriamento remoto são: ruído de leitura (*read-out noise*), causado por flutuações eletrônicas durante a conversão da carga (elétrons) em tensão nos circuitos de leitura; ruído térmico, ou de escuro (*dark current noise*), gerado pela geração espontânea de elétrons térmicos no sensor, mesmo na ausência de luz; ruído fotônico (*photon noise*), que representa a flutuação estatística do número de fótons incidentes sobre o sensor, mesmo sob iluminação constante, seguindo uma distribuição de Poisson e estabelecendo um limite físico à sensibilidade do sistema; ruído de disparo (*shot noise*), associado à variabilidade estatística na conversão dos fótons incidentes em carga elétrica no material sensível; e ruído de quantização (*quantization noise*), introduzido durante a conversão do sinal analógico para digital, dependendo da resolução do ADC (*Analog-to-Digital Converter*) (JANESICK, 2001).

6.5 Implementação dos algoritmos de pré-processamento

A restauração de uma imagem pode ser melhor avaliada se a degradação a que ela foi submetida for bem caracterizada. Por essa premissa, foi implementado um módulo de pré-processamento voltado à simulação fiel de imagens degradadas por desfoques espaciais e ruídos. Essa etapa estabelece as condições de teste para os algoritmos de deconvolução subsequentes, especialmente para os métodos não cegos.

6.5.1 Algoritmos de desfoque

Durante o desenvolvimento do *software*, foram implementados diferentes tipos de desfoques (*blur*) para simular a degradação em imagens de imageamento remoto por meio da convolução com uma PSF arbitrária. As opções implementadas incluem:

- **Desfoque Gaussiano:** Gerado com base na equação da distribuição gaussiana bidimensional, mostrada pela Eq. 6.2.

$$G(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (6.2)$$

O usuário pode configurar o desvio padrão σ e o tamanho do kernel, o qual é automaticamente forçado a ser ímpar por meio da função para garantir a centralização simétrica da PSF.

- **Desfoques direcionais:** Esses modos foram projetados para simular degradações anisotrópicas relacionadas a movimento, comuns em sensores orbitais.
 - ***Across track:*** Aplica um desfoque sintético que emula movimentação no sentido transversal ao movimento da plataforma de imageamento, com um kernel estreito no eixo vertical e largo no horizontal.
 - ***Along track:*** Simula o desfoque no sentido longitudinal ao deslocamento da plataforma, invertendo a orientação do kernel em relação ao modo anterior (estreito no eixo horizontal e largo no eixo vertical).
 - ***Diagonal:*** Utiliza um kernel com elementos não nulos ao longo da diagonal principal, permitindo simular situações de desfoque com variação conjunta dos eixos.

Esses desfoques são selecionáveis por meio de um menu suspenso na interface gráfica, com controles adicionais para ajuste do tamanho do kernel e do parâmetro σ . A visualização da PSF gerada é atualizada automaticamente em tempo real na interface.

Após a geração do kernel, a convolução é realizada no domínio da frequência e foi implementada manualmente. O algoritmo segue as seguintes etapas fundamentais:

1. Conversão para ponto flutuante (float64) da imagem e do kernel, para garantir precisão numérica.
2. Aplicação de *padding* simétrico à imagem original, com o objetivo de reduzir artefatos de borda.
3. Redimensionamento da PSF por *padding* de zeros para igualar seu tamanho ao da imagem com *padding*.
4. Centralização do kernel na origem do domínio espectral.¹
5. Cálculo da Transformada de Fourier bidimensional da imagem e da PSF.
6. Multiplicação elemento a elemento dos espectros complexos (produto convolução no domínio da frequência).

¹ Na convolução no domínio da frequência, a posição da PSF afeta diretamente o resultado. É necessário perfomar um deslocamento espectral antes da transformada, que reorganize os quadrantes da PSF de modo que seu centro seja movido para a origem do domínio espectral. Esse procedimento é fundamental para garantir a consistência matemática da operação de convolução no domínio da frequência. Sem essa centralização adequada, a PSF seria aplicada com deslocamento espacial indevido, resultando em distorções não desejadas.

7. Aplicação da transformada inversa e extração da parte real.
8. Recorte do *padding* e normalização do resultado final para o intervalo dinâmico da original da imagem.

Essa implementação permite simular com fidelidade os efeitos de desfoque típicos em sistemas ópticos e cenários de aquisição degradada, conforme discutido anteriormente nesse Capítulo. O uso do domínio da frequência garante maior eficiência computacional, especialmente para imagens e kernels de grandes dimensões.

6.5.2 Algoritmos de adição de ruídos

Complementarmente, desenvolveu-se um conjunto de modelos de ruído que podem ser adicionados à imagem degradada para simular ruídos que acometem a imagem no processo de aquisição. Os tipos de ruído disponíveis são:

- **Ruído Gaussiano Aditivo:** Simula ruído branco com distribuição normal, controlado pelos parâmetros de média μ e desvio padrão σ , o qual é somado diretamente à imagem. A média μ determina o deslocamento central da distribuição, por isso, quando $\mu = 0$, o ruído preserva, em média, os níveis de intensidade originais. Já valores positivos ou negativos de μ resultam em um brilho artificialmente acrescido ou reduzido, respectivamente. O desvio padrão σ , por sua vez, controla a dispersão das amostras em torno da média. Valores maiores de σ geram variações mais intensas e visivelmente perceptíveis nos níveis de cinza, tornando o ruído mais agressivo. Por outro lado, valores baixos de σ produzem ruídos sutis.
- **Ruído Sal e Pimenta:** Introduce picos de valores máximos (sal) e mínimos (pimenta) em proporções aleatórias de pixels. O processo de geração utiliza máscaras booleanas aplicadas sobre a matriz da imagem. Implementou-se controles para a probabilidade de ocorrência de sal e de pimenta, os quais determinam o percentual de pixels afetados por cada tipo de ruído.
- **Ruído de Poisson:** Baseado na distribuição de Poisson, é dependente da intensidade de cada pixel e simula flutuações quânticas associadas a sensores de detecção fotônica. Como a variância do ruído de Poisson é igual ao valor médio de intensidade, esse tipo de ruído é mais intenso em regiões brilhantes da imagem. Implementou-se um controle que ajusta o percentual de amplificação dos valores da imagem antes da aplicação da distribuição de Poisson.
- **Ruído de listras verticais:** Um ruído determinístico foi adicionado para simular falhas em sensores de leitura linear. Essa perturbação é aplicada como uma variação periódica ou alternada de intensidade entre colunas, resultante da falta de calibração

ou morte de pixels. O sistema permite ao usuário controlar a intensidade com que o ruído acomete a imagem. Quanto maior o valor, maior a densidade de falha dos pixels.

Esse módulo de pré-processamento oferece flexibilidade para simular diferentes cenários de degradação, fornecendo uma base confiável para a aplicação dos métodos de deconvolução discutidos nos capítulos seguintes.

6.5.3 Reamostragem

Embora a reamostragem não contribua diretamente para os processos de degradação ou restauração, sua inclusão no *pipeline* de pré-processamento foi considerada essencial para adequação dimensional das imagens aos objetivos analíticos. Há imagens pequenas demais ou grandes demais para certos fins, o que pode comprometer o desempenho computacional do sistema.

Para contornar esses problemas, implementou-se o controle de fator de reamostragem. Esse fator é aplicado utilizando interpolação bilinear. A nova imagem resultante mantém a proporção original, mas com número de pixels ajustado proporcionalmente ao fator especificado.

7 A deconvolução

A deconvolução é uma técnica de processamento utilizada para recuperar sinais ao reverter degradações causadas pelo sistema de captura tanto quanto possível (JANSSON, 2012). Portanto, a deconvolução busca, por diferentes técnicas, estimar a imagem original a partir da versão observada e do conhecimento (ou estimativa) do operador de degradação.

Em suma, o objetivo da deconvolução consiste em resolver uma equação de convolução da forma da Eq. 7.1.

$$(f \otimes h)(x) = g(x) = \int_{-\infty}^{\infty} f(u) \cdot h(x - u) du \quad (7.1)$$

onde $g(x)$ é o sinal observado (ou imagem degradada), $f(u)$ é o sinal original que se deseja recuperar e $h(x - u)$ é a função de distorção ou filtro (como uma PSF ou kernel). O sinal registrado resulta da convolução do sinal original com essa função e espalhamento, e a deconvolução busca, idealmente, reverter esse processo (JANSSON, 2012)..

Dependendo da disponibilidade de informações sobre a PSF, os métodos de deconvolução podem ser classificados como não-cegos, quando a PSF é conhecida, ou cegos, quando tanto a imagem original quanto a PSF são estimadas simultaneamente (BURTON; LALOR, 2015). A efetividade da deconvolução depende diretamente da precisão da modelagem do sistema degradante, da relação sinal-ruído e da robustez algorítmica frente à amplificação de ruídos durante o processo (SOUZA et al., 2021).

7.1 Problema da deconvolução

Uma das principais limitações da deconvolução está relacionada à amplificação de ruídos. Como a operação inversa da convolução tende a reforçar as componentes de alta frequência, que são justamente onde estão os ruídos, o processo pode amplificar significativamente perturbações indesejadas presentes na imagem observada. Isso ocorre especialmente quando se utiliza a inversão direta no domínio da frequência, como na Eq. 7.2, pois pequenas amplitudes em $H(u, v)$ podem levar a grandes variações em $F(u, v)$, resultando em imagens com granularidade acentuada, artefatos e padrões que não refletem a cena real (JANSSON, 2012).

$$F(u, v) = \frac{G(u, v)}{H(u, v)} \quad (7.2)$$


Esse problema é classicamente mal-posto, pois pequenas perturbações em $g(x)$, como ruídos, podem causar grandes desvios na estimativa de $f(x)$. Matematicamente, um

problema mal-posto pode não ter solução, ter múltiplas soluções, ou ter uma solução que é extremamente sensível a pequenas mudanças nos dados. Assim, técnicas de deconvolução precisam incorporar restrições ou regularizações para obter soluções estáveis e fisicamente plausíveis (JANSSON, 2012).

Além disso, a presença de efeitos de borda é um desafio adicional. A convolução e a deconvolução assumem, idealmente, que os sinais são infinitamente estendidos. Contudo, no processamento de imagens digitais, trabalha-se com domínios finitos, o que leva à introdução de bordas artificiais quando o kernel se aproxima dos limites da imagem. Esses efeitos podem gerar descontinuidades ou reflexões espúrias nos contornos da imagem restaurada, sendo necessária a aplicação de técnicas como *padding*, seja ele por espelhamento ou por extrapolação, para mitigar o problema (JANSSON, 2012).

A Figura 9 ilustra esse fenômeno. À esquerda, observa-se a aplicação direta de um kernel sobre a imagem sem qualquer tipo de *padding*, o que afeta o cálculo de valores próximos às bordas. À direita, é apresentado um exemplo de *padding*, em que a imagem é estendida artificialmente (representada pela região sombreada em verde). Essa estratégia permite reduzir os efeitos indesejados de borda e assegurar uma transição mais suave nas regiões limítrofes da imagem.

Figura 9 – Representação do problema de borda em operações de convolução 2D.



Fonte: Autoria própria.

Outro aspecto importante é que a solução obtida pela deconvolução pode não corresponder, de fato, à imagem original desejada. Em particular, quando há perda de componentes espectrais durante a aquisição, como bandas de frequência eliminadas ou atenuadas pela PSF, a informação ausente não pode ser recuperada unicamente por in-

versão. Nesses casos, diferentes soluções $f(x)$ podem satisfazer a equação convolucional, dificultando a seleção da mais adequada. A regularização, nesse contexto, funciona como um critério adicional que favorece soluções compatíveis com propriedades físicas, estatísticas ou geométricas esperadas da imagem original (JANSSON, 2012).

Portanto, o problema da deconvolução exige abordagens cuidadosas que combinem modelagem precisa do sistema degradante, técnicas numéricas robustas e hipóteses bem fundamentadas sobre a estrutura da imagem, de modo a garantir estabilidade, realismo e fidelidade no processo de restauração.

7.2 Deconvolução cega e não cega

Na deconvolução não cega, assumimos que conhecemos a Função de Espalhamento de Ponto (PSF) que descreve o borramento aplicado à imagem. A PSF é essencial para a deconvolução, pois define como a imagem original foi degradada. Este conhecimento permite aplicar as técnicas de deconvolução de forma mais precisa, uma vez que o processo de degradação é bem definido.

A deconvolução cega é utilizada para restaurar imagens quando a PSF não é conhecida. Ao contrário da deconvolução não cega, em que se conhece a PSF *a priori*, a *blind deconvolution* estima simultaneamente a imagem original e a PSF a partir da imagem degradada. Isso é especialmente útil em situações em que o sistema de captura de imagem é complexo ou cujas condições de captura variam significativamente (JANSSON, 2012).


Métodos de deconvolução cega podem funcionar iterativamente, ajustando tanto a estimativa da imagem quanto a PSF para minimizar a diferença entre a imagem observada e a imagem convoluída estimada. Este processo de otimização é fundamental para o sucesso da deconvolução cega, mas geralmente depende de um bom chute inicial para a PSF. A qualidade do chute inicial é crucial, pois influencia diretamente a qualidade da imagem final e a convergência do algoritmo. Se o chute inicial estiver longe da PSF real, o algoritmo pode convergir para uma solução incorreta ou demorar muito tempo para encontrar uma solução adequada (JANSSON, 2012).

7.3 Filtro inverso

A deconvolução pode ser realizada, em teoria, pela inversão direta da PSF no domínio da frequência, como já mostrado na Eq. 7.2. No entanto, a equação é altamente sensível a ruídos, especialmente em regiões em que $H(u, v)$ possui valores próximos de zero, o que pode amplificar significativamente o ruído $N(u, v)$. Por esse motivo, métodos práticos de deconvolução costumam empregar técnicas de regularização ou abordagens iterativas que buscam encontrar o melhor compromisso entre restauração e estabilidade.

A Figura 10 apresenta um diagrama simplificado desse processo.

Figura 10 – Diagrama de blocos do processo de degradação e recuperação por deconvolução via filtro inverso.



7.3.1 Implementação do filtro inverso

A implementação do Filtro Inverso seguiu rigorosamente a formulação da Eq. 7.2, com a inclusão de salvaguardas numéricas para prevenir instabilidades. Em particular, a estratégia de evitar divisões por zero substituindo os valores espectrais muito pequenos por uma constante positiva (como $\varepsilon = 10^{-3} \cdot \max(|H(u, v)|)$) é por vezes referida na literatura como filtro pseudo-inverso. Neste trabalho, entretanto, adotamos a nomenclatura genérica de filtro inverso, considerando que a modificação preserva a essência do modelo original ao mesmo tempo em que torna sua implementação computacionalmente viável.

A rotina computacional pode ser sumarizada nos seguintes passos:

1. Um *padding* simétrico é aplicado à imagem observada, com o intuito de mitigar a introdução de artefatos de borda.
2. A PSF é centralizada no domínio espectral, garantindo que sua origem esteja adequadamente posicionada para a transformação;
3. A PSF é redimensionada com *padding* de zeros para tamanho compatível com o da imagem;
4. Calculam-se as transformadas de Fourier bidimensionais da imagem e da PSF;
5. O espectro da PSF é regularizado. Valores cujo módulo seja inferior a ε são substituídos por ε ;
6. Realiza-se a divisão $\hat{F}(u, v) = G(u, v)/H(u, v)$;
7. A transformada inversa é aplicada ao resultado e, em seguida, os *padding*s adicionados são removidos para restaurar as dimensões originais da imagem.

O resultado obtido é então normalizado para o intervalo dinâmico original da imagem e apresentado automaticamente na interface gráfica. Esse método mostra-se particularmente adequado em situações em que a PSF é perfeitamente conhecida e o nível de ruído

é desprezível, como discutido anteriormente, uma vez que sua simplicidade é contrabalançada por uma alta sensibilidade.

Na interface gráfica, o Filtro Inverso pode ser selecionado diretamente no menu suspenso de algoritmos de deconvolução. Por não requerer ajustes de parâmetros adicionais, sua execução é imediata, favorecendo seu uso como método de referência. Vale destacar que a disponibilidade dessa função está condicionada à existência de um kernel de borramento, previamente aplicado no módulo de pré-processamento, necessariamente.

7.4 Método de Wiener

A deconvolução de Wiener é uma técnica clássica utilizada para restaurar imagens degradadas por um sistema convolucional linear e ruído aditivo. Este método se fundamenta na minimização do erro quadrático médio entre a imagem original e a imagem estimada, assumindo conhecimento prévio da função de espalhamento e das características estatísticas do ruído e do sinal (JANSSON, 2012).

A formulação da deconvolução de Wiener no domínio da frequência é apresentada na Eq. 7.3:

$$F(u, v) = \frac{H^*(u, v)}{|H(u, v)|^2 + K} \cdot G(u, v) \quad (7.3)$$

onde $F(u, v)$ é a transformada de Fourier da imagem estimada, $G(u, v)$ é a transformada de Fourier da imagem observada, $H(u, v)$ é a transformada de Fourier da PSF, $H^*(u, v)$ é a conjugada complexa de $H(u, v)$ e K é o parâmetro que representa a razão entre a densidade espectral de potência do ruído e do sinal, como mostra a Eq. 7.4:

$$K = \frac{S_n(u, v)}{S_f(u, v)} \quad (7.4)$$

onde S_n e S_f são as potências espectrais do ruído e do sinal, respectivamente.

O filtro de Wiener busca encontrar um equilíbrio entre a recuperação do sinal e a supressão do ruído. Quando $K \rightarrow 0$, o filtro aproxima-se do inverso ideal, e quando $K \rightarrow \infty$, o filtro atenua completamente as altas frequências, agindo como um suavizador. Portanto, o valor de K é fundamental para controlar o grau de regularização aplicado à reconstrução (JANSSON, 2012).

A principal vantagem do método de Wiener está na sua estabilidade e menor suscetibilidade ao ruído, particularmente quando este apresenta distribuição gaussiana aditiva. Diferente da deconvolução inversa direta, que pode amplificar fortemente o ruído nas regiões do espectro onde $H(u, v)$ é pequeno, o filtro de Wiener modera essa amplificação por meio do denominador regulado (JANSSON, 2012).

7.4.1 Implementação do método de Wiener

A implementação do algoritmo de deconvolução de Wiener foi estruturada de forma a garantir flexibilidade no ajuste do parâmetro de regularização. O procedimento segue a sequência definida de etapas, descritas a seguir:

1. Aplica-se *padding* simétrico à imagem degradada, para evitar artefatos de borda;
2. A PSF é centralizada no domínio espectral, assegurando que sua origem esteja corretamente posicionada para a aplicação da transformada;
3. A PSF é redimensionada com *padding* de zeros para tamanho compatível com o da imagem;
4. Calculam-se então as transformadas de Fourier bidimensionais da imagem e da PSF;
5. O filtro de Wiener é aplicado diretamente no domínio da frequência, conforme a Eq. 7.3, atenuando ruído com base no parâmetro de regularização K ;
6. A transformada inversa é aplicada ao resultado e, em seguida, os *padding*s adicionados são removidos para restaurar as dimensões originais da imagem.

O parâmetro K desempenha um papel importante no equilíbrio entre fidelidade à imagem observada e supressão do ruído. Na implementação desenvolvida, foram previstos dois modos de definição desse parâmetro:

- **Modo manual:** o usuário pode inserir diretamente um valor de K por meio de um controle interativo, comumente situado entre 0.001 e 0.1, de acordo com a severidade do ruído;
- **Modo automático:** o valor de K é estimado com base na razão entre a variância do ruído e a variância do sinal, conforme definido pela Eq. 7.5.

$$K = \frac{\sigma_{\text{ruído}}^2}{\sigma_{\text{sinal}}^2 + \varepsilon} \quad (7.5)$$

Nessa equação, ε é um termo pequeno adicionado ao denominador para evitar divisão por zero durante o cálculo. A variância do ruído é estimada utilizando a mediana absoluta das diferenças (MAD). Em seguida, essa variância do ruído é subtraída da variância total da imagem suavizada com um filtro Gaussiano ($\sigma = 1$), fornecendo assim uma estimativa da variância do sinal. Esse processo assegura que o parâmetro K reflita a razão entre ruído e estrutura da imagem, mesmo sem dados de referência externos.

O método pode ser selecionado por meio do menu de algoritmos na interface gráfica. Ao acioná-lo, o sistema aplica a deconvolução e exibe a imagem restaurada, a PSF utilizada e as métricas correspondentes.

7.5 Método de Richardson-Lucy

O método de Richard-Lucy é um dos algoritmos mais populares para deconvolução cega. Trata-se de uma técnica iterativa baseada no princípio de máxima verossimilhança, assumindo que a imagem observada segue uma distribuição de Poisson (JANSSON, 2012).

O funcionamento do método é descrito pela fórmula iterativa apresentada na Eq. 7.6:

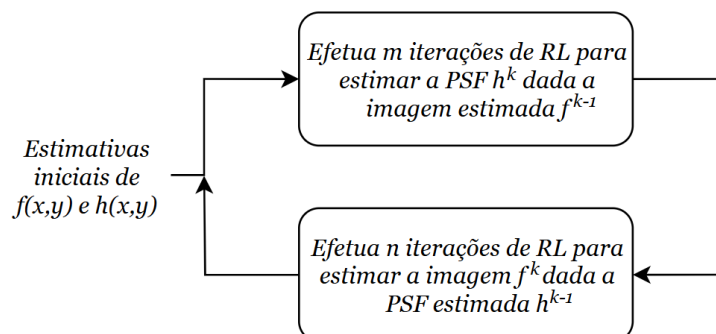
$$f_{k+1}(x, y) = f_k(x, y) \left[\frac{g(x, y)}{(f_k \otimes h)(x, y)} \otimes h^*(x, y) \right] \quad (7.6)$$

onde $f_k(x, y)$ é a estimativa da imagem na k -ésima iteração, $g(x, y)$ é a imagem observada, $h(x, y)$ é a PSF, e $h^*(x, y)$ é a versão invertida da PSF.

O algoritmo de Richard-Lucy ajusta a estimativa da imagem $f_k(x, y)$ e da PSF $h(x, y)$ iterativamente, melhorando a precisão da restauração a cada ciclo. A razão da Eq. 7.6 representa o quociente entre a imagem observada e a imagem estimada pela convolução atual, enquanto a convolução posterior com $h^*(x, y)$ distribui essa correção ao longo da imagem.

No caso da deconvolução cega, em que tanto a imagem $f(x, y)$ quanto a PSF $h(x, y)$ são desconhecidas, o método pode ser adaptado para alternar entre a estimativa de cada uma das variáveis. Essa abordagem está ilustrada na Figura 11, em que se realizam m iterações de Richardson-Lucy para estimar h^k , seguidas por n iterações para atualizar f^k , formando um ciclo recursivo (FISH; BRINICOMBE; PIKE, 1995).

Figura 11 – Fluxo iterativo da deconvolução cega por Richardson-Lucy.



Fonte: Adaptado de Fish, Brinicombe e Pike (1995).

As equações específicas para essa forma alternada estão descritas a seguir. A Eq. 7.7 corresponde à atualização da PSF dada uma imagem estimada, enquanto a Eq. 7.8 descreve a atualização da imagem com base na PSF.

$$h_{i+1}^{(k)}(x, y) = \left[\left(\frac{g(x, y)}{f^{(k-1)}(x, y) \otimes h_i^{(k)}(x, y)} \right) \otimes f^{(k-1)}(-x, -y) \right] \cdot h_i^{(k)}(x, y) \quad (7.7)$$

$$f_{i+1}^{(k)}(x, y) = \left[\left(\frac{g(x, y)}{f_i^{(k)}(x, y) \otimes h^{(k)}(x, y)} \right) \otimes h^{(k)}(-x, -y) \right] \cdot f_i^{(k)}(x, y) \quad (7.8)$$

Este método apresenta várias vantagens, sendo conhecido por fornecer boas estimativas da imagem original e da PSF, mesmo quando o chute inicial não é ideal. A abordagem iterativa permite refinamentos sucessivos e controlados na estimativa, melhorando a qualidade da imagem a cada passo.

No entanto, esse tipo de deconvolução cega também apresenta possíveis desvantagens. Como efeito adverso, sabe-se que a convergência do algoritmo pode ser lenta, especialmente se o chute inicial for desfavorável. Em alguns casos, a operação pode convergir para uma solução local, resultando em uma imagem restaurada subótima. Além disso, a sensibilidade ao ruído pode ainda ser um problema, exigindo estratégias adicionais de regularização ou suavização (HAJLAOUI et al., 2010).

7.5.1 Implementação do método de Richardson-Lucy

A implementação do algoritmo de Richardson-Lucy foi realizado com controle total sobre os parâmetros essenciais para a reconstrução e sucesso do método. O fluxo computacional é estruturado da seguinte forma:

1. Inicializa a estimativa da imagem com a versão degradada;
2. A PSF inicial é inserida centralmente em uma matriz de mesmo tamanho da imagem (*padding* de zeros);
3. Para cada iteração completa, aplicam-se dois módulos principais:
 - a) Estimativa da PSF a partir da imagem estimada na iteração anterior, conforme a Eq. 7.7;
 - b) Estimativa da imagem partir da PSF estimada na iteração anterior, conforme a Eq. 7.8;
4. Realiza-se o *clipping* dos valores negativos e superiores a 65535, mantendo o intervalo dinâmico da imagem de 16 bits, evitando saturações;
5. Os *padding*s adicionados são removidos para restaurar as dimensões originais da imagem.
6. A PSF e a imagem deconvoluída são exibidas a cada iteração para o usuário

A interface oferece ao usuário controles precisos sobre:

- Tipo da PSF de inicialização (Gaussiana, Along track, Across track, Diagonal) e sua intensidade;
- Número de iterações completa (pelo menos uma estimativa da PSF e uma da imagem);
- Número de estimativas consecutivas da PSF;
- Número de estimativas consecutivas da imagem;

Durante o processo, são armazenadas as estimativas parciais da imagem restaurada, possibilitando a visualizações da evolução da deconvolução ao longo das iterações.

7.6 Método de Richardson-Lucy com regularização por *Total Variation*

A regularização por *Total Variation* (TV) é uma estratégia eficaz para atenuar a amplificação de ruídos que ocorre ao longo das iterações do algoritmo de Richardson-Lucy (RL) (DEY et al., 2006). Diferentemente de técnicas baseadas na minimização da norma ℓ_2 , que tendem a suavizar indistintamente todas as regiões da imagem, inclusive bordas, a regularização TV penaliza a variação total da imagem, favorecendo soluções com gradientes esparsos, isto é, imagens com regiões homogêneas separadas por transições abruptas, como ocorre naturalmente em cenas estruturadas (CHAMBOLLE, 2004).

Na prática, a regularização por TV foi aplicada neste trabalho por meio da função `denoise_tv_chambolle`, uma implementação do algoritmo proposto por Chambolle para a resolução do problema de minimização de Rudin–Osher–Fatemi (ROF). Esse modelo visa encontrar uma imagem regularizada u que permaneça próxima da imagem degradada f , conforme Eq. 7.9 (CHAMBOLLE, 2004):

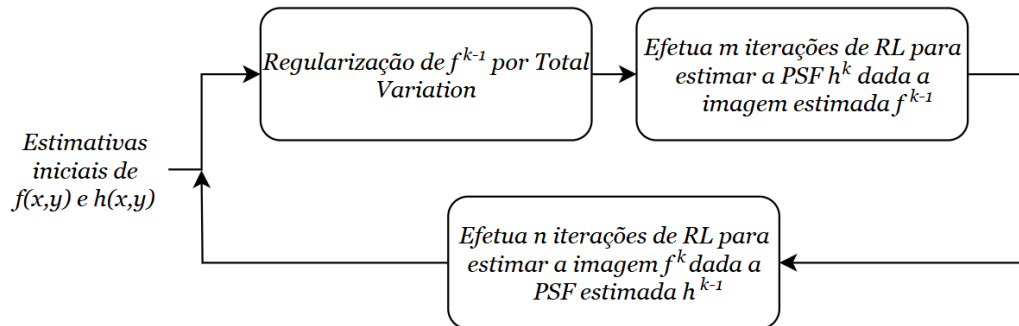
$$\min_u \sum_{x,y} \left(|\nabla u(x,y)| + \frac{\lambda}{2} (f(x,y) - u(x,y))^2 \right) \quad (7.9)$$

Nesse modelo, o primeiro termo representa a variação total da imagem e o segundo assegura a fidelidade aos dados observados. O parâmetro λ controla o equilíbrio entre suavização e aderência ao dado original. Valores maiores de λ privilegiam a fidelidade à imagem degradada, enquanto valores menores favorecem uma imagem mais suave.

A aplicação da TV no contexto desse trabalho ocorre como uma etapa intermediária entre as atualizações de RL. Assim, em cada iteração externa, a imagem estimada é regularizada antes de ser utilizada na atualização da PSF, como esquematizado na Figura 12. A regularização age como um filtro adaptativo que suprime variações de alta frequência provocadas pela amplificação de ruído nas iterações de RL, mas sem comprometer a nitidez de bordas relevantes. A suavização é controlada de maneira localizada, permitindo

que detalhes estruturais sejam mantidos mesmo em regiões com alto contraste (DEY et al., 2006).

Figura 12 – Fluxo iterativo do algoritmo de Richardson-Lucy com regularização por *Total Variation*.



Fonte: Adaptado de Fish, Brinicombe e Pike (1995).

7.6.1 Implementação do método de Richardson-Lucy com regularização por *Total Variation*

Embora o algoritmo de Richardson-Lucy produza bons resultados em diversos cenários, sua natureza pode amplificar o ruído presente na imagem observada ao longo das iterações. Para mitigar esse efeito, foi implementada a regularização baseada na penalização por *Total Variation*.

A rotina implementada é semelhante a descrita na seção anterior, com a adição do TV da seguinte forma:

1. Inicializa a estimativa da imagem com a versão degradada;
2. A PSF inicial é inserida centralmente em uma matriz de mesmo tamanho da imagem (*padding* de zeros);
3. Para cada iteração, aplicam-se dois módulos principais:
 - a) A regularização por TV, com peso λ controlado pelo usuário;
 - b) Estimativa da PSF a partir da imagem estimada na iteração anterior, conforme a Eq. 7.7;
 - c) Estimativa da imagem partir da PSF estimada na iteração anterior, conforme a Eq. 7.8;
4. Realiza-se o *clipping* dos valores fora do intervalo $[0, 65535]$, evitando saturações;
5. A PSF e a imagem deconvoluída são exibidas a cada iteração para o usuário

O controle da regularização é realizado pelo ajuste do valor de λ , peso da penalização TV. Valores mais baixos preservam detalhes finos, ao passo que valores maiores ajudam a suprimir ruídos de alta frequência.

Durante o processo iterativo, o progresso é exibido graficamente e as estimativas parciais da imagem restaurada são armazenadas para posterior inspeção.

7.7 Deconvolução por *Deep Image Prior*

A técnica de *Deep Image Prior* (DIP) explora a estrutura de redes neurais convolucionais como um regularizador implícito (LEMPITSKY; VEDALDI; ULYANOV, 2018). Essa abordagem permite realizar tarefas de deconvolução, super-resolução e remoção de ruído sem a necessidade de dados de treinamento ou conhecimento estatístico prévio sobre as imagens. O princípio fundamental do DIP está na constatação de que redes convolucionais possuem um viés estrutural que as leva, naturalmente, a modelar padrões regulares e estruturas visuais coerentes antes de se ajustarem ao ruído presente na imagem observada (HECKEL; HAND, 2020). Em outras palavras, elas tendem a reconstruir inicialmente os componentes de baixa frequência espacial, sendo menos propensas a modelar diretamente o ruído, que reside em faixas de alta frequência.

No problema da deconvolução, assume-se que a imagem observada $g(x, y)$ é obtida pela convolução de uma imagem ideal $f(x, y)$ com uma função de espalhamento $h(x, y)$, acrescida de ruído aditivo $n(x, y)$, como descrito anteriormente na Eq. 6.1. Na formulação DIP, a imagem ideal $f(x, y)$ é representada como a saída de uma rede neural convolucional $f_\theta(z)$, parametrizada por pesos θ e alimentada por uma entrada fixa z , definida como uma matriz de ruído gaussiano. O processo de restauração consiste em encontrar os parâmetros θ que minimizam o erro entre a imagem observada e a convolução da saída da rede com a PSF conhecida (LEMPITSKY; VEDALDI; ULYANOV, 2018):

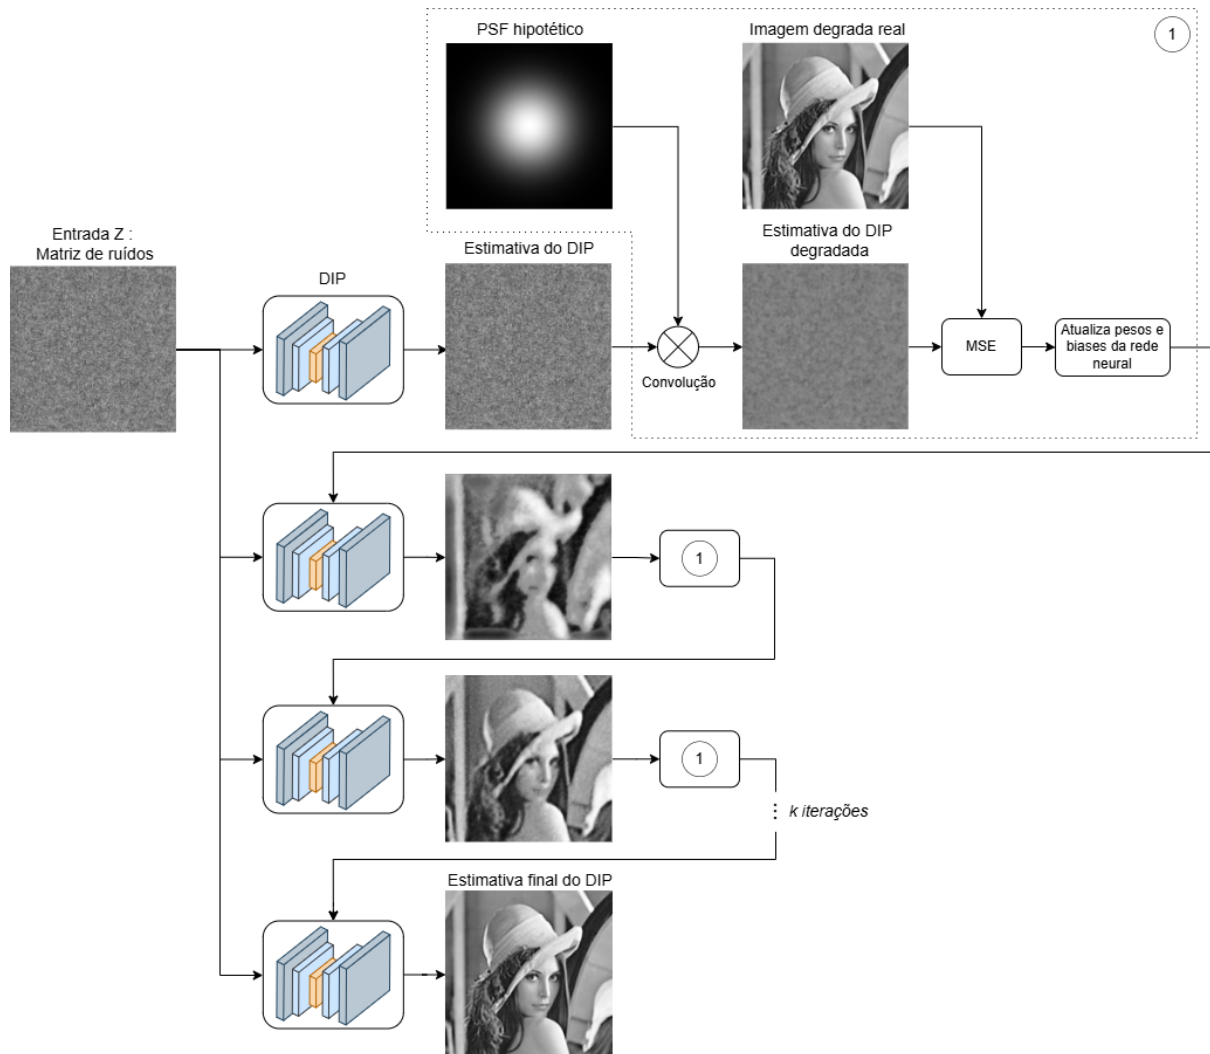
$$\min_{\theta} \|g - (f_\theta(z) \otimes h)\|_2^2 \quad (7.10)$$

Na implementação prática utilizada neste trabalho, a rede convolucional possui uma arquitetura simétrica do tipo encoder-decoder, com camadas convolucionais e de normalização em cada bloco, e usa como entrada uma matriz de ruído z gerada aleatoriamente. A rede é otimizada com o algoritmo Adam (KINGMA; BA, 2014), sendo que os únicos parâmetros atualizados são os pesos e biases dos filtros convolucionais (θ), enquanto a PSF permanece fixa. A imagem de saída da rede é ajustada durante o processo iterativo para minimizar o MSE entre a imagem observada e a convolução da imagem estimada com a PSF. A entrada z , por sua vez, permanece constante ao longo de todas as iterações.

A Figura 13 ilustra esse processo, em que a matriz de entrada z é processada por uma rede convolucional (DIP) que gera uma imagem estimada, a qual é degradada via convolução com uma PSF hipotética (arbitrário) para o caso cego, ou PSF real para o

caso não-cego. Essa imagem degradada é então comparada com a imagem observada real por meio de uma função de perda (MSE), e os pesos da rede são atualizados via retropropagação do erro. O processo se repete ao longo de múltiplas iterações até a convergência ou até um ponto de parada escolhido (LEMPITSKY; VEDALDI; ULYANOV, 2018).

Figura 13 – Esquema conceitual do processo de deconvolução com *Deep Image Prior*, com base na implementação utilizada.



Fonte: Autoria própria.

Em síntese, o *Deep Image Prior* representa uma abordagem adaptável e não supervisionada para a restauração de imagens, oferecendo resultados competitivos mesmo na ausência de dados externos ou modelos explícitos de regularização (LEMPITSKY; VEDALDI; ULYANOV, 2018).

7.7.1 Implementação da deconvolução por *Deep Image Prior*

A implementação do método *Deep Image Prior* (DIP) foi realizada com o suporte da biblioteca PyTorch, utilizando uma arquitetura do tipo *encoder-decoder* composta por camadas convolucionais, normalização por lotes (*Batch Normalization*) e funções de ativação *ReLU*.

O processo de restauração da imagem por meio do DIP segue os seguintes passos:

1. Inicializa a estimativa da imagem com a versão degradada;
2. A PSF inicial é inserida centralmente em uma matriz de mesmo tamanho da imagem (*padding* de zeros);
3. Uma rede convolucional do tipo *encoder-decoder* com conexões simétricas e blocos convolucionais com `BatchNorm` e `ReLU` é instanciada. Ela segue uma topologia em “U”, permitindo aprendizado hierárquico multiescala.
4. O tensor z de ruído gaussiano de dimensão (C_z, H, W) é criado, onde C_z é o número de canais ajustável. Este ruído permanece fixo durante o treinamento e é a única entrada da rede.
5. O otimizador Adam é utilizado com taxa de aprendizado ajustável, realizando atualização adaptativa dos pesos da rede.
6. *Arrays* para registrar imagens de cada iteração.
7. Para cada iteração do DIP:
 - a) Propaga-se z pela rede, gerando uma estimativa de imagem $f(x, y)$;
 - b) A imagem gerada é interpolada para o tamanho da imagem original, caso necessário;
 - c) Essa imagem é convoluída com a PSF para gerar uma estimativa da imagem borrada $\hat{g}(x, y)$;
 - d) Calcula-se a perda (erro quadrático médio) entre \hat{g} e a imagem borrada g ;
 - e) Realiza-se o retropropagação e atualização dos pesos.

Três parâmetros principais são disponibilizados ao usuário, com impactos diretos na qualidade da reconstrução e no tempo de execução:

- **Número de canais de entrada (C_z):** quanto maior o número de canais no tensor de entrada z , maior a capacidade da rede em capturar padrões sutis, mas também maior o risco de sobreajuste ao ruído. Valores típicos variam entre 8 e 32 canais, sendo ajustáveis conforme o grau de complexidade da imagem a ser restaurada.

- **Taxa de aprendizado:** regula a magnitude das atualizações dos pesos da rede. Taxas muito altas podem causar oscilações na convergência, enquanto taxas muito baixas tornam o processo extremamente lento. O valor padrão adotado na interface é 10^{-3} , podendo ser ajustado conforme a sensibilidade do problema.
- **Número de iterações:** define o número total de ciclos de retropropagação. Iterações em excesso podem levar ao (*overfitting*), enquanto iterações insuficientes podem resultar em imagens subrestauradas.

A grande vantagem do DIP reside no fato de a rede neural servir simultaneamente como gerador e regularizador. O processo de restauração é, portanto, conduzido pela estrutura da rede e pela semelhança espectral entre a saída da rede e a imagem observada, como apresentado nessa Seção.

8 Métricas

A avaliação da qualidade de imagens é essencial para garantir a precisão dos dados obtidos e a eficiência do processo de deconvolução, especialmente em imagens de sensoriamento remoto. Para isso, utiliza-se várias métricas que quantificam diferentes aspectos da qualidade da imagem. Elas permitem comparar e analisar a fidelidade das imagens em relação à referência ou em relação a si próprias, facilitando a identificação e correção de degradações (HORE; ZIOU, 2010). A seguir, são apresentadas algumas das principais métricas.

8.1 Índice de similaridade estrutural (SSIM)

O *Structural Similarity Index* (SSIM) é uma métrica perceptual que quantifica a similaridade entre duas imagens, levando em consideração não apenas as diferenças ponto a ponto, mas também variações estruturais, de luminância e de contraste (WANG et al., 2004). O SSIM é particularmente útil na avaliação da qualidade de imagens restauradas, pois busca refletir a percepção visual humana. Valores próximos de 1 indicam maior similaridade estrutural entre as imagens comparadas. A expressão geral do SSIM é dada pela Eq. 8.1.

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (8.1)$$

onde μ_x e μ_y são as médias locais, σ_x^2 e σ_y^2 são as variâncias locais e σ_{xy} é a covariância local entre as imagens x e y . Os termos C_1 e C_2 são constantes de estabilização.

8.2 Relação sinal-ruído de pico (PSNR)

A *Peak Signal-to-Noise Ratio* (PSNR) é uma métrica baseada na diferença absoluta entre os valores dos pixels de uma imagem original e sua versão degradada ou restaurada. É expressa em decibéis (dB) e é largamente empregada para avaliar a fidelidade de reconstruções em processos de compressão, transmissão ou restauração de imagens (HORE; ZIOU, 2010). A PSNR é definida pela Eq. 8.2.

$$\text{PSNR} = 10 \cdot \log_{10} \left(\frac{\text{Max}_I^2}{\text{MSE}} \right) \quad (8.2)$$

onde Max_I é o valor máximo possível para um pixel (por exemplo, 255 para imagens de 8 bits) e MSE é o erro quadrático médio entre as duas imagens. Valores mais altos de PSNR indicam maior semelhança com a imagem de referência.

8.3 Erro quadrático médio normalizado (NRMSE)

O *Normalized Root Mean Squared Error* (NRMSE) é uma métrica de erro que quantifica a diferença global entre uma imagem restaurada e sua referência, normalizada pelo intervalo dinâmico dos valores da imagem original (GONZALES; WINTZ, 1987). O NRMSE é definido pela Eq. 8.3.

$$\text{NRMSE} = \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2}}{x_{\max} - x_{\min}} \quad (8.3)$$

onde x_i e y_i são os pixels das imagens original e restaurada, respectivamente, N é o número total de pixels, e x_{\max} e x_{\min} representam os valores máximo e mínimo da imagem de referência.

8.4 Variância do Laplaciano

A variância do Laplaciano é uma métrica comumente utilizada para quantificar o nível de nitidez de uma imagem. Essa abordagem baseia-se no fato de que imagens nítidas apresentam maiores variações locais de intensidade, o que implica em valores mais altos na aplicação do operador Laplaciano (PECH-PACHECO et al., 2000). A métrica é calculada como a variância da imagem filtrada com o kernel do Laplaciano, conforme a Eq. 8.4.

$$\text{Var}_{\nabla^2}(f) = \text{Var}(\nabla^2 f(x, y)) \quad (8.4)$$

onde $\nabla^2 f(x, y)$ representa a aplicação do operador Laplaciano à imagem $f(x, y)$. Quanto maior o valor da variância, maior a nitidez da imagem.

8.5 Largura a meia altura (FWHM)

A *Full Width at Half Maximum* (FWHM) é uma medida escalar que descreve a largura de uma função no ponto em que sua intensidade atinge metade do valor máximo. Em processamento de imagens, é utilizada para quantificar a largura de funções como a LSF, sendo uma métrica direta da resolução espacial do sistema. A FWHM é particularmente útil para avaliar o grau de borramento de imagens e estimar a PSF associada ao sistema de aquisição (LIANG; ZENG, 2012). Valores menores de FWHM indicam melhor resolução espacial.

9 Construção de ferramenta integrada de processamento de imagem

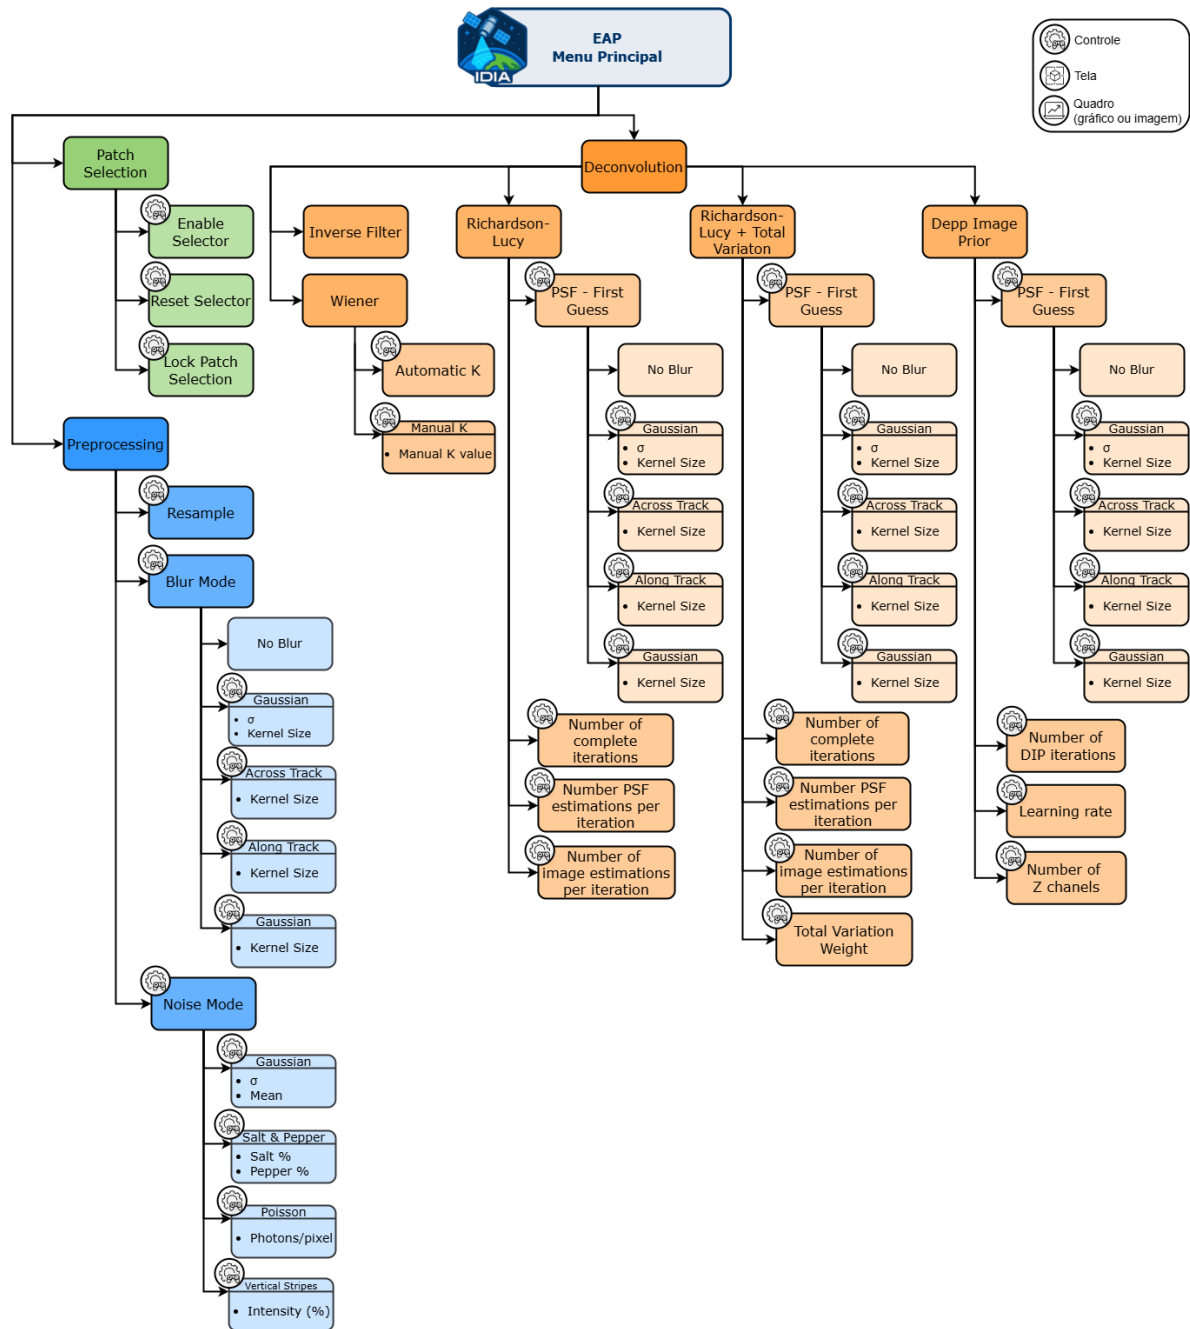
Com o objetivo de viabilizar a experimentação controlada dos algoritmos de deconvolução apresentados neste trabalho, foi desenvolvido um *software* denominado IDIA (*Integrated Deconvolution and Image Analysis*). Essa ferramenta atua como uma plataforma de suporte que permite tanto a simulação de diferentes condições de degradação quanto a aplicação comparativa de métodos de recuperação de imagem e a visualização de métricas de imagem relevantes.

Para organizar a estrutura da ferramenta, organizou-se um EAP (Estrutura Analítica do Projeto) com foco na clareza e na decomposição hierárquica de tudo que a aplicação abarca. A Figura 14 apresenta um EAP voltado ao menu principal do IDIA. A partir de um menu colapsável, o usuário pode pré-processar a imagem conforme seus objetivos analíticos, navegar entre módulos responsáveis pela seleção de região de interesse (*patch*), útil para a habilitação de funções métricas, e escolher o algoritmo de deconvolução mais adequado para cada caso. Todos os métodos de degradação (distorções e ruídos) e de deconvolução (filtro inverso, método de Wiener, Richardson–Lucy com ou sem regularização por variação total e o *Deep Image Prior*) contam com controles específicos para ajuste de seus parâmetros.

Nas representações esquemáticas do *software*, os ícones localizados acima dos blocos indicam a natureza funcional de cada elemento: Controles, telas e quadros. Blocos que não possuem nenhum desses ícones são classificados como rótulos (*labels*) e têm função meramente informativa, sem interação com o usuário. Os controles variam em tipo e finalidade, podendo incluir botões, menus suspensos, caixas de seleção, campos numéricos e barras de rolagem. Já as telas funcionam como contêineres que organizam e agrupam os controles e quadros associados a uma determinada etapa do fluxo de operação. Por fim, os quadros são dedicados à plotagem de dados e visualizações gráficas, como imagens processadas e gráficos.

Desenvolveu-se também um conjunto de guias de exibição que permite acompanhar o processo de restauração em múltiplas perspectivas. Como mostra a Figura 15, o sistema permite a visualização de uma série de objetos, como: imagem carregada, imagem pré-processada, PSF inicial e estimada, mapa de calor, visualização tridimensional das imagens, gráficos das funções métricas (ESF, LSF), quadro de métricas quantitativas (PSNR, SSIM, NRMSE, variância do laplaciano, σ_x , σ_y , espalhamento da ESF e FWHM).

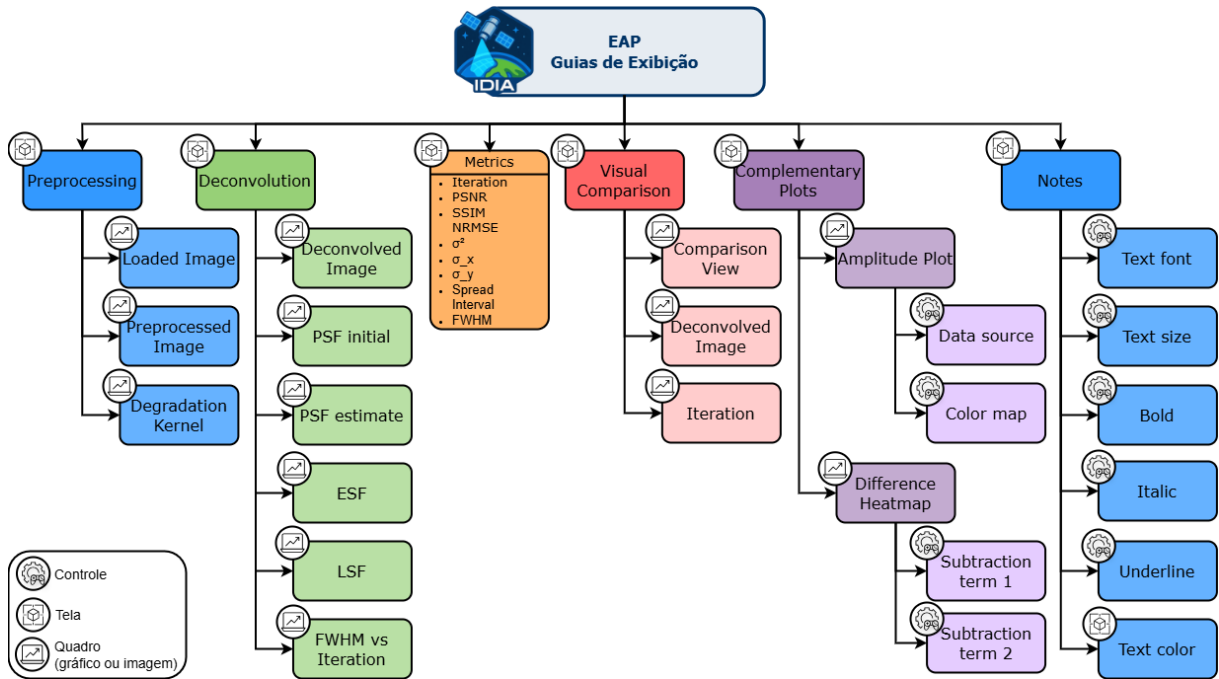
Figura 14 – Estrutura funcional do menu principal da ferramenta IDIA.



Fonte: Autoria própria.

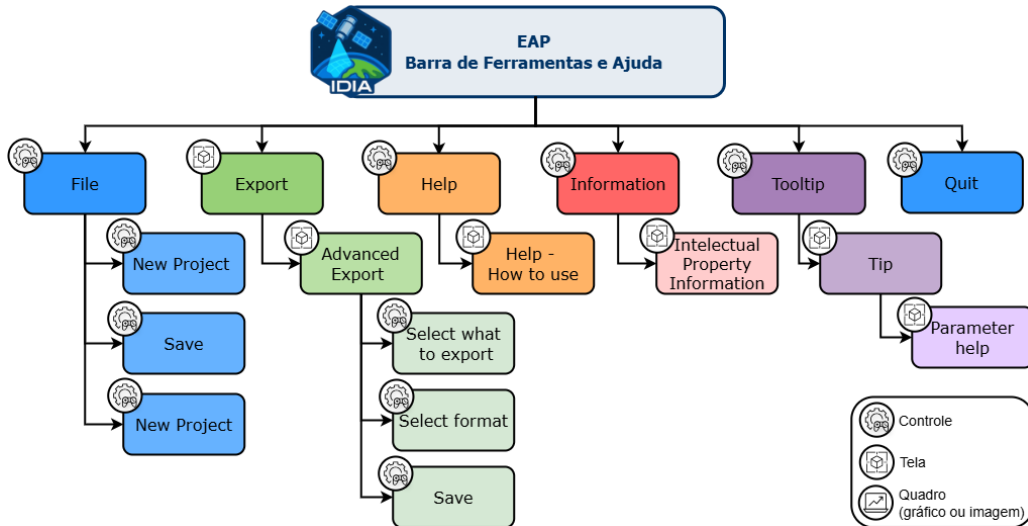
A interface também contempla ferramentas de exportação de dados, ajuda contextual e informações sobre o projeto, como detalhado na Figura 16. Essas funcionalidades foram implementadas para ampliar a autonomia do usuário e facilitar a documentação dos experimentos realizados. Em particular, as dicas de contexto oferecem descrições detalhadas dos parâmetros de cada método, a tela de exportação avançada permite selecionar conjuntos específicos de dados e gráficos para salvamento em múltiplas extensões de arquivo, que variam conforme o tipo de objeto a ser exportado (imagem, dados ou texto) e o menu *file* permite salvar, carregar ou iniciar projetos.

Figura 15 – Estrutura dos elementos de exibição e visualização métrica da ferramenta IDIA.



Fonte: Autoria própria.

Figura 16 – Organização da barra de ferramentas e ajuda da ferramenta IDIA.



Fonte: Autoria própria.


9.1 Interface gráfica

A interface gráfica do *software* IDIA foi projetada para oferecer uma experiência interativa, clara e modular, permitindo que o usuário controle todas as etapas do processo de deconvolução, desde o pré-processamento da imagem até a visualização e análise dos resultados. A estrutura é dividida em abas, painéis e quadros visuais, com botões, caixas de seleção e campos de entrada que permitem ajustar os parâmetros de forma direta e em

tempo real.


A Figura 17 mostra a tela inicial da interface, exibida logo após a execução da aplicação. Nessa etapa, o ambiente ainda não possui nenhuma imagem carregada ou configuração aplicada, apresentando, portanto, apenas os elementos estruturais principais. À esquerda, observa-se o painel lateral fixo contendo os três blocos funcionais que definem o fluxo principal do sistema: *Preprocessing*, *Patch Selection* e *Deconvolution*. Cada bloco pode ser expandido individualmente para revelar os controles específicos de sua etapa.

Figura 17 – Tela inicial da interface.



Fonte: Autoria própria.

O conteúdo do menu suspenso *File*, localizado na barra superior da interface do *software*, é mostrado pela Figura 18. Esse menu oferece as principais opções relacionadas ao gerenciamento de projetos, permitindo ao usuário iniciar um novo experimento, salvar o progresso atual ou carregar um projeto previamente salvo. Ao criar um projeto, um explorador de arquivos é aberto para seleção da imagem a ser processada.

Figura 18 – Menu *File* com suas opções para gerenciamento dos projetos.

Fonte: Autoria própria.

A Figura 19 mostra o detalhamento das opções dos submenus que compõem o menu lateral. Cada aba colapsável exibe controles específicos. A imagem mostra os painéis laterais expandidos, com seus controles interativos ativados. Os valores e opções visíveis na Figura são exemplos ilustrativos e o usuário pode alterar livremente os parâmetros de acordo com o cenário de análise.

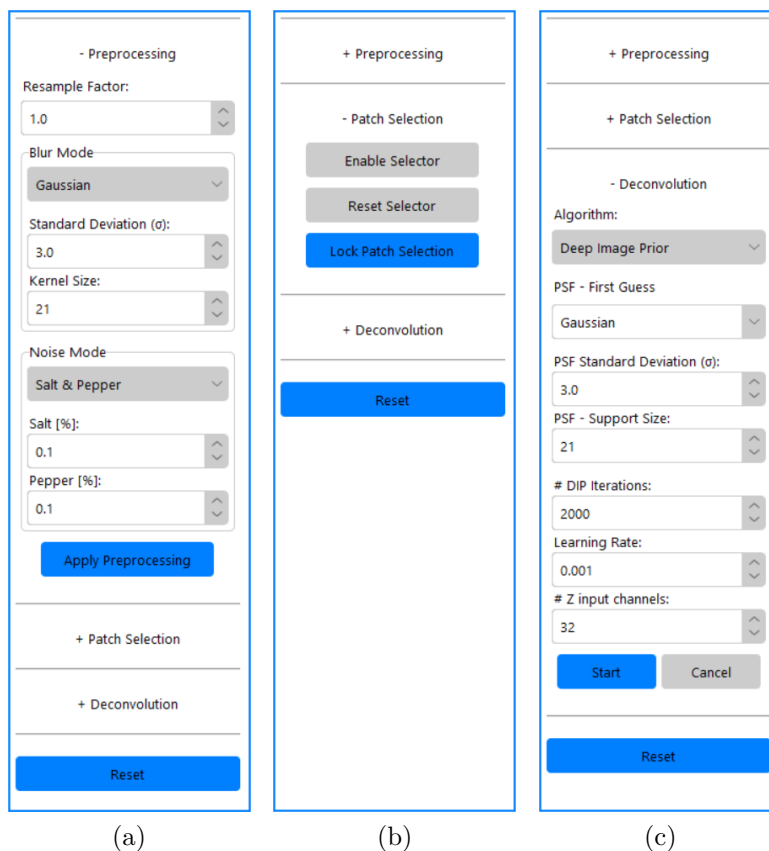
O Figura 19a corresponde à etapa de pré-processamento. Nela, o usuário pode definir um fator de reamostragem (*Resample Factor*), selecionar o tipo de desfoque a ser aplicado (*Blur Mode*) e ajustar seus parâmetros específicos, mostrados somente ao selecionar o tipo de borramento. Logo abaixo, é possível configurar o tipo de ruído adicionado à imagem, cujos parâmetros também são mostrados de acordo com o tipo de ruído selecionado. Após os ajustes, o botão *Apply Preprocessing* executa as transformações sobre a imagem carregada.

O painel mostrado pela Figura 19b corresponde à seleção de região de interesse (*patch*). Por meio dos botões *Enable Selector*, *Reset Selector* e *Lock Patch Selection*, o usuário ativa, reinicia ou fixa a seleção da área que será utilizada para análise local e visualização dos efeitos da PSF.

Já o painel da Figura 19c exibe os controles da etapa de deconvolução. É possível escolher o algoritmo desejado, definir o tipo de PSF inicial (neste exemplo, Gaussiana), e ajustar todos os controles associados ao método escolhido. Os botões *Start* e *Cancel* permitem iniciar ou interromper o processo de deconvolução.

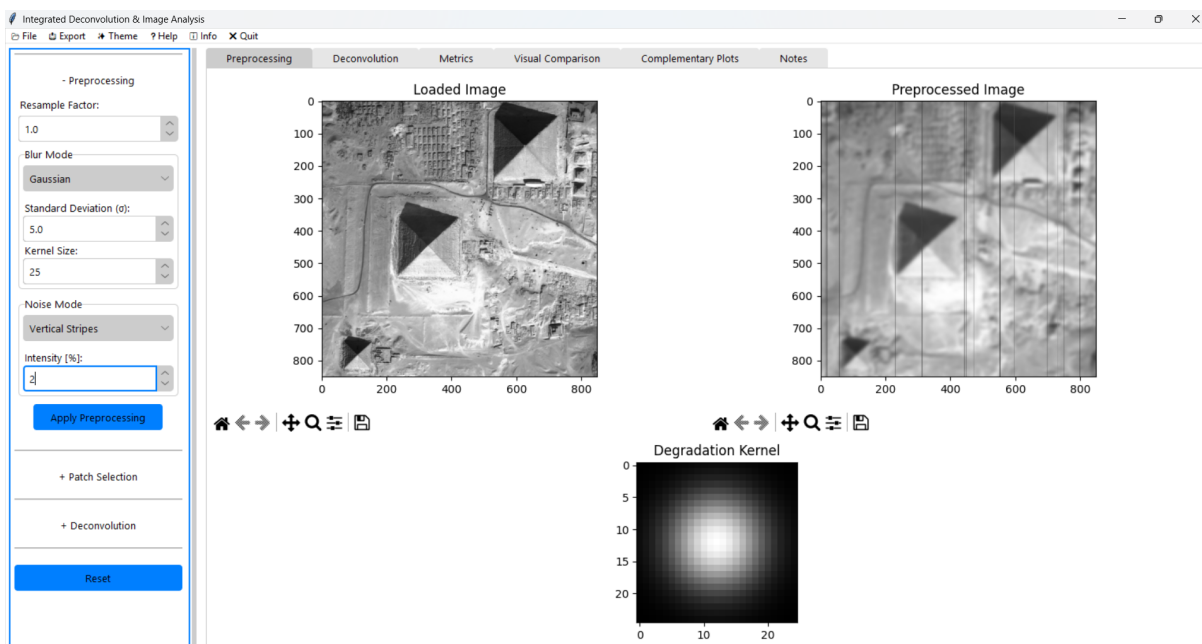
A aba de visualização gráfica da etapa de pré-processamento, em que são exibidas a imagem original carregada (*Loaded Image*) e a imagem degradada resultante da aplicação de filtros e ruídos (*Preprocessed Image*), é apresentada na Figura 20. Esta aba está organizada em um painel central de visualização, que facilita a comparação visual direta entre os estados inicial e degradado da imagem. Além das imagens principais, um terceiro quadro (*Degradation Kernel*) é exibido na parte inferior direita da tela. Esse quadro mostra o mapa da PSF, gerada com base nos parâmetros de desfoque selecionados, permitindo ao usuário verificar visualmente a forma do kernel aplicado.

Figura 19 – Controles do menu principal. a) Menu colapsável *Preprocessing*. b) Menu colapsável *Patch Selection*. c) Menu colapsável *Deconvolution*.



Fonte: Autoria própria.

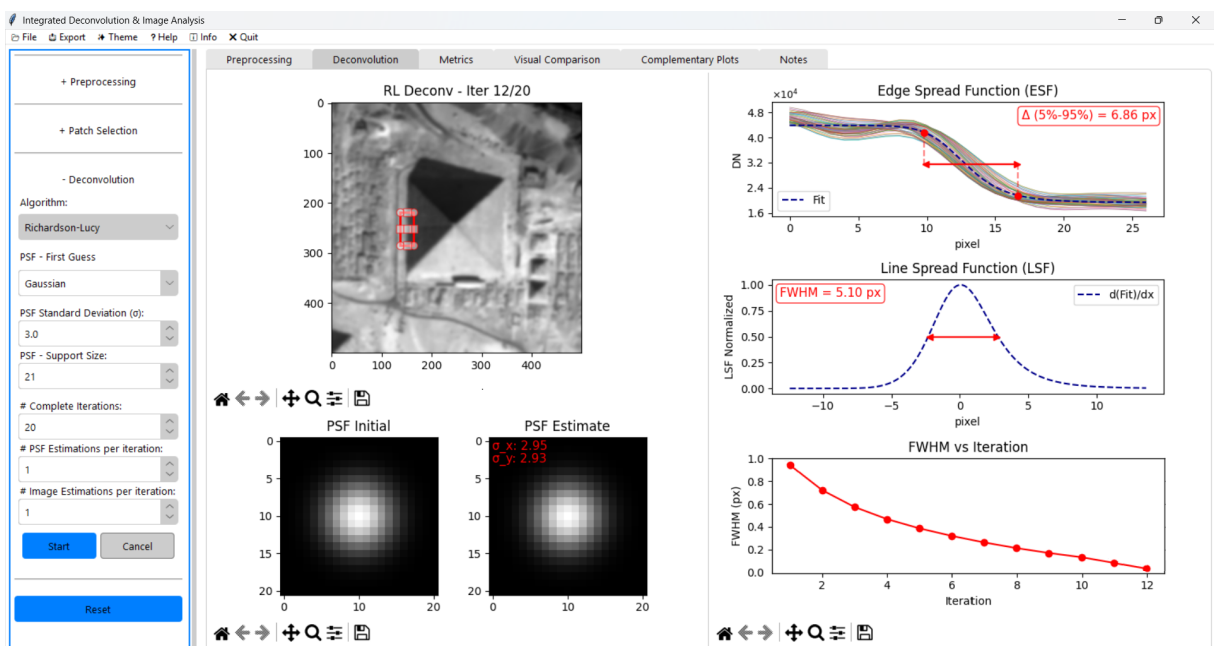
Figura 20 – Aba de visualização da etapa de pré-processamento.



Fonte: Autoria própria.

A Figura 21 apresenta a aba dedicada ao processo de deconvolução. Essa interface foi projetada para fornecer ao usuário uma visão conjunta da evolução da restauração, das estimativas da PSF, quando existentes, e da evolução de algumas métricas associadas à qualidade da imagem ao longo das iterações. Na parte superior esquerda, é exibida a imagem restaurada em sua iteração corrente. Sobreposta à imagem está a região de análise, marcada pelo retângulo vermelho, usada para o cálculo das funções de espalhamento e métricas associadas. Essa seleção define o perfil mostrado nos gráficos na parte direita da tela. Na seção inferior direita da aba, dois quadros apresentam as PSFs inicial e estimada associadas ao método de deconvolução selecionado.

Figura 21 – Aba de visualização da etapa de deconvolução



Fonte: Autoria própria.

A Figura 22 exibe a aba *Metrics*, que consolida em formato tabular os indicadores quantitativos extraídos ao longo das iterações dos algoritmos de deconvolução. As métricas estão organizadas por linha, com cada entrada representando uma etapa do processo, desde a imagem original (*Loaded*), a imagem degradada (*Preprocessed*), até as iterações numeradas do algoritmo de deconvolução selecionado.

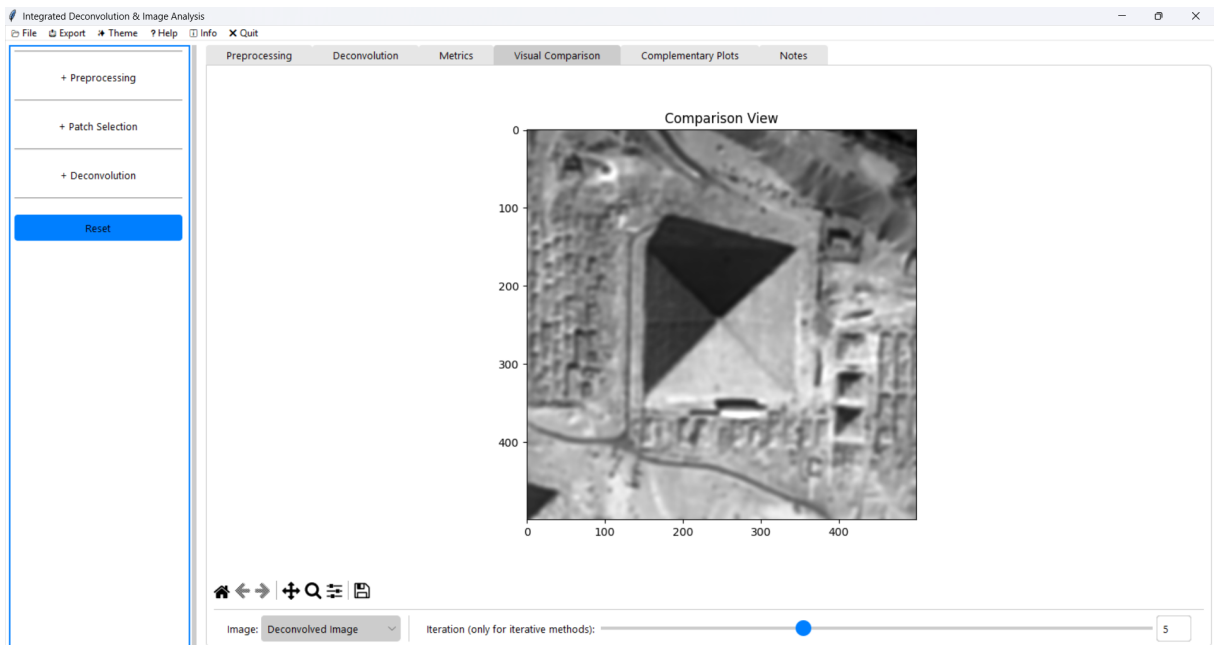
A aba *Visual Comparison* é exibida pela Figura 23, cuja finalidade é permitir a inspeção visual detalhada da imagem ao longo das iterações dos algoritmos de deconvolução. Essa aba foi concebida para facilitar a análise visual das imagens produzidas, possibilitando ao usuário selecionar qual imagem visualizar (original, preprocessed ou deconvolvida). Para métodos iterativos de deconvolução é possível percorrer as imagens das iterações, pelo controle deslizante na parte inferior da aba.

Figura 22 – Aba *Metrics*, com indicadores quantitativos por iteração da deconvolução.

| Iteration | PSNR (dB) | SSIM | NRMSE | σ^2 (Laplacian) | σ_x | σ_y | Spread Interval (Δ) [px] | FWHM [px] |
|--------------|-----------|--------|--------|------------------------|------------|------------|-----------------------------------|-----------|
| Loaded | inf | 1.0000 | 0.0000 | 1627.003 | nan | nan | nan | nan |
| Preprocessed | 27.24 | 0.8354 | 0.0697 | 114.401 | nan | nan | nan | nan |
| Preprocessed | 22.10 | 0.5011 | 0.1259 | 4.076 | nan | nan | nan | nan |
| 1 | 22.22 | 0.5113 | 0.1241 | 4.448 | 1.00 | 1.00 | 9.55 | 7.23 |
| 2 | 22.25 | 0.5141 | 0.1236 | 4.593 | 1.00 | 1.00 | 9.52 | 7.21 |
| 3 | 22.26 | 0.5151 | 0.1235 | 4.663 | 1.00 | 1.00 | 9.52 | 7.21 |
| 4 | 22.27 | 0.5155 | 0.1234 | 4.713 | 1.00 | 1.00 | 9.52 | 7.21 |
| 5 | 22.27 | 0.5157 | 0.1234 | 4.742 | 1.00 | 1.00 | 9.52 | 7.21 |
| 6 | 22.27 | 0.5158 | 0.1234 | 4.775 | 1.00 | 1.00 | 9.52 | 7.21 |
| 7 | 22.27 | 0.5158 | 0.1234 | 4.797 | 1.00 | 1.00 | 9.52 | 7.21 |
| 8 | 22.27 | 0.5159 | 0.1234 | 4.825 | 1.00 | 1.00 | 9.52 | 7.21 |
| 9 | 22.27 | 0.5159 | 0.1234 | 4.848 | 1.00 | 1.00 | 9.52 | 7.21 |
| 10 | 22.27 | 0.5159 | 0.1234 | 4.871 | 1.00 | 1.00 | 9.52 | 7.21 |
| 11 | 22.27 | 0.5159 | 0.1234 | 4.895 | 1.00 | 1.00 | 9.52 | 7.21 |
| 12 | 22.27 | 0.5159 | 0.1234 | 4.915 | 1.00 | 1.00 | 9.52 | 7.21 |
| 13 | 22.27 | 0.5159 | 0.1234 | 4.937 | 1.00 | 1.00 | 9.52 | 7.21 |
| 14 | 22.27 | 0.5159 | 0.1234 | 4.958 | 1.00 | 1.00 | 9.52 | 7.21 |
| 15 | 22.27 | 0.5159 | 0.1234 | 4.981 | 1.00 | 1.00 | 9.52 | 7.21 |
| 16 | 22.27 | 0.5159 | 0.1234 | 5.000 | 1.00 | 1.00 | 9.52 | 7.21 |
| 17 | 22.27 | 0.5159 | 0.1234 | 5.025 | 1.00 | 1.00 | 9.52 | 7.21 |
| 18 | 22.27 | 0.5159 | 0.1234 | 5.040 | 1.00 | 1.00 | 9.52 | 7.21 |
| 19 | 22.27 | 0.5159 | 0.1234 | 5.061 | 1.00 | 1.00 | 9.52 | 7.21 |
| 20 | 22.27 | 0.5159 | 0.1234 | 5.084 | 1.00 | 1.00 | 9.52 | 7.21 |
| 1 | 22.55 | 0.5354 | 0.1194 | 5.778 | 3.00 | 3.00 | 8.86 | 6.57 |
| 2 | 22.70 | 0.5478 | 0.1174 | 6.686 | 2.99 | 2.99 | 8.41 | 6.21 |
| 3 | 22.80 | 0.5567 | 0.1161 | 7.511 | 2.99 | 2.98 | 8.09 | 5.97 |
| 4 | 22.88 | 0.5638 | 0.1150 | 8.294 | 2.99 | 2.98 | 7.85 | 5.80 |
| 5 | 22.94 | 0.5696 | 0.1142 | 9.029 | 2.98 | 2.97 | 7.67 | 5.67 |
| 6 | 23.00 | 0.5745 | 0.1135 | 9.721 | 2.98 | 2.97 | 7.52 | 5.56 |
| 7 | 23.04 | 0.5787 | 0.1129 | 10.352 | 2.97 | 2.96 | 7.39 | 5.47 |
| 8 | 23.08 | 0.5824 | 0.1124 | 10.944 | 2.97 | 2.96 | 7.28 | 5.39 |
| 9 | 23.12 | 0.5857 | 0.1119 | 11.528 | 2.97 | 2.95 | 7.18 | 5.32 |
| 10 | 23.15 | 0.5887 | 0.1115 | 12.072 | 2.96 | 2.94 | 7.10 | 5.26 |

Fonte: Autoria própria.

Figura 23 – Aba *Visual Comparison*, com controle de iteração e seleção de imagem para inspeção visual.

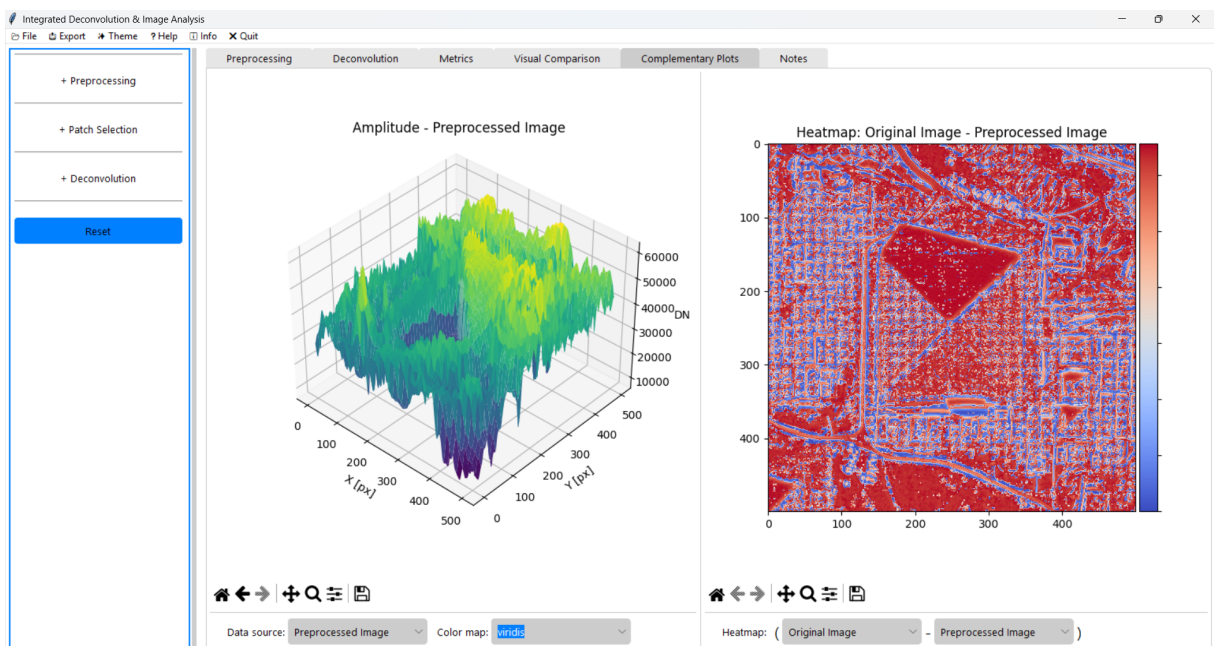


Fonte: Autoria própria.

A Figura 24 apresenta a aba *Complementary Plots*, destinada à visualização complementar dos dados de imagem por meio da representação tridimensional e por mapa de diferença. À esquerda, encontra-se o gráfico tridimensional de amplitude da imagem, representando a distribuição de intensidade (*Digital Numbers*) ao longo das coordenadas

espaciais x e y . da imagem. Essa representação pode ser útil para visualizar efeitos de suavização e adição de ruídos por uma nova perspectiva. O usuário pode modificar a imagem, proveniente de cada etapa do *software*, e ajustar a paleta de cores utilizada. À direita, encontra-se o *Heatmap* da diferença entre duas imagens. Essa representação evidencia, por meio de uma escala de cores a semelhança ou diferença entre as imagens selecionadas.

Figura 24 – Aba *Complementary Plots* com visualização tridimensional de intensidade e mapa de diferença entre imagens.



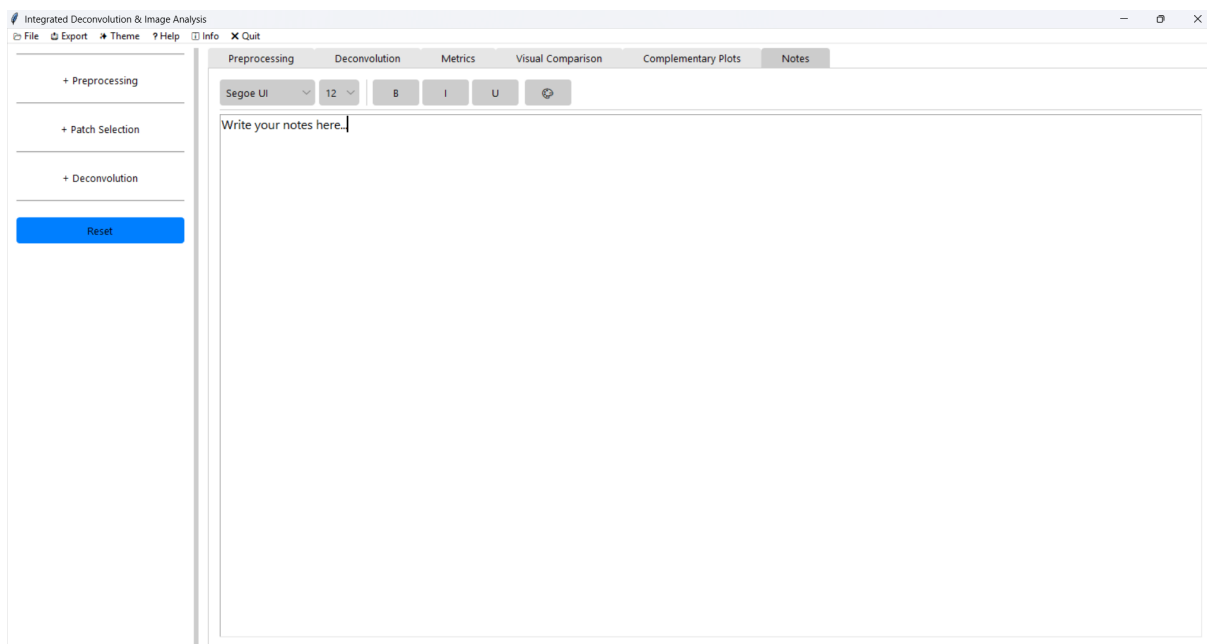
Fonte: Autoria própria.

A aba *Notes*, apresentada pela Figura 25, é um espaço destinado à inserção de anotações e observações do usuário diretamente dentro do ambiente do *software*. A interface da aba é composta por um editor de texto, com suporte a formatação tipográfica básica.

A Figura 26 apresenta a interface da funcionalidade de *Exportação Avançada*, responsável por permitir ao usuário salvar os resultados gerados pelo sistema em diferentes formatos. Essa funcionalidade é acessada por meio do menu *Export* da barra superior da interface e oferece uma janela independente. Na Figura 26a, observa-se o estado inicial da interface de exportação de imagens. O usuário pode escolher qual conteúdo será exportado (Figura 26b) e o formato de saída desejado (Figura 26c), que varia conforme o tipo de elemento a ser salvo. Após a seleção, basta acionar o botão *Save* para abrir a janela de exploração de arquivos e salvar no diretório definido.

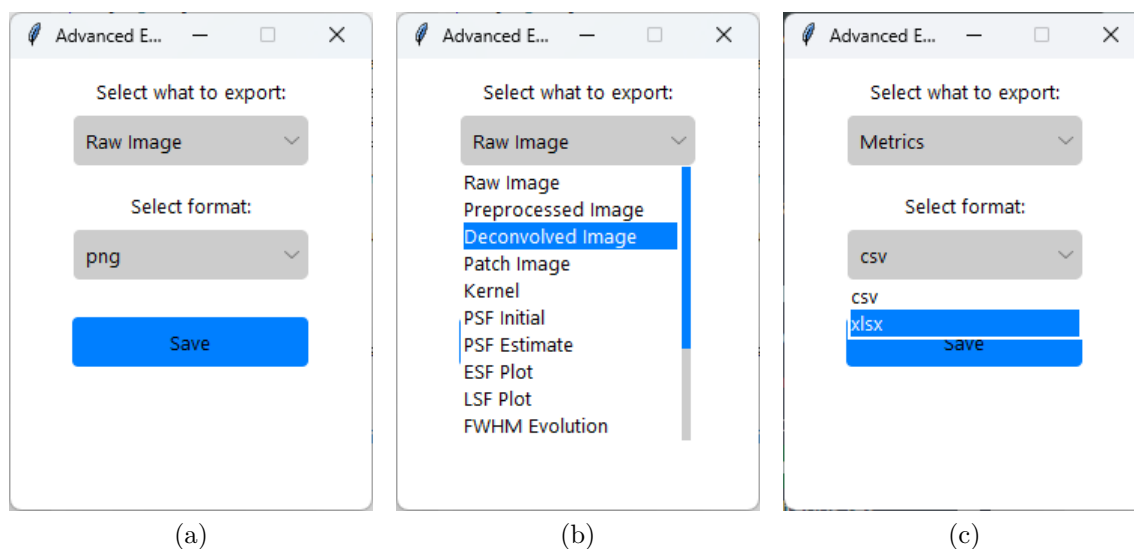
Intellectual Property Information é a janela exibida pela Figura 27, a qual é acessível por meio do menu *Info* localizado na barra superior da interface. Essa janela foi implementada com o objetivo de informar diretamente a propriedade da aplicação e seus recursos, o autor e a instituição associada.

Figura 25 – Aba *Notes*, dedicada ao registro de observações do usuário com suporte a formatação básica.



Fonte: Autoria própria.

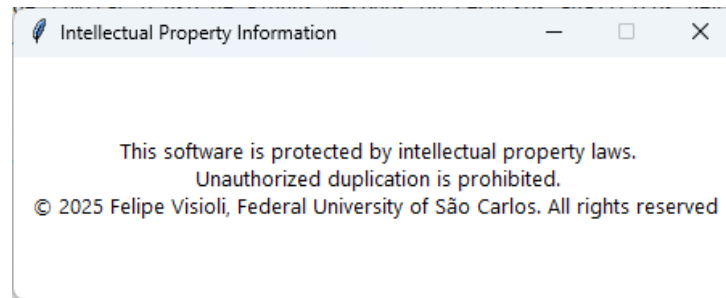
Figura 26 – Tela de exportação. a) Estado inicial da tela. b) Seletor da fonte de dados aberto c) Seletor do tipo de extensão do arquivo.



Fonte: Autoria própria.

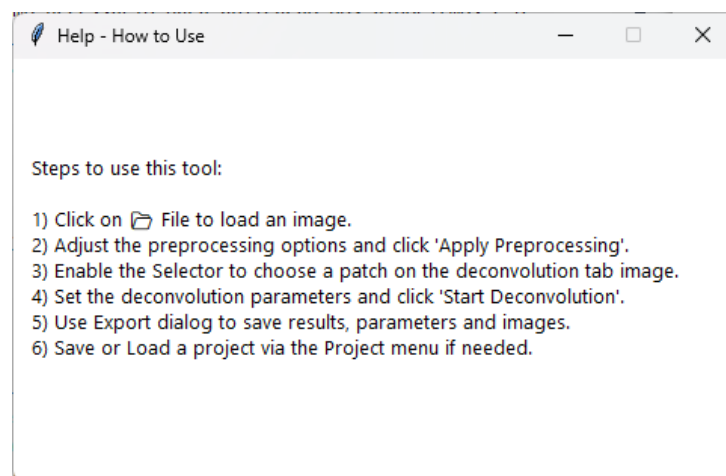
A Figura 28 exibe a janela *Help – How to Use*, acessível por meio do menu *Help* localizado na barra superior da interface. Essa janela tem por objetivo oferecer uma orientação concisa e direta ao usuário, especialmente útil para quem utiliza a ferramenta pela primeira vez ou deseja recordar o fluxo geral de operação.

Figura 27 – Janela de propriedade intelectual.




Fonte: Autoria própria.

Figura 28 – Janela de ajuda com instruções resumidas de uso do sistema.



Fonte: Autoria própria.

O *software* conta com um sistema de ajuda contextual por meio de *tooltips*, o qual pode ser visto pelo exemplo da Figura 29. Ele foi projetado para fornecer explicações rápidas sobre os controles da interface ao passar o cursor do mouse sobre um elemento interativo. Existem dois níveis de profundidade, sendo eles: uma explicação breve, exibida automaticamente ao repousar o cursor sobre um campo por mais de 2 segundos e uma descrição mais detalhada.

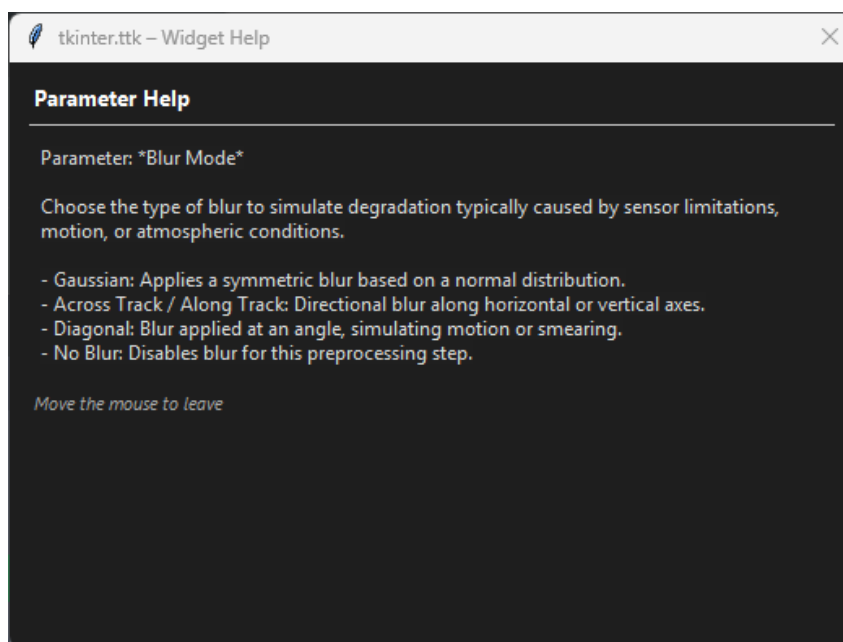
Figura 29 – Tooltip com explicação resumida e suporte à tecla *F1* para informações adicionais.

Fonte: Autoria própria.

A janela de ajuda detalhada, apresentada pela Figura 30, é o recurso ativado ao pressionar a tecla *F1* quando o foco está sobre um controle e a janela de ajuda contextual está

aberta, como na Figura 29. Essa funcionalidade complementa o sistema de ajuda com explicações mais profundas sobre o significado e a finalidade de cada parâmetro ajustável. A janela é exibida em posição flutuante e é automaticamente ocultada ao mover o cursor para fora de seus limites.

Figura 30 – Janela de ajuda contextual detalhada.



Fonte: Autoria própria.

9.2 Guia rápido do usuário


A presente seção visa apresentar um breve manual para a ferramenta desenvolvida, a fim de orientar seu uso adequado.

A lógica de navegação entre as etapas do processo de análise foi pensada para oferecer flexibilidade sem comprometer a integridade das operações. Como ilustrado na Figura 31, o usuário pode seguir o fluxo completo, passando por pré-processamento, seleção de *patch* e a deconvolução, ou optar por caminhos simplificados. O fluxo mínimo necessário para aplicação dos algoritmos é o carregamento direto da imagem. A exclusão das etapas de pré-processamento e seleção de *patch* é possível, mas pode limitar o uso de alguns métodos ou recursos analíticos devido à possível inexistência de variáveis cruciais.

A seguir, descrevem-se algumas recomendações de uso:

1. **Carregamento da imagem:** Para iniciar um projeto, o usuário deve acessar o menu *File* e selecionar a opção *New Project*. Um explorador de arquivos será aberto para escolha da imagem a ser analisada. Imagens em tons de cinza ou coloridas, nos formatos *.png*, *.jpg* ou *.tif* (*.tiff*) são suportadas. Contudo, imagens coloridas serão automaticamente transformadas para escala de cinza.

Figura 31 – Fluxos possíveis de operação da ferramenta IDIA.




- ① Fluxo completo
- ② Fluxo sem pré-processamento (não permite utilização do Filtro Inverso e do método de Wiener)
- ③ Fluxo sem seleção de patch (não permite visualização das funções métricas e suas estatísticas)

Fonte: Autoria própria.

2. **Pré-processamento da imagem:** Com a imagem carregada, o painel *Preprocessing* pode ser expandido. Nele, o usuário define o fator de reamostragem e os parâmetros de desfoque e ruído. Cada modo de degradação apresenta controles específicos, exibidos dinamicamente de acordo com a seleção. Após configurar os parâmetros, o botão *Apply Preprocessing* aplica as transformações e atualiza a visualização da imagem degradada e do kernel. O pré-processamento pode ser utilizado a qualquer momento e por múltiplas vezes, incidindo sempre sobre a imagem original carregada, ou seja, não possui efeito cumulativo.
3. **Seleção de região de interesse (patch):** Esta consiste na seleção de uma área específica da imagem para análise métrica. Isso é feito por meio do painel *Patch Selection*. Ao clicar em *Enable Selector*, o usuário é automaticamente direcionado para a aba *Deconvolution*. Nela, é possível traçar um retângulo sobre a imagem principal, indicando a região de interesse. Os botões *Reset Selector* e *Lock Patch Selection* permitem redefinir ou fixar a seleção, respectivamente. Ao fixar a seleção, os gráficos pertinentes serão atualizados.

É extremamente relevante ressaltar que o *patch* selecionado contenha, imprescindivelmente, uma região com contraste cujo perfil da borda seja predominantemente linear, como exemplificado pela Figura 32.

Figura 32 – Possíveis escolhas corretas de *patches*.

Fonte: Autoria própria.

4. **Configuração e execução da deconvolução:** O painel *Deconvolution* permite ao usuário selecionar o algoritmo desejado (Filtro Inverso, Wiener, Richardson-Lucy, Richardson-Lucy com TV ou *Deep Image Prior*) e ajustar seus parâmetros. A interface se adapta automaticamente ao método escolhido, exibindo os campos necessários. Após a configuração, o botão *Start* inicia o processo. Para métodos iterativos, a barra de progresso acompanha a execução e os resultados parciais são armazenados a cada iteração. É possível cancelar a execução da deconvolução a qualquer momento pelo botão *Cancel*.
5. **Análise dos resultados:** As abas superiores organizam a visualização dos resultados de maneira independente:
 - *Preprocessing*: compara a imagem original com a pré-processada, além de exibir a PSF aplicada;
 - *Deconvolution*: mostra a imagem restaurada, as PSFs inicial e estimada, os perfis ESF/LSF e a evolução do FWHM por iteração;
 - *Metrics*: exibe uma tabela com métricas quantitativas como PSNR, SSIM, NRMSE, FWHM, σ_x , σ_y e variância do Laplaciano;
 - *Visual Comparison*: permite alternar a visualização entre diferentes imagens (original, degradada, deconvoluída) e percorrer iterações para os métodos iterativos;
 - *Complementary Plots*: exibe visualizações 3D da imagem e mapa de calor da diferenças entre pares de imagens;
 - *Notes*: espaço livre para anotações com suporte a formatação de texto (fonte, tamanho, negrito, itálico, sublinhado e cor).
6. **Exportação dos resultados:** Através do menu *Export*, é possível salvar imagens, métricas, PSFs e gráficos. A funcionalidade de exportação avançada permite selecionar individualmente os elementos a serem salvos e o formato de arquivo mais adequado (*.png*, *.csv*, *.xlsx*, entre outros).
7. **Ajuda e documentação:** O menu *Help* fornece instruções resumidas de uso, e os campos interativos contam com *tooltips* automáticos acionados após 2 segundos de foco no elemento. Uma janela de ajuda detalhada é acionada pela tecla *F1*.
8. **Gerenciamento de projetos:** O menu *File* também permite salvar o progresso atual em um arquivo de projeto e recarregá-lo posteriormente com as configurações e resultados preservados. Isso facilita a documentação de experimentos e a retomada de análises em sessões futuras.

9. **Reinício da aplicação:** O botão *Reset* permite retornar a aplicação para o seu estado inicial. Qualquer configuração, processo ou dado será perdido se não for salvo antecipadamente.
10. **Informações:** Informações de uso e de propriedade intelectual podem ser acessadas pelos menus *Help* e *Info* da barra superior, respectivamente.

A execução da ferramenta IDIA exige os seguintes requisitos mínimos:

- Sistema operacional: Windows 10 (ou superior);
- Resolução de tela mínima recomendada: 1366×768 pixels;
- Memória RAM mínima recomendada: 8 GB;
- GPU com suporte a CUDA (opcional, mas recomendada para acelerar o método *Deep Image Prior*).

O *software* IDIA foi inteiramente desenvolvido em linguagem *Python*, aproveitando a flexibilidade de suas bibliotecas científicas e gráficas para construir tanto os algoritmos de deconvolução quanto a interface gráfica. No entanto, para facilitar sua distribuição e garantir acessibilidade a usuários não familiarizados com ambientes de desenvolvimento, a versão final foi compilada como um executável independente (*.exe*) para o sistema operacional Windows. Dessa forma, não é necessário instalar dependências externas ou configurar ambientes virtuais para utilizar a aplicação, o que amplia sua portabilidade e usabilidade.

O IDIA não apenas permite a aplicação prática dos algoritmos discutidos nos capítulos anteriores, mas também fornece uma base estruturada para comparação, visualização e análise quantitativa dos resultados de restauração. Sua modularidade favorece a replicação de experimentos, a inserção de novos algoritmos e a personalização de testes conforme seus objetivos.

10 Análise dos Resultados


Este capítulo apresenta uma análise sistemática dos resultados obtidos por meio da aplicação dos algoritmos de deconvolução implementados na ferramenta IDIA. A abordagem adotada contempla diferentes cenários de degradação, variando quanto ao tipo e intensidade do desfoque e à presença de ruído aditivo, permitindo avaliar a robustez e a efetividade de cada método sob condições controladas. Inicialmente, são discutidos os efeitos do pré-processamento sobre as imagens degradadas, seguido pela avaliação comparativa dos métodos nos casos de PSF conhecida (não cego) e PSF desconhecida (cego e semi-cego). Por fim, são discutidos aspectos qualitativos e estruturais da ferramenta desenvolvida, ressaltando seus êxitos e limitações.

10.1 Efetividade dos algoritmos de pré-processamento

Os algoritmos de pré-processamento implementados no *software* IDIA têm por objetivo simular, de forma controlada, condições de degradação observadas em sistemas de imageamento remoto. Esta seção apresenta os efeitos visuais da aplicação dos diferentes tipos de desfoque, ruído e suas combinações, com o intuito de verificar se os modelos implementados são capazes de reproduzir padrões realistas de degradação.

A Figura 33 apresenta os resultados da aplicação de diferentes funções de espalhamento. Observa-se que o desfoque gaussiano (b) provoca uma suavização isotrópica e uniforme das bordas, enquanto os desfoques direcionais, tanto horizontais (c), verticais (d) quanto diagonais (e), resultam em borramentos anisotrópicos, com perda de nitidez mais acentuada ao longo do eixo de orientação do kernel. Essas distorções são coerentes com os fenômenos de desfoque e degradação por movimento, respectivamente, e foram corretamente produzidas conforme as especificações de cada PSF.

Figura 33 – Imagem original (a) e imagens degradadas por diferentes tipos de desfoque: (b) Gaussiano, (c) horizontal, (d) vertical e (e) diagonal.

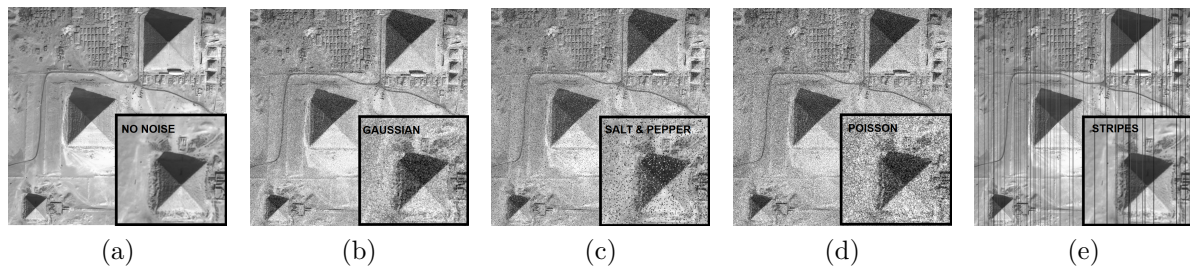


Fonte: Autoria própria.

Na Figura 34, são exibidos os efeitos de diferentes tipos de ruído. O ruído gaussiano

(b) introduz uma variação aleatória de pequena amplitude sobre todos os pixels, o que é característico de sensores eletrônicos em condições de baixa razão sinal-ruído. O ruído sal e pimenta (c) gera pixels com valores máximos e mínimos de forma esparsa e aleatória, causando artefatos pontuais que dificultam a recuperação de bordas. O ruído de Poisson (d), por sua vez, simula flutuações fotônicas dependentes da intensidade do sinal. Por fim, o ruído de listras verticais (e) reproduz padrões periódicos estruturados que simulam falhas em sensores lineares. A fidelidade com que esses padrões foram reproduzidos demonstra a capacidade da implementação feita em simular diferentes regimes de ruído de forma controlada e adaptada a cada contexto experimental.


Figura 34 – Imagem original (a) e imagens degradadas por diferentes tipos de ruído: (b) Gaussiano, (c) Sal e Pimenta, (d) Poisson e (e) Listras verticais.



Fonte: Autoria própria.

A Figura 35 mostra casos em que desfoque e ruído foram aplicados conjuntamente. Essa simulação composta é mais próxima das condições reais de aquisição, em que a imagem é acometida simultaneamente por distorções e ruídos. Observa-se que a presença de ruído compromete ainda mais a percepção de detalhes já degradados pelo desfoque, o que justifica a necessidade de técnicas de deconvolução para restauração.

Figura 35 – Imagens degradadas por associação de desfoque e ruído: (a) Desfoque Gaussiano e ruído gaussiano, (b) Desfoque vertical e ruído Sal e Pimenta, (c) Desfoque horizontal e ruído Poisson, (d) Desfoque diagonal e listras verticais.



Fonte: Autoria própria.

Os resultados apresentados confirmam que os algoritmos de pré-processamento foram implementados com coerência e rigor funcional, atingindo seus objetivos com fidelidade e permitindo a geração de diferentes cenários de degradação. Portanto, os algoritmos servem

como base concreta para a análise e validação dos métodos de deconvolução discutidos nas seções seguintes.

10.2 Deconvolução com PSF conhecida (caso não cego)

Neste cenário, assume-se que a PSF é plenamente conhecida. Essa premissa permite avaliar o desempenho dos algoritmos de deconvolução em condições ideais, isolando as análises de qualquer incerteza na estimativa do modelo de degradação. Concentra-se, portanto, em explorar a capacidade dos métodos de restaurarem a nitidez e o contraste da imagem original, levando em consideração informações a priori dos modelos de degradação.

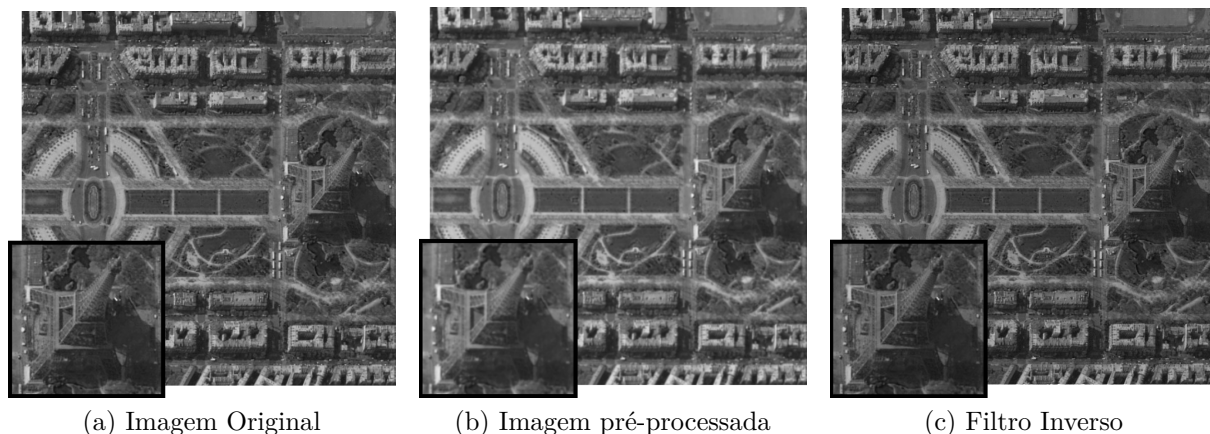
10.2.1 Desfoque isotrópico leve

Nesta subseção, analisam-se os resultados obtidos para o caso de desfoque isotrópico leve, sem a presença de ruído aditivo. A escolha desse cenário visa avaliar o desempenho dos algoritmos em condições favoráveis, nas quais o modelo de degradação (PSF) é conhecido e a ausência de ruído beneficia todos os métodos de deconvolução.

A Figura 36 apresenta, respectivamente, a imagem original, a imagem após o pré-processamento e o resultado da deconvolução utilizando o filtro inverso. Observa-se que o pré-processamento foi aplicado corretamente, produzindo uma versão degradada da imagem original com leve perda de nitidez, como esperado.

O método de Filtro Inverso apresentou bom desempenho nesse cenário. Por conhecer exatamente a PSF e operar em ambiente completamente livre de ruído, o método recuperou detalhes com elevado grau de fidelidade. As métricas obtidas reforçam essa observação, com PSNR de 18,09 dB e SSIM de 0,8040.

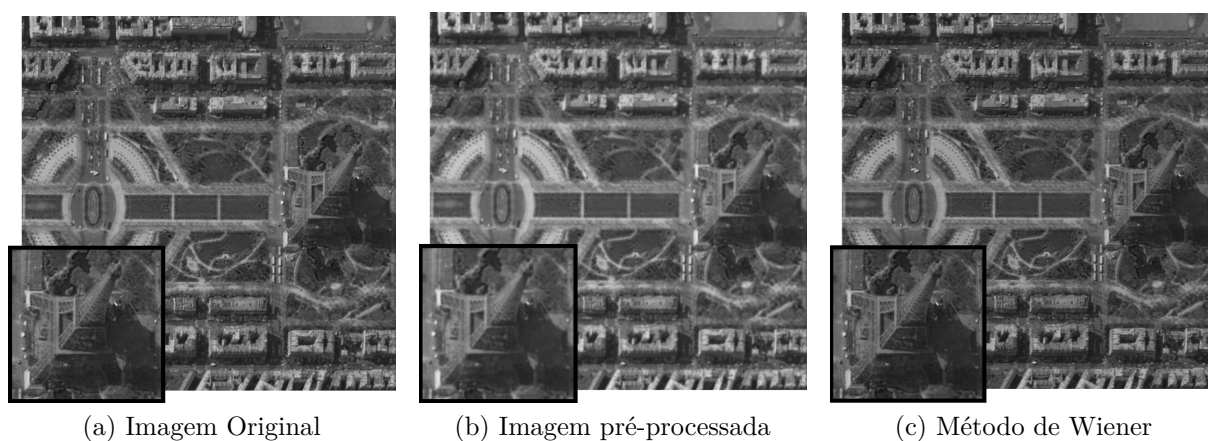
Figura 36 – Imagem original, imagem pré-processada com desfoque leve e resultado da deconvolução por Filtro Inverso.



Fonte: Autoria própria.

A Figura 37 mostra os mesmos estágios para o método de Wiener. Neste caso, a imagem restaurada apresenta resultado visualmente equivalente ao obtido pelo filtro inverso. Como a imagem degradada está livre de ruído, o parâmetro de suavização ($k = 0,0001$) teve pouca influência sobre a imagem estimada, permitindo a recuperação da nitidez como em um Filtro Inverso. As métricas obtidas confirmam a qualidade similar da restauração proveniente dos métodos para esse caso de estudo: PSNR de 18,04 dB e SSIM de 0,8054, valores bastante próximos aos obtidos pelo filtro inverso.

Figura 37 – Imagem original, imagem pré-processada com desfoque leve e resultado da deconvolução por Wiener.



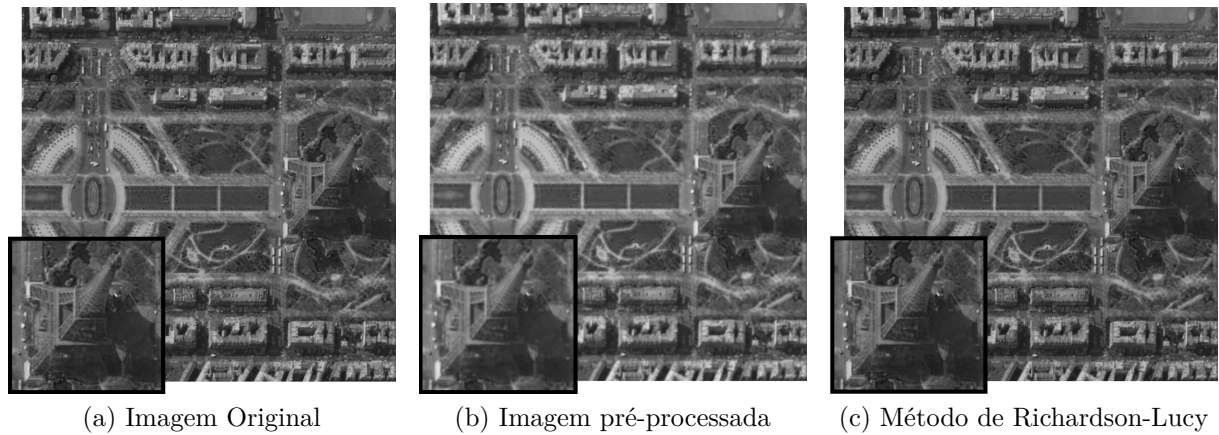
Fonte: Autoria própria.

A Figura 38 apresenta os resultados para o método de Richardson-Lucy, executado com a PSF exata como entrada inicial. Esse método é iterativo, e sua performance está diretamente relacionada à escolha adequada do número de iterações. A imagem ótima foi obtida na iteração 14, ponto em que o FWHM atingiu seu menor valor (2,0486). Ou seja, nessa iteração, produziu-se o menor espalhamento das bordas, o que implica no melhor contraste e nitidez entre as iterações. Visualmente, o método produziu uma imagem com boa recuperação de contraste e detalhe, sem criação de artefatos relevantes. As métricas relacionadas confirmam esse desempenho, sendo as mais relevantes o SSIM de 0,9878 e NRMSE baixo (0,0265), que indicam elevada similaridade com a imagem original.

A Figura 39 mostra os resultados para o método de Richardson-Lucy com regularização por *Total Variation* (RL+TV), cujo resultado ótimo, segundo a FWHM, também ocorreu na 14ª iteração. Como não há ruído no cenário, o peso do termo de regularização foi definido como pequeno (0,01), de modo que o comportamento do método se aproxime muito ao do RL tradicional.

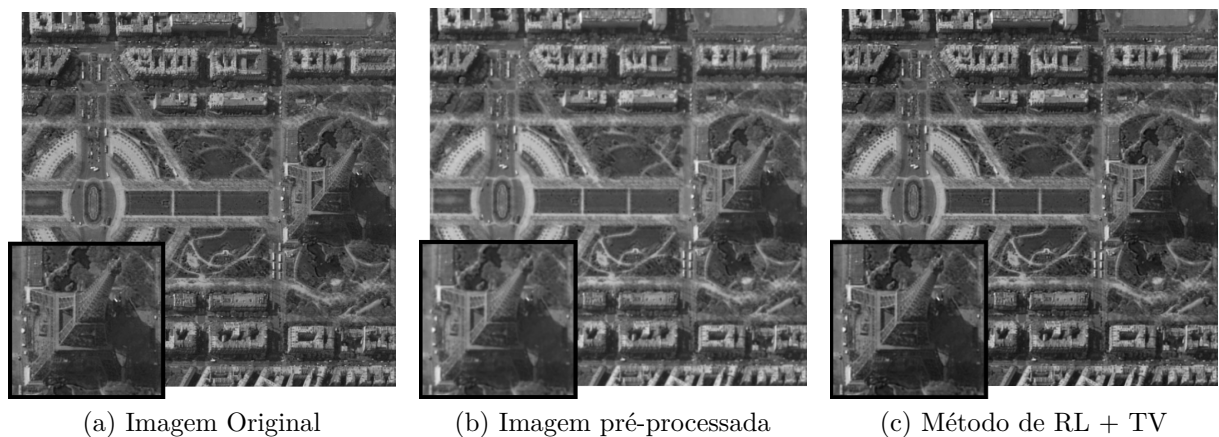
Visualmente e de acordo com as métricas angariadas, os resultados são praticamente idênticos. PSNR, SSIM e FWHM mantêm os mesmos valores da versão sem regularização. A vantagem, neste caso, seria mais evidente em situações com ruído, o que não se aplica aqui.

Figura 38 – Imagem original, imagem pré-processada com desfoque leve e resultado da deconvolução por RL.



Fonte: Autoria própria.

Figura 39 – Imagem original, imagem pré-processada com desfoque leve e resultado da deconvolução por RL+TV.



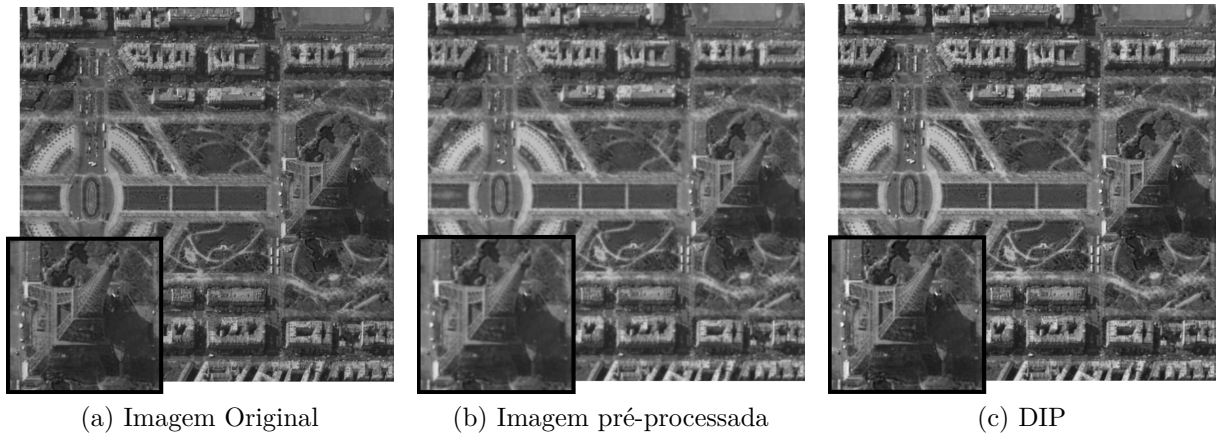
Fonte: Autoria própria.

A Figura 40 exibe os resultados para o método *Deep Image Prior*, que alcançou seu melhor resultado na iteração 1855. O DIP é notoriamente mais custoso computacionalmente, pois exige milhares de iterações para convergir e, por consequência, consome mais tempo que os demais métodos. Ainda assim, demonstrou capacidade de reconstrução satisfatória, mesmo sem qualquer dado prévio sobre a imagem original, além da PSF. As métricas obtidas reforçam a qualidade da imagem restaurada, que apresenta alta similaridade com a imagem original (SSIM de 0,9484).

Para facilitar a comparação visual entre os métodos, a Figura 41 reúne lado a lado as imagens restauradas por cada um dos cinco algoritmos.

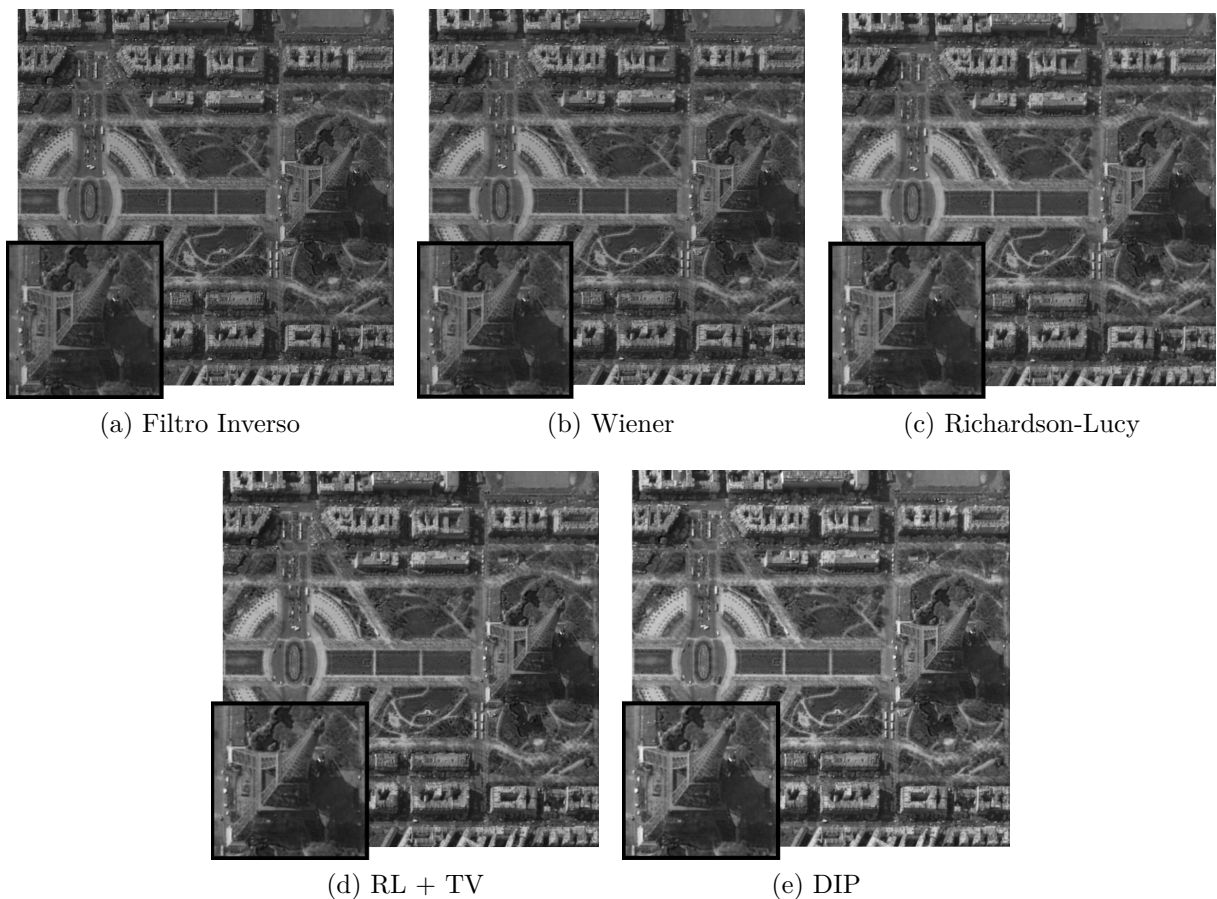
A Tabela 1 apresenta as métricas quantitativas dos métodos testados, permitindo comparações diretas entre acurácia estrutural (SSIM), fidelidade numérica (PSNR, NRMSE) e fator de borrimento das bordas (FWHM). A partir dela vê-se que os métodos iterativos RL e RL+TV destacaram-se amplamente. Ambos alcançaram SSIM de 0,9878 e

Figura 40 – Imagem original, imagem pré-processada com desfoque leve e resultado da deconvolução por DIP (iteração 1855).



Fonte: Autoria própria.

Figura 41 – Comparativo visual entre os resultados dos cinco métodos de deconvolução.



Fonte: Autoria própria.

NRMSE de apenas 0,0265, indicando uma reconstrução bastante próxima da imagem original, embora apresentem FWHM de 2,0486, ligeiramente superior ao de outros métodos. O método DIP apresentou desempenho intermediário para a configuração. Com PSNR de 25,68 dB e SSIM de 0,9484, ele conseguiu recuperar grande parte da estrutura da

imagem e, notavelmente, apresentou o menor FWHM (1,9435) entre todos os métodos, o que sugere uma recuperação mais concentrada das bordas. Esse comportamento pode estar associado ao viés das redes convolucionais em priorizar estruturas regulares e contornos. Os métodos não iterativos tiveram desempenho um pouco inferior, refletindo alguma perda estrutural na imagem.

Vale citar que, pelas observações empíricas, um menor FWHM nem sempre se traduz em superioridade visual ou métrica geral. Uma hipótese é que ele reflita mais a acentuação artificial de transições do que uma real recuperação do conteúdo original, logo, deve ser sempre analisado com cuidado e preferencialmente associado a outras métricas.

Tabela 1 – Comparativo geral das métricas para o caso de desfoque isotrópico leve.

| <i>Método</i> | It. | PSNR | SSIM | NRMSE | Var_{∇^2} | FWHM |
|-----------------------------|------|-------|--------|--------|-------------------------|--------|
| Filtro Inverso | – | 18.09 | 0.8040 | 0.3280 | 1730.516 | 1.9264 |
| Wiener ($k = 0,0001$) | – | 18.04 | 0.8054 | 0.3297 | 1619.305 | 1.9659 |
| RL | 14 | 39.93 | 0.9878 | 0.0265 | 294.429 | 2.0486 |
| RL + TV (peso = 0,01) | 14 | 39.93 | 0.9878 | 0.0265 | 294.427 | 2.0486 |
| DIP (learning rate = 0,001) | 1855 | 25.68 | 0.9484 | 0.1368 | 534.562 | 1.9435 |

Fonte: Autoria própria.

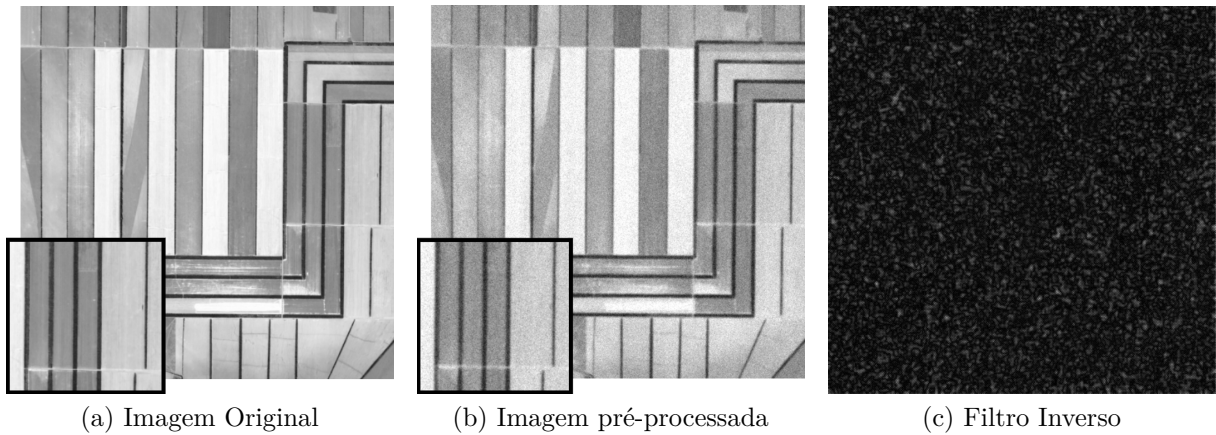
10.2.2 Desfoque isotrópico leve com ruído aditivo

São analisados nessa subseção os resultados da deconvolução para imagens submetidas simultaneamente a desfoque isotrópico leve e ruído aditivo. A presença de ruído impõe uma condição mais desafiadora para os algoritmos, especialmente os não iterativos ou cujos modelos não incorporam alguma regularização. O objetivo desta análise é avaliar a robustez de cada método frente a esse caso específico, observando tanto os resultados visuais quanto as métricas quantitativas.

A Figura 42 apresenta a imagem original, a imagem pré-processada, com desfoque e ruído, e o resultado da deconvolução utilizando o filtro inverso. Diferente do cenário da seção anterior, o resultado é insatisfatório, dado que o filtro inverso é instável e amplifica significativamente o ruído presente na imagem degradada, gerando uma imagem restaurada ininteligível. Isso era esperado, pois o método aplica uma inversão direta da PSF no domínio espectral, o que amplifica componentes de alta frequência onde o ruído está concentrado.

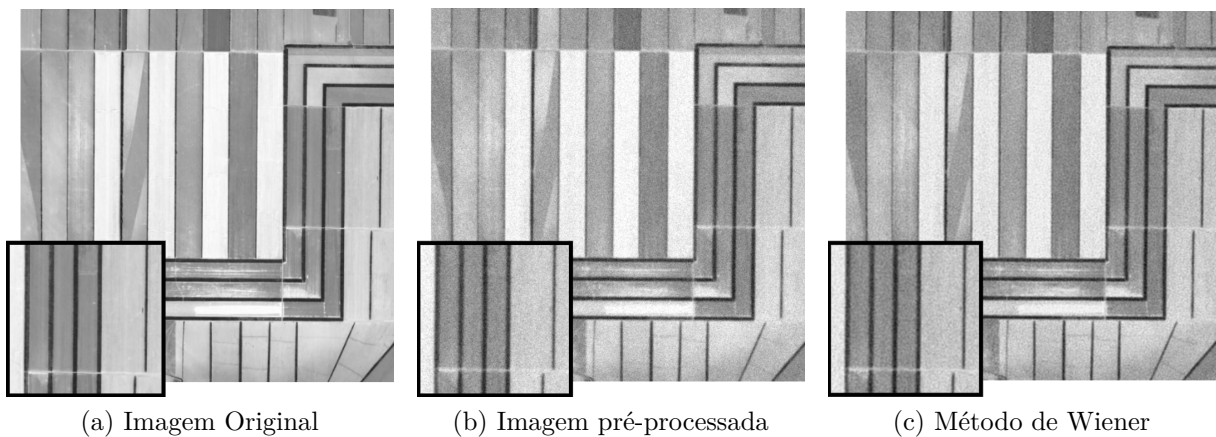
Analogamente, a Figura 43 mostra os mesmos estágios para o método de Wiener. O desempenho do método é altamente superior ao do Filtro Inverso. A introdução do parâmetro de regularização $k = 0,3$ atenua os efeitos do ruído, suavizando a imagem, mas preservando a maior parte de suas estruturas. Visualmente, observa-se uma imagem suavizada, com contornos preservados, baixa amplificação ruidosa, mas com pouco efeito de restauração do contraste.

Figura 42 – Imagem original, imagem degradada e resultado da deconvolução por Filtro Inverso na presença de ruído aditivo.



Fonte: Autoria própria.

Figura 43 – Imagem original, imagem degradada e resultado da deconvolução por Wiener com ruído aditivo.



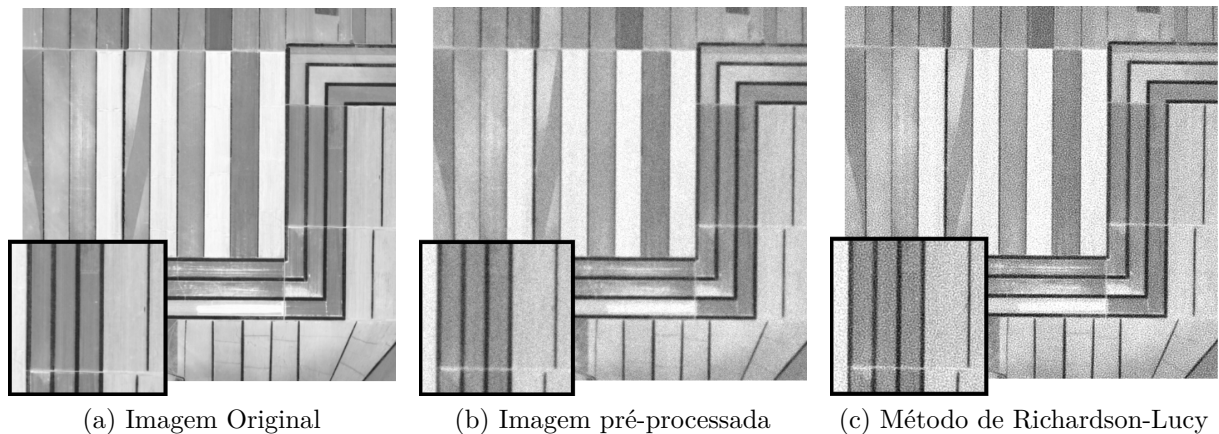
Fonte: Autoria própria.

Os resultados para o método de Richardson-Lucy são mostrados pela Figura 44. A imagem restaurada foi extraída na 16^a iteração, a qual apresentou o menor FWHM (4,1083) dentre todas. Apesar do bom detalhamento observado, a presença de ruído impacta fortemente a estabilidade do método, gerando artefatos nas regiões homogêneas e comprometendo a qualidade visual. As métricas obtidas são significativamente inferiores às dos métodos regularizados (SSIM de apenas 0,3495 e PSNR de 20,30 dB).

A Figura 45 mostra os resultados obtidos com o método Richardson-Lucy com regularização por *Total Variation*. Para esse caso, o melhor resultado ocorreu já na 6^a iteração, com FWHM de 3,4218. A introdução da regularização trouxe ganhos evidentes em termos de redução de ruído e preservação estrutural. A redução de ruídos implica diretamente na quantidade de artefatos criados pela deconvolução. Comparado ao RL tradicional, o método RL+TV resultou em uma imagem mais suave e coerente, com artefatos menos intensos do que os observados anteriormente. As métricas corroboram a melhora, com

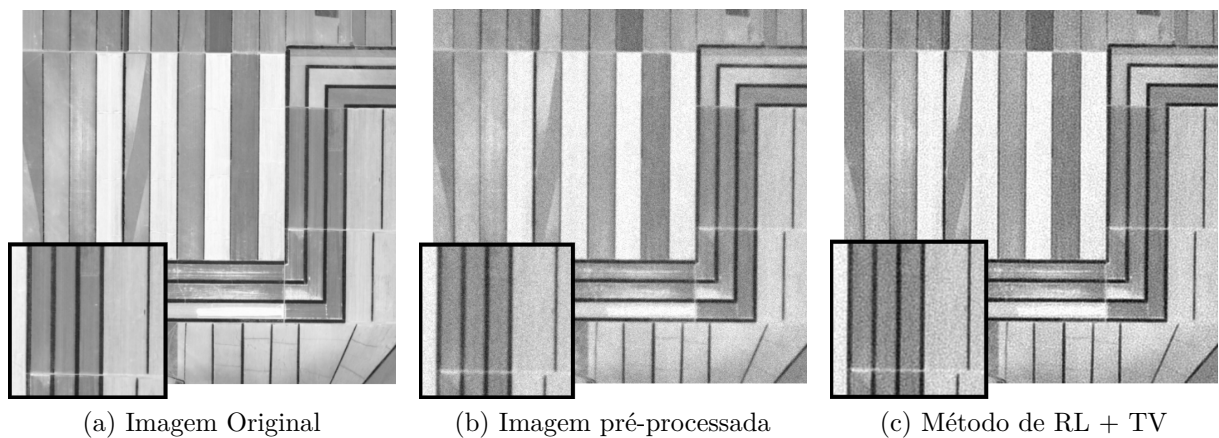
SSIM de 0,5800 e PSNR de 26,20 dB, valores comparáveis ao do método de Wiener. É importante dizer que, se aumentado o fator de regularização, seria possível eliminar mais os ruídos amplificados, mas isso ocorre sempre em detrimento da recuperação do contraste e da nitidez.

Figura 44 – Imagem original, imagem degradada e resultado da deconvolução por RL com ruído aditivo.



Fonte: Autoria própria.

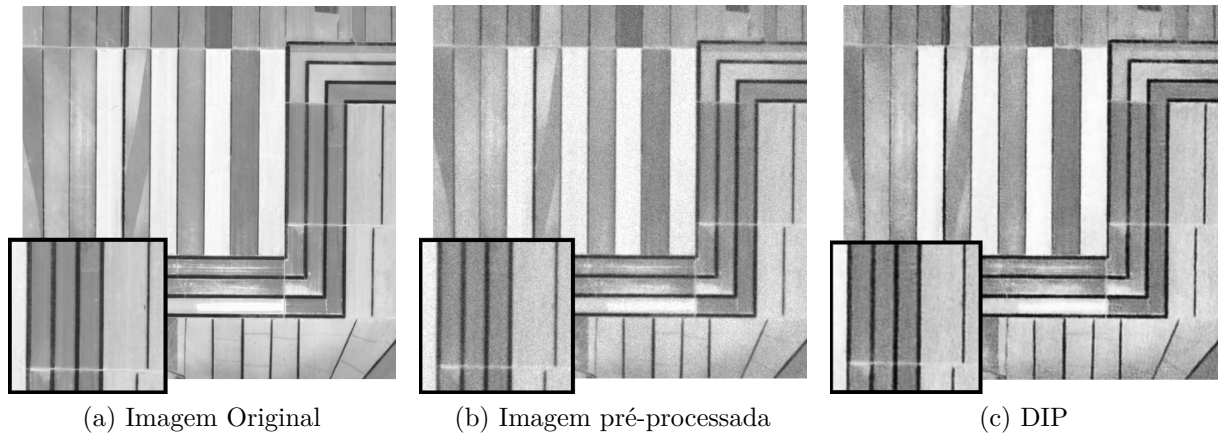
Figura 45 – Imagem original, imagem degradada e resultado da deconvolução por RL+TV com ruído aditivo.



Fonte: Autoria própria.

Com o uso do DIP, obteve-se a imagem deconvoluída mostrada pela Figura 46. A restauração foi interrompida na iteração 650, ponto no qual as métricas indicaram convergência satisfatória. O método se mostrou o mais eficaz neste cenário, atingindo o SSIM elevado (0,7469). Visualmente, a imagem restaurada apresenta bons contornos e o menor nível de ruído perceptível dentre os resultados dos métodos trabalhados. O resultado evidencia o potencial do DIP para lidar com degradações compostas, ainda que a um custo computacional significativamente mais alto quando comparado ao custo dos demais métodos.

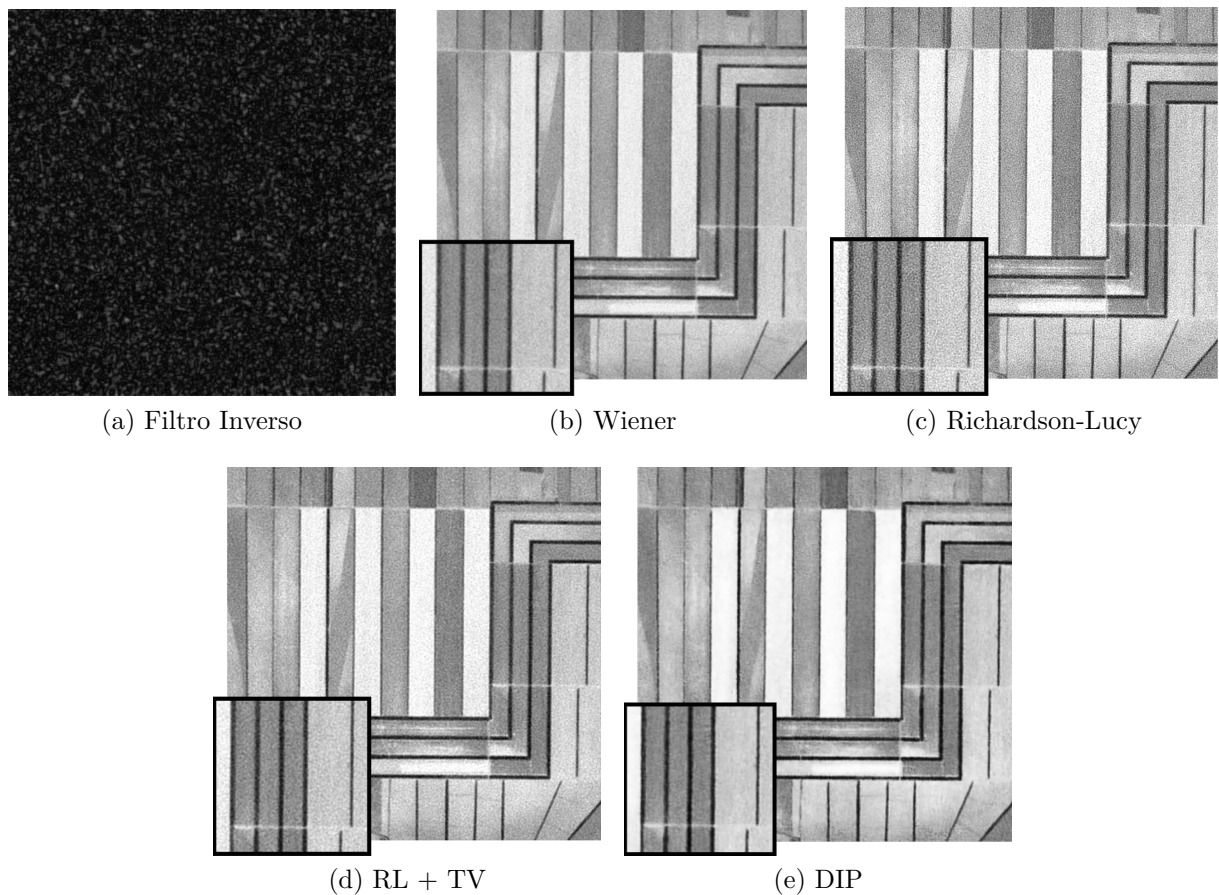
Figura 46 – Imagem original, imagem degradada e resultado da deconvolução por DIP com ruído aditivo.



Fonte: Autoria própria.

A Figura 47 reúne, lado a lado, os resultados visuais finais para os cinco métodos de deconvolução avaliados nesta subseção.

Figura 47 – Comparativo visual entre os resultados dos cinco métodos com desfoque leve e ruído aditivo.



Fonte: Autoria própria.

Os dados da Tabela 2 reforçam as observações visuais feitas anteriormente. O método

DIP foi o que apresentou os melhores resultados gerais, alcançando o maior PSNR (27,30 dB), o menor NRMSE (0,0616) e o menor FWHM (2,3379). Isso indica um potencial de recuperação visual e estrutural maior mesmo em presença de ruído. O RL tradicional apresentou SSIM de apenas 0,3495 e PSNR de 20,30 dB, com alta variância do Laplaciano, o que confirma a presença de artefatos e ruído amplificado. Por outro lado, o RL + TV mostrou-se mais estável e eficiente, com métricas significativamente melhores, evidenciando a importância da regularização em casos análogos ao trabalhado.

Por fim, destaca-se que o Filtro Inverso, como esperado, falhou completamente neste cenário, sendo incapaz de produzir uma imagem restaurada viável. Seu comportamento em presença de ruído é altamente instável e, portanto, o método deve ser evitado em contextos como esse.

Essa análise confirma que a robustez frente ao ruído é o fator crítico e mais desafiador para os algoritmos de deconvolução e que estratégias baseadas em regularização (como RL+TV) ou em redes neurais convolucionais (como DIP) tendem a apresentar melhor desempenho.

Tabela 2 – Comparativo geral das métricas para o caso de desfoque isotrópico leve com ruído aditivo.


| <i>Método</i> | It. | PSNR | SSIM | NRMSE | Var_{∇^2} | FWHM |
|-----------------------------|-----|-------|--------|--------|-------------------------|--------|
| Filtro Inverso | – | – | – | – | – | – |
| Wiener ($k = 0,3$) | – | 26.86 | 0.7919 | 0.0648 | 125.205 | 4.1149 |
| RL | 16 | 20.30 | 0.3495 | 0.1380 | 9540.598 | 4.1083 |
| RL + TV (peso = 1,3) | 6 | 26.20 | 0.5800 | 0.0700 | 962.479 | 3.4218 |
| DIP (learning rate = 0,001) | 650 | 27.30 | 0.7469 | 0.0616 | 612.324 | 2.3379 |

Fonte: Autoria própria.

10.2.3 Desfoque isotrópico intenso

Nesta subseção, analisa-se o comportamento dos algoritmos frente a uma degradação mais severa, provocada por uma PSF isotrópica de maior espalhamento. O objetivo é avaliar a capacidade dos métodos de recuperar detalhes e preservar estruturas sob condições extremas de borramento. A Figura 48 ilustra a imagem original e sua versão degradada produzida pelo pré-processamento. Visualmente, o desfoque introduzido resultou em perda significativa de contraste e apagamento de detalhes finos, especialmente nas bordas dos edifícios. O padrão de simetria circular da PSF, evidenciado no canto inferior direito da imagem, reforça o caráter isotrópico da degradação. Tal espalhamento representa um desafio mais pronunciado para os algoritmos de deconvolução, tendo em vista que detalhes mais finos têm sua informação espalhada pela PSF a ponto de ser difícil ou, por vezes, impossível recuperá-los.

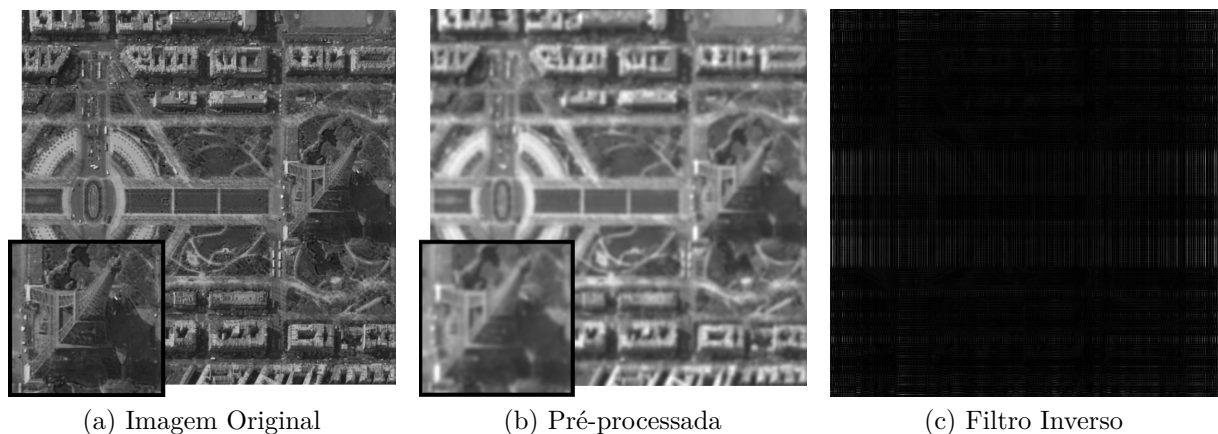
Figura 48 – Imagem original (a) e versão degradada com desfoque isotrópico intenso (b).



Fonte: Autoria própria.

Neste cenário de desfoque severo, o filtro inverso falha completamente, como evidenciado pela Figura 49, resultando em uma imagem tomada por artefatos. O filtro inverso é notoriamente instável frente a degradações severas e à presença de componentes de alta frequência mal condicionados, o que se traduz em total perda de informação útil.

Figura 49 – Resultado da deconvolução com Filtro Inverso.

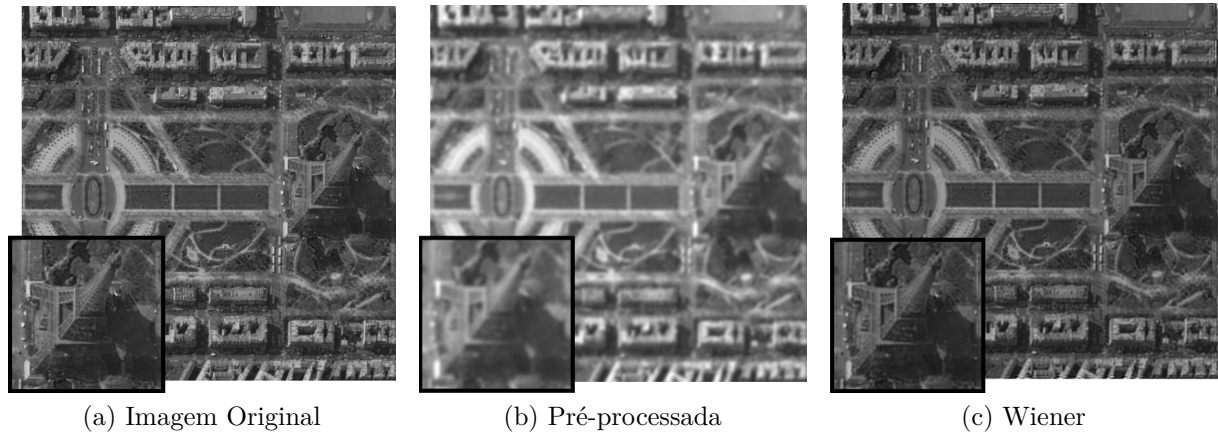


Fonte: Autoria própria.

A Figura 50 apresenta o resultado da aplicação do método de Wiener. Apesar da severidade do desfoque, o método conseguiu bom desempenho na restauração da imagem. Como esperado, o filtro atuou com suavização moderada, controlando a amplificação do ruído em altas frequências. A deconvolução por filtro inverso falha em imagens suavizadas intensamente devido a problemas numéricos e de amplificação de ruído, enquanto a

deconvolução de Wiener lida melhor com essas situações porque incorpora informações estatísticas do sinal na sua formulação.

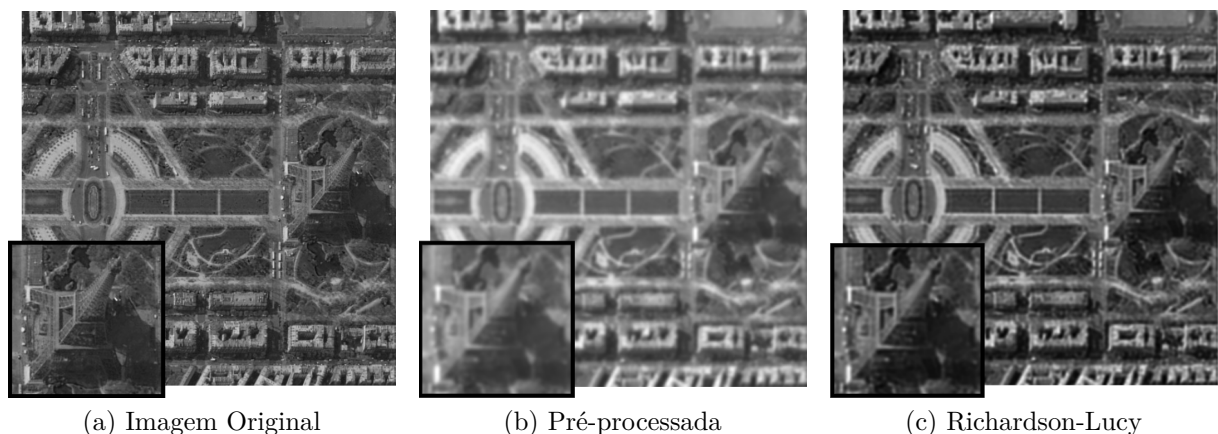
Figura 50 – Resultado da deconvolução com método de Wiener.



Fonte: A autoria própria.

É possível analisar, pela Figura 51, o resultado do método de Richardson-Lucy, cuja melhor imagem foi obtida na 20ª iteração. Visualmente, nota-se um contraste mais pronunciado e recuperação parcial de contornos que estavam completamente desfocados, especialmente daqueles de alta frequência espacial. No entanto, detalhes finos como as treliças da torre não são satisfatoriamente recuperados. As métricas indicam um SSIM de 0,7641 e PSNR de 27,34 dB. O FWHM obtido foi de 4,0550, o maior entre todos os métodos testados neste cenário, sugerindo que o contraste foi, potencialmente, reforçado em detrimento da naturalidade dos contornos.

Figura 51 – Resultado da deconvolução com método de Richardson-Lucy.

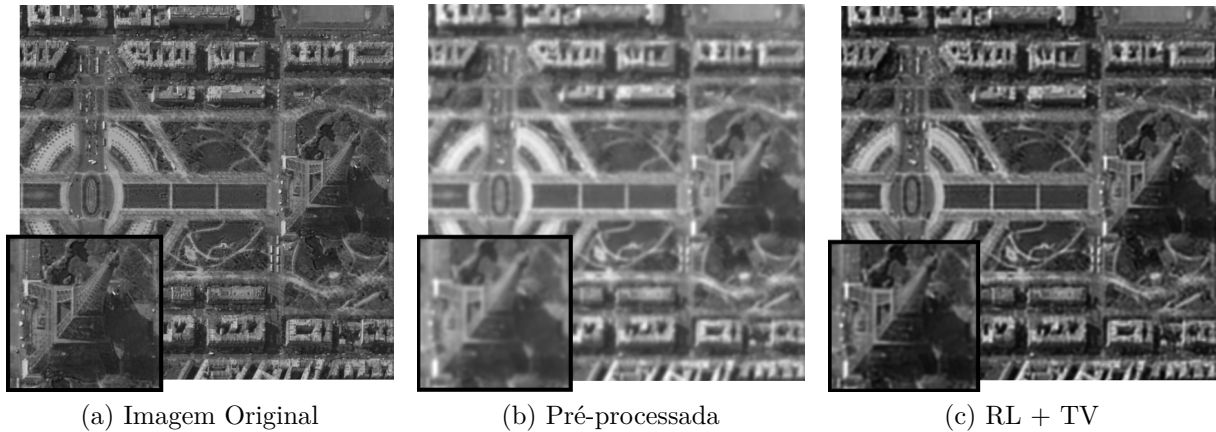


Fonte: A autoria própria.

A Figura 52 exibe os resultados para o método RL+TV, cuja melhor iteração foi a de número 19. Visualmente, observa-se uma imagem muito semelhante à produzida pelo RL tradicional. A suavização promovida pela regularização foi pequena, o que embasa

a análise anterior acerca da tendência desse método em reproduzir os resultados da deconvolução de RL na ausência de ruído. Os valores obtidos para as métricas são muito próximos aos do RL comum, confirmando quantitativamente a semelhança dos resultados.

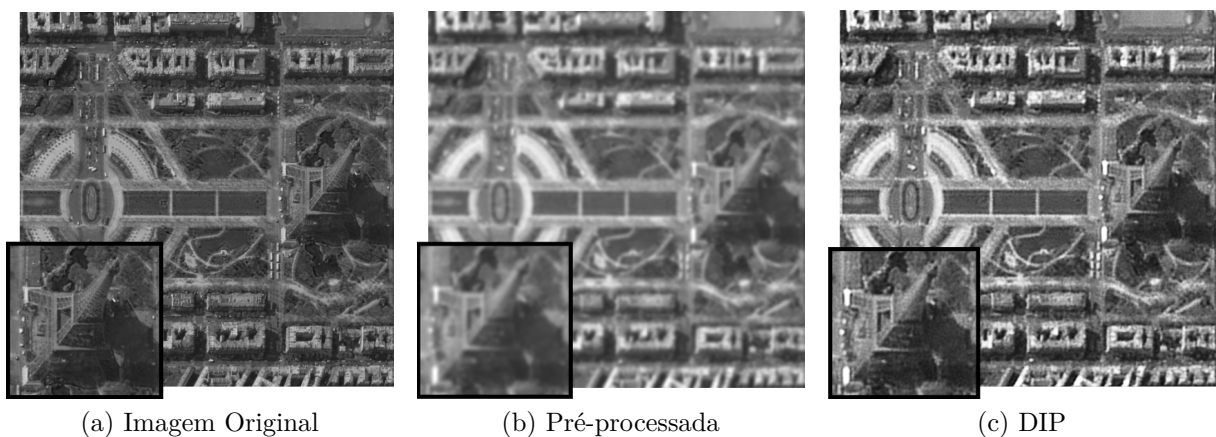
Figura 52 – Resultado da deconvolução com método RL + TV (iteração 19).



Fonte: Autoria própria.

Por fim, a Figura 53 apresenta os resultados do método *Deep Image Prior*, cuja restauração considerada ótima foi obtida na iteração 1847. Diferente dos métodos anteriores, o DIP não apresenta tendência à granularidade e consegue recuperar a organização espacial global da imagem com boa suavidade. No entanto, a intensidade do desfoque imposta pela PSF fez com que a rede apresentasse resultados um pouco inferiores aos demais métodos, segundo as métricas, embora a imagem seja visualmente coerente.

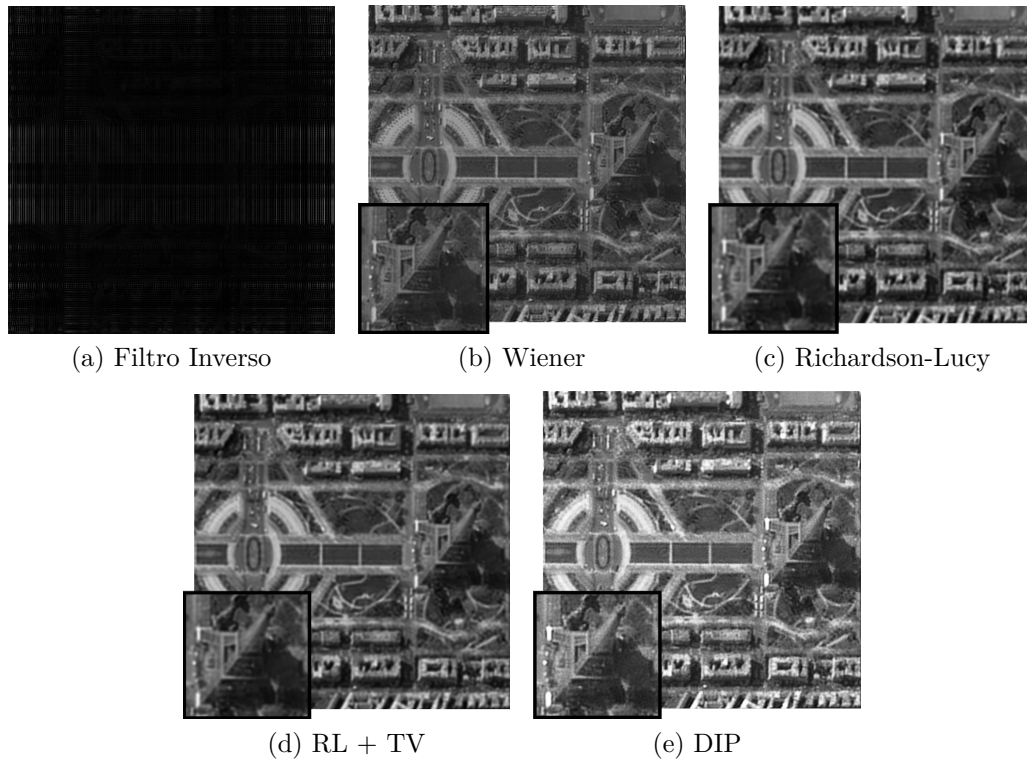
Figura 53 – Resultado da deconvolução com método DIP (iteração 1847).



Fonte: Autoria própria.

Para facilitar a comparação entre os diferentes métodos de deconvolução aplicados ao caso de desfoque isotrópico intenso, a Figura 54 apresenta o conjunto de resultados angariados.

Figura 54 – Comparativo visual entre os resultados dos cinco métodos de deconvolução no caso de desfoque intenso.



Fonte: Autoria própria.

A Tabela 3 apresenta o resumo quantitativo das métricas obtidas para cada método. Ao contrário do caso com desfoque leve, nenhum método alcança níveis muito elevados de SSIM ou PSNR, o que evidencia a complexidade do cenário imposto por uma PSF intensamente degradante. O método DIP teve desempenho ligeiramente inferior em PSNR e NRMSE, o que pode ser atribuído à complexidade da cena combinada à ausência de conhecimento explícito sobre a imagem original e ao apagamento de componentes espectrais mais elevadas. Apesar disso, apresentou o menor FWHM, o que pode refletir o viés da rede em preservar transições abruptas, embora isso não se traduza necessariamente em fidelidade visual ou estrutural. De modo geral, o cenário de desfoque intenso revela limitações significativas para todos os métodos.

Tabela 3 – Comparativo geral das métricas para o caso de desfoque isotrópico intenso.

| Método | It. | PSNR | SSIM | NRMSE | Var_{∇^2} | FWHM |
|-----------------------------|------|-------|--------|--------|-------------------------|--------|
| Filtro Inverso | – | – | – | – | – | – |
| Wiener ($k = 0,0001$) | – | 26.01 | 0.8808 | 0.1318 | 88.229 | 3.6636 |
| Richardson-Lucy | 20 | 27.34 | 0.7641 | 0.1130 | 25.172 | 3.9602 |
| RL + TV (peso = 0,01) | 19 | 27.32 | 0.7626 | 0.1133 | 24.872 | 3.9628 |
| DIP (learning rate = 0,001) | 1847 | 16.38 | 0.7276 | 0.3993 | 186.832 | 3.8076 |

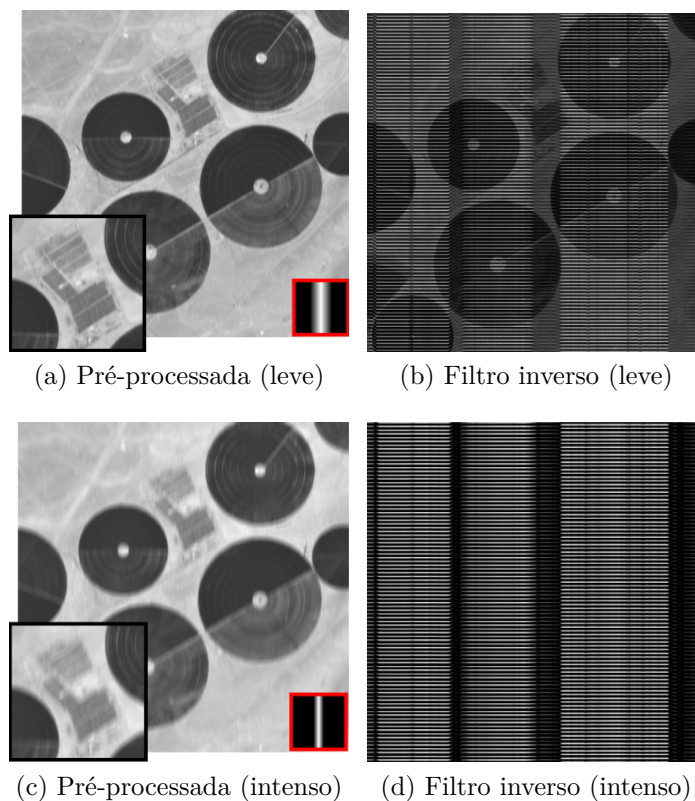
Fonte: Autoria própria.

10.2.4 Desfoque direcional

A seguir, examina-se a performance dos algoritmos de deconvolução frente a distorções do tipo desfoque direcional que emulam, por exemplo, distorções por movimento. Este tipo de degradação é particularmente desafiador, pois os detalhes são afetados de forma não isotrópica, simulando o efeito de movimento durante a captura da imagem. Dois níveis de desfoque direcional foram empregados, leve e intenso, ambos com PSF conhecida e alinhada ao eixo vertical. As análises a seguir consideram a aplicação dos cinco algoritmos sobre as imagens degradadas, com avaliação visual e métrica dos resultados.

No caso do filtro inverso, o resultado foi completamente comprometido em ambos os níveis de desfoque. Como mostra a Figura 55, a imagem restaurada apresenta padrões de artefatos evidentes, especialmente para o caso intenso.

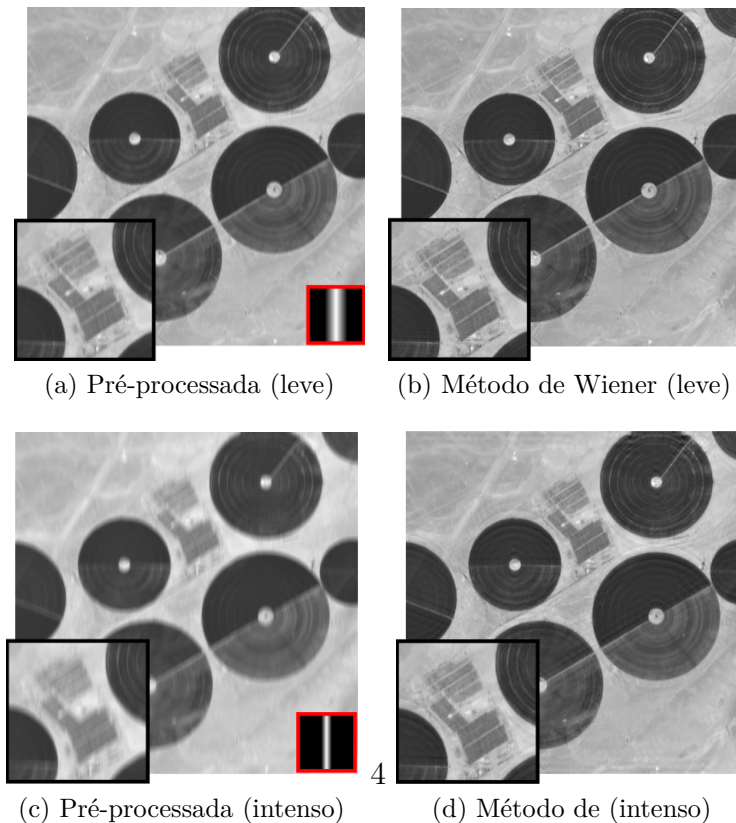
Figura 55 – Resultados do Filtro Inverso para desfoque direcional leve e intenso.



Fonte: Autoria própria.

A seguir, a Figura 56 apresenta os resultados do método de Wiener. Para o caso leve, o método apresentou bom desempenho, com nitidez recuperada e ausência de artefatos significativos. No cenário intenso, o desempenho é inferior, sendo possível distinguir estruturas relevantes da imagem, mas com a introdução de múltiplos artefatos ao redor dos círculos escuros (halos).

Figura 56 – Resultados do método de Wiener para desfoque direcional leve e intenso.



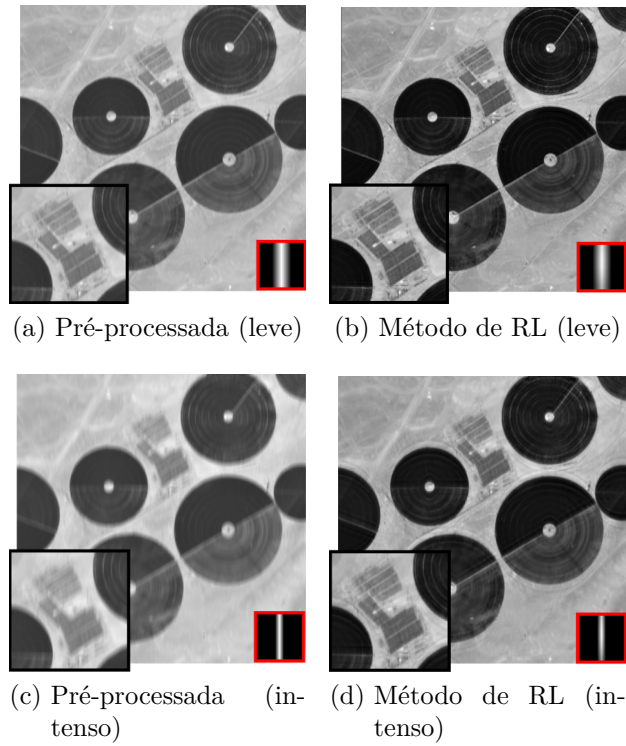
Fonte: Autoria própria.

A Figura 57 mostra os resultados do método de Richardson-Lucy. No cenário leve, a imagem restaurada, proveniente da 50ª iteração, apresenta considerável recuperação de detalhes e nitidez. Já com desfoque intenso, o resultado da 32ª iteração apresentou superamplificação de ruído e criação de artefatos tão significativos quanto aqueles observados no método anterior, mas ainda produz uma imagem com definição muito melhor do que a pré-processada.

Os resultados do método RL com regularização por TV, vide Figura 58, também mostraram boa qualidade. Em ambos os casos, borramento direcional leve e intenso, praticamente não há diferença visual em relação ao RL puro, dado que o peso da regularização foi baixo. As métricas desses métodos são muito parecidas, especialmente para o primeiro ensaio.

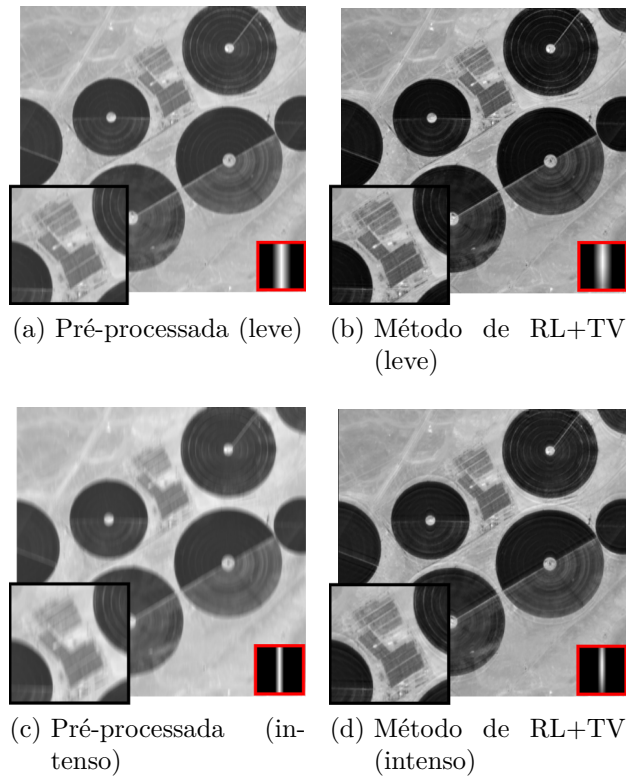
O método DIP, cujo resultado é exposto pela Figura 59, produziu resultados visuais interessantes em ambos os casos. No cenário leve, houve boa recuperação de bordas, com ausência de artefatos. Resultante da iteração 1813, a imagem estimada para o cenário leve mostrou boa recuperação de contraste e nitidez, o que acrescenta à percepção de competência da rede neural. No cenário intenso, por sua vez, a recuperação foi inferior aos métodos anteriores no que diz respeito à nitidez local. Contudo, ele foi o único a não introduzir artefatos na imagem estimada.

Figura 57 – Resultados do método de Richardson-Lucy para desfoque direcional leve e intenso.




Fonte: Autoria própria.

Figura 58 – Resultados do método de RL+TV para desfoque direcional leve e intenso.



Fonte: Autoria própria.

Figura 59 – Resultados do método DIP para desfoque direcional leve e intenso.



Fonte: Autoria própria.

A Tabela 4 resume as métricas extraídas das imagens restauradas para os casos de desfoque direcional leve e intenso, permitindo a comparação entre os métodos aplicados. No cenário leve, os métodos iterativos Richardson-Lucy (RL) e RL+TV destacaram-se com os melhores valores de PSNR (40,15 dB) e os menores NRMSE (0,0176), mantendo um SSIM elevado (0,9750 e 0,9751, respectivamente). O método de Wiener também apresentou desempenho notável. O DIP, embora mais estável em termos visuais, obteve métricas mais modestas, com destaque para um SSIM de 0,8838 e um FWHM muito próximo dos demais métodos (1,4184), sugerindo boa recuperação das bordas.

No cenário de desfoque intenso, todos os métodos apresentaram degradação de desempenho, como esperado. O RL e o RL+TV obtiveram valores similares (SSIM de 0,8981 e 0,9016, respectivamente), mas com leve piora nas métricas numéricas. O DIP apresentou piores resultados quantitativos nesse cenário, com PSNR de 25,10 dB e NRMSE mais elevado (0,0994), embora tenha mantido FWHM compatível com os demais (1,4205) e não tenha introduzido artefatos na imagem deconvoluída. Isso sugere que o DIP não conseguiu recuperar os detalhes mais finos da imagem sob esse tipo de degradação, reforçando a hipótese de que redes neurais do tipo DIP enfrentam mais dificuldade em restaurar estruturas altamente direcionais sem *overfitting*.

Tabela 4 – Comparativo geral das métricas para desfoque direcional leve e intenso.

| Desfoque direcional leve | | | | | | |
|-----------------------------|------|-------|--------|--------|-------------------|--------|
| Método | It. | PSNR | SSIM | NRMSE | Var $_{\nabla^2}$ | FWHM |
| Filtro Inverso | – | – | – | – | – | – |
| Wiener (k = 0.009) | – | 34.68 | 0.9775 | 0.0330 | 218.663 | 1.4190 |
| RL | 50 | 40.15 | 0.9750 | 0.0176 | 259.089 | 1.4178 |
| RL + TV (p = 0.01) | 50 | 40.15 | 0.9751 | 0.0176 | 259.027 | 1.4178 |
| DIP | 1813 | 29.70 | 0.8838 | 0.0586 | 139.398 | 1.4184 |
| Desfoque direcional intenso | | | | | | |
| Método | It. | PSNR | SSIM | NRMSE | Var $_{\nabla^2}$ | FWHM |
| Filtro Inverso | – | – | – | – | – | – |
| Wiener (k = 0.0001) | – | 34.12 | 0.9139 | 0.0352 | 110.196 | 1.4203 |
| RL | 32 | 33.31 | 0.8981 | 0.0387 | 88.944 | 1.4211 |
| RL + TV (p = 0.01) | 51 | 33.58 | 0.9016 | 0.0375 | 115.159 | 1.4221 |
| DIP | 1729 | 25.10 | 0.8498 | 0.0994 | 185.515 | 1.4205 |

Fonte: Autoria própria.

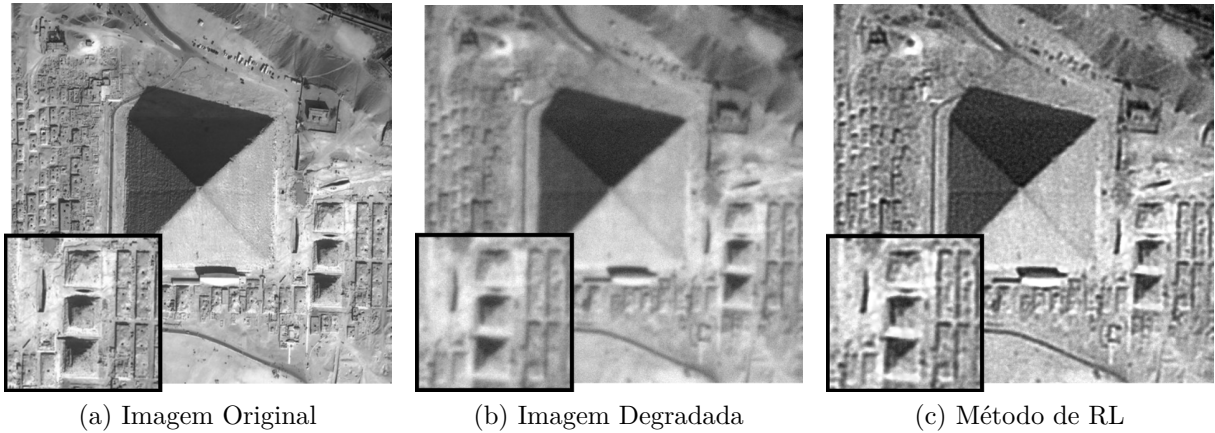
10.3 Deconvolução com PSF desconhecida (caso cego e semi-cego)

Nesta última análise acerca dos algoritmos de deconvolução, são avaliadas as capacidades dos métodos iterativos de deconvolução em cenários nos quais a PSF original é desconhecida. Para isso, os métodos de Richardson-Lucy e *Deep Image Prior* foram testados em configurações com chutes iniciais aleatórios, e uma estratégia adicional combinando ambos os métodos foi avaliada. Tal abordagem visa simular contextos mais realistas, em que o modelo de degradação não é completamente conhecido (semi-cego) ou completamente desconhecido (cego).

Na Figura 60, observa-se o desempenho do método RL em sua 42^a iteração, partindo de uma estimativa inicial da PSF qualquer (nesse caso, utilizou-se uma PSF com desvio padrão de 2,5). Nota-se que a imagem restaurada apresenta ganho de nitidez e recuperação parcial de contornos, mas exibe artefatos perceptíveis que alteram a textura da imagem restaurada. Esses efeitos são típicos do algoritmo, sobretudo após muitas iterações.

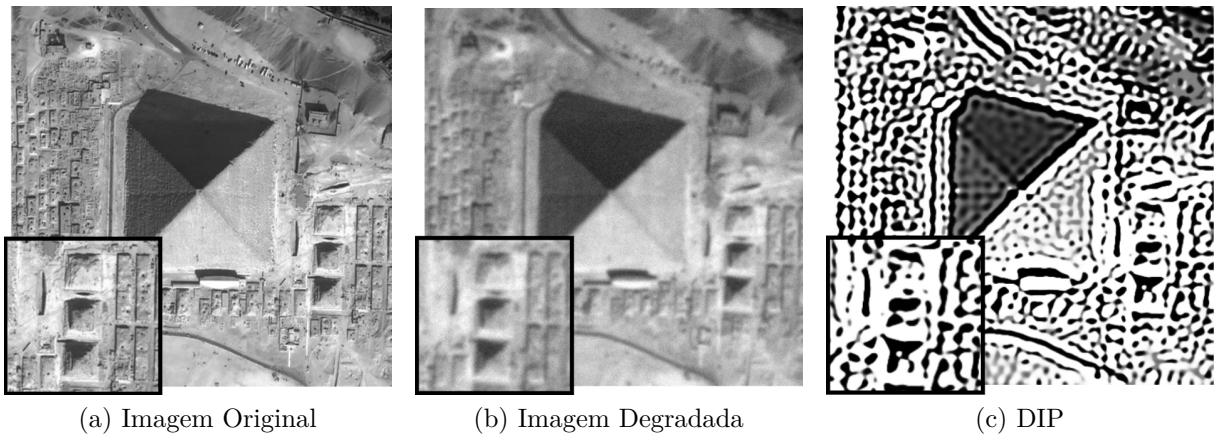
O comportamento do método DIP partindo de uma PSF aleatória é mostrado na Figura 61. Ainda que o método produza imagens visualmente consistentes em outros contextos, nesse cenário o resultado obtido é bastante limitado. A falta de informação confiável sobre o modelo de degradação impede a convergência adequada da rede, mesmo após 2000 iterações. Como evidenciado pela imagem, apenas uma estrutura geral muito básica foi estimada.

Figura 60 – Imagem original, imagem degradada e resultado da deconvolução com RL partindo de PSF aleatória.



Fonte: Autoria própria.

Figura 61 – Imagem original, imagem degradada e resultado da deconvolução com DIP partindo de PSF aleatória.

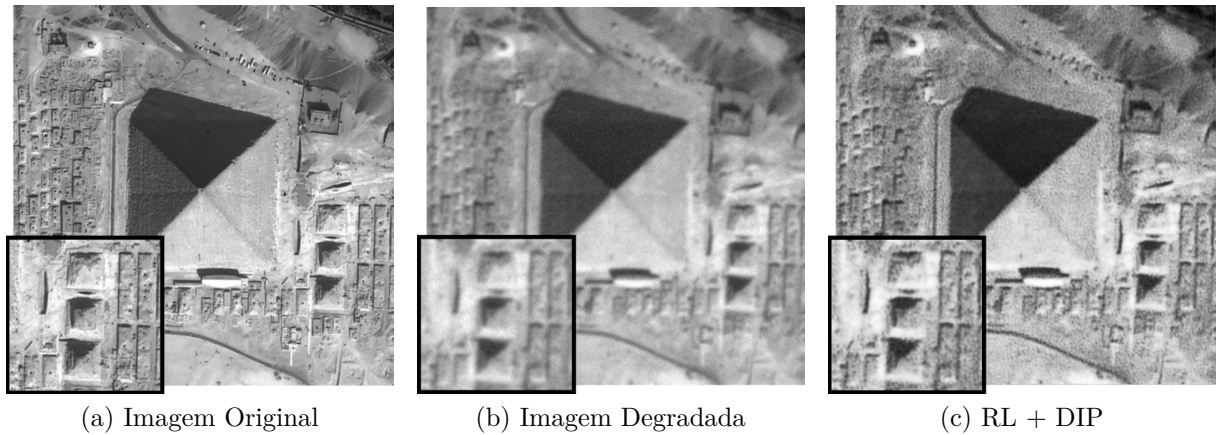


Fonte: Autoria própria.

Como alternativa, avaliou-se uma abordagem combinada, na qual a PSF estimada após algumas iterações do RL é usada como chute inicial para o DIP. Essa estratégia é ilustrada na Figura 62. O resultado apresenta maior definição estrutural, com recuperação visível de contornos e menos artefatos. A melhoria significativa, comparada ao DIP com PSF aleatória, evidencia que a qualidade do chute inicial da PSF tem impacto direto na convergência e eficácia da rede, como já mencionado em outras Seções.


A Figura 63 compara os resultados dos três cenários testados. Nota-se que a solução obtida pelo RL clássico (a) e DIP baseado na estimativa de PSF de RL (c) são mais satisfatórias do que o DIP com PSF aleatória em todos os aspectos visuais e métricos. Este comparativo reforça a importância de fornecer ao DIP uma estimativa inicial mais próxima da PSF real. Entre as melhores imagens, Figuras 63a e 63c, a segunda é qualitativamente mais adequada que a primeira, especialmente quanto a presença menor de ruídos amplificados.

Figura 62 – Imagem original, imagem degradada e resultado do DIP (1672 iterações) com PSF estimada via RL.



Fonte: Autoria própria.

Figura 63 – Comparativo visual entre os resultados dos três métodos com PSF desconhecida.




Fonte: Autoria própria.

Além dos resultados visuais, foram comparadas as PSFs envolvidas no processo, conforme ilustra a Figura 64. São apresentados, respectivamente: (a) a PSF real, (b) o chute inicial aleatório utilizado para o RL e para o DIP, (c) a PSF estimada após as iterações do RL, e (d) a PSF média ($\sigma = 1,8$) resultante da estimativa de RL usada como entrada no DIP combinado. Observa-se que a PSF gerada pelo RL se aproxima estruturalmente da real, servindo como um melhor guia para o DIP.

Os valores de métricas quantitativas para os três métodos são apresentados na Tabela 5. O método RL obteve resultado razoável com PSNR de 22,29 dB e SSIM de 0,5265, mas introduziu artefatos. O DIP com PSF aleatória foi claramente ineficaz. Já o DIP combinado com RL obteve o melhor resultado, com SSIM de 0,5830 e NRMSE de 0.1088, indicando sucesso da abordagem híbrida na reconstrução da imagem com PSF inicialmente desconhecida.

Figura 64 – Comparativo entre PSFs: real, chute inicial, PSF estimada pelo RL, e PSF usada no DIP.



Fonte: Autoria própria.

Tabela 5 – Comparativo geral das métricas para métodos com PSF desconhecida.

| Método | It. | PSNR | SSIM | NRMSE | Var_{∇^2} | FWHM |
|---------------------|------|-------|--------|--------|-------------------------|--------|
| RL | 42 | 22.29 | 0.5265 | 0.1231 | 1799.327 | 1.9734 |
| DIP (PSF aleatória) | 2000 | 9.83 | 0.1798 | 0.5168 | 3038.214 | – |
| RL + DIP | 1672 | 23.37 | 0.5830 | 0.1088 | 296.073 | 2.4074 |

Fonte: Autoria própria.

10.4 Limites dos métodos de deconvolução

Os experimentos realizados evidenciam que cada método de deconvolução testado apresenta vantagens e limitações distintas, fortemente condicionadas pela intensidade do desfoque, presença de ruído e conhecimento prévio da PSF. Métodos não iterativos, como o Filtro Inverso e o de Wiener, mostraram-se bastante sensíveis à presença de ruído, com desempenho satisfatório apenas em cenários com PSF conhecida. Em especial, no caso do Filtro Inverso, o principal limitador é a instabilidade numérica e a capacidade inexistente de lidar com contaminações de ruído aditivo.

Por outro lado, métodos iterativos como Richardson-Lucy e sua variante com regularização por *Total Variation*, demonstraram maior robustez e versatilidade frente a diferentes níveis de desfoque e ruído. A principal limitação do RL é sua sensibilidade ao número de iterações. Poucas iterações resultam em sub-recuperação da imagem, enquanto muitas iterações introduzem artefatos, como halos e intensificação de ruído. O uso de regularização com TV ameniza esse efeito, oferecendo controle adicional sobre o alisamento das bordas e amplificação de ruídos.

O método DIP destaca-se por sua capacidade de recuperar estruturas regulares mesmo em cenários com PSF parcialmente conhecida ou ruidosa, sem reproduzir o ruído na imagem estimada. Entretanto, sua principal limitação reside no custo computacional elevado, exigindo milhares de iterações para convergência. Além disso, a qualidade da

reconstrução depende fortemente do viés indutivo da rede e da estimativa inicial da PSF, sendo especialmente vulnerável em cenários cegos. Além disso, por vezes o resultado do DIP foi igual ou inferior ao de RL em suas suas variações, que são mais rápidas e menos computacionalmente complexas.

A abordagem híbrida RL seguido de DIP revelou-se promissora ao combinar o poder otimizador do RL, para uma estimativa inicial razoável da PSF, com a capacidade de regularização implícita do DIP. Isso permitiu reconstruções superiores em cenários de deconvolução cega, superando o uso isolado de cada técnica. No entanto, a eficácia dessa associação depende criticamente do número de iterações do RL e da qualidade da PSF convergida pelo algoritmo.

10.5 Ferramenta de processamento integrada

O ambiente computacional desenvolvido e descrito no capítulo anterior provou ser fundamental para a realização das análises apresentadas neste trabalho. Sua implementação cuidadosa permitiu não apenas a execução dos algoritmos de deconvolução, mas também o monitoramento sistemático do desempenho de cada método ao longo das iterações. A estrutura modular e parametrizável da aplicação foi crucial para garantir reprodutibilidade e flexibilidade nas simulações.

Todas as etapas descritas neste capítulo, desde o pré-processamento das imagens, a execução dos métodos iterativos e não iterativos, a escolha automática das melhores iterações com base em critérios métricos, até a exportação das imagens, foram viabilizadas diretamente pelas funcionalidades da aplicação. A organização do fluxo de processamento em uma interface unificada permitiu a condução de experimentos com controle sobre variáveis como PSF inicial, taxa de aprendizado, número de iterações, ruído aditivo, entre outras.

Destaca-se também a integração automática dos resultados em formatos gráficos e tabulares, o que acelerou significativamente o processo de análise comparativa. A ferramenta possibilitou ainda a visualização flexível e múltipla de todas as etapas do fluxo de processamento, o que contribuiu para a inspeção qualitativa detalhada. O cálculo iterativo de métricas como PSNR, SSIM, NRMSE, variância do gradiente e FWHM, em paralelo à execução dos métodos, forneceu subsídios complementares à avaliação visual.

A estrutura de código permite ampliações futuras com relativa facilidade, seja para incluir novos métodos de deconvolução (tradicionais ou baseados em aprendizado profundo), seja para integrar novos modos de análise, como avaliação perceptual ou comparação entre PSFs estimadas. Assim, pode-se afirmar que a ferramenta desenvolvida não foi apenas um suporte operacional, mas constituiu um elemento central na condução do presente trabalho, contribuindo decisivamente para as análises obtidas. Sua construção reflete

uma abordagem sistemática e bem estruturada do problema de restauração de imagens degradadas, servindo como base sólida para estudos futuros.

11 Conclusões

Este trabalho apresentou o desenvolvimento e avaliação de uma ferramenta computacional para análise e comparação de métodos de deconvolução aplicados à restauração de imagens de sensoriamento remoto. A partir de uma abordagem modular e extensível, foi possível implementar, aplicar e validar algoritmos clássicos, como o Filtro Inverso, método de Wiener, método de Richardson-Lucy com e sem regularização por *Total Variation*), e algoritmos modernos, como o *Deep Image Prior*, em cenários com diferentes níveis de complexidade.

A investigação experimental contemplou casos com PSF conhecida e PSF desconhecida, sob degradações isotrópicas leves e intensas, desfoques direcionais e situações com presença de ruído aditivo. A estrutura sistemática da análise permitiu estudar as capacidades e limitações de cada método, avaliando visualmente os resultados e quantitativamente por meio de métricas específicas.

Os resultados indicaram que os métodos iterativos, sobretudo o Richardson-Lucy com regularização, são mais robustos em cenários com PSF desconhecida, apresentando boa fidelidade estrutural e estabilidade frente a ruído moderado. Já o método DIP mostrou-se particularmente promissor para restauração de detalhes sem amplificação excessiva de ruído, ainda que com custo computacional significativamente maior.

Ademais, evidenciou-se que os métodos de deconvolução cega são altamente sensíveis à qualidade do chute inicial para a PSF. Quando um estimador inicial mais informado foi utilizado, como a PSF estimada por algumas iterações do método de Richardson-Lucy, o desempenho subsequente do DIP melhorou consideravelmente, tanto visual quanto em metricamente. Isso reforça a viabilidade de uma abordagem híbrida, na qual métodos iterativos contribuem com uma estimativa inicial para métodos baseados em otimização profunda.

A ferramenta desenvolvida revelou-se essencial para a realização sistemática de testes e comparações. Seu design permitiu rápida reconfiguração de parâmetros, organização eficiente dos resultados e visualização simultânea de todas as fases do processamento. A exportação automática de métricas e imagens contribuiu para a análise detalhada das diferenças entre métodos e suas configurações, além de facilitar e viabilizar a documentação de todos os ensaios desse trabalho.

Além das contribuições técnicas e científicas obtidas ao longo do desenvolvimento dessa obra, destaca-se também o relevante aprofundamento conceitual e prático proporcionado. A imersão em tópicos como processamento digital de imagens, modelagem de sistemas de aquisição de dados e fundamentos de imageamento remoto permitiu uma compreensão mais ampla e integrada das etapas que compõem a cadeia de formação e restauração

de imagens orbitais. Conceitos como PSF, métricas de nitidez e sistemas de aquisição, anteriormente abstratos, tornaram-se concretos ao serem aplicados em situações reais de simulação e análise. Do ponto de vista prático, o projeto representou uma oportunidade significativa de aprimoramento em programação científica. A construção de uma ferramenta interativa e modular, com grande foco na manipulação eficiente de dados, ampliou a maturidade técnica para enfrentar desafios futuros no campo da engenharia e da pesquisa aplicada.

Em suma, esta pesquisa contribuiu com uma análise abrangente sobre as capacidades de métodos clássicos e modernos de deconvolução, fornecendo uma base sólida para estudos futuros e aplicações práticas em processamento de imagem. A flexibilidade e eficiência da ferramenta proposta possibilitam sua expansão para outros domínios da restauração e realce de imagens.

11.1 Trabalhos futuros

A partir das contribuições consolidadas neste trabalho, diversas oportunidades de aprimoramento e extensão podem ser exploradas:

- **Super-resolução:** incorporar e avaliar algoritmos que operem além da restauração espacial, aumentando a resolução das imagens por meio de métodos de aprendizagem profunda ou técnicas clássicas aprimoradas.
- **Implementação embarcada:** adaptar e portar a ferramenta para plataformas embarcadas, como Raspberry Pi ou Jetson Nano, visando aplicações em tempo real para sistemas autônomos ou sensores espaciais.
- **Extração de patches em qualquer orientação:** ampliar a funcionalidade de seleção de regiões de interesse para permitir o alinhamento automático de patches segundo qualquer angulação, especialmente útil em imagens com bordas inclinadas ou estruturas oblíquas, a fim de aprimorar a estimativa do FWHM.
- **Paralelização dos métodos iterativos:** explorar a implementação *multithread* dos métodos iterativos, em especial o Richardson-Lucy e o DIP, com o objetivo de reduzir o tempo de execução sem comprometer a reprodutibilidade dos resultados.
- **Avaliação de novas métricas:** incorporar métricas perceptuais e baseadas em aprendizado, como LPIPS ou FSIM, para complementar a avaliação da qualidade das imagens restauradas sob diferentes cenários de degradação.

Essas direções representam caminhos promissores para ampliar o impacto e aplicabilidade do estudo proposto, tornando tanto as análises quanto a ferramenta IDIA mais robustas frente aos desafios contemporâneos do processamento de imagens digitais.

Referências Bibliográficas

- BARALDI, M. et al. A mtf-based distance for the assessment of geometrical quality of fused products. *IEEE Transactions on Geoscience and Remote Sensing*, v. 42, n. 7, p. 1445–1454, 2004.
- BECK, A.; TEOULLE, M. Fast gradient-based algorithms for constrained total variation image denoising and deblurring problems. *IEEE Transactions on Image Processing*, v. 18, n. 11, p. 2419–2434, 2009.
- BURTON, D. R.; LALOR, M. J. Modulation transfer function measurement of satellite imagery using practical psf estimation. *PeerJ*, v. 3, p. e722, 2015. Disponível em: <<https://peerj.com/articles/722/>>.
- CEOS. *CBERS-4 Satellite Mission Summary*. 2023. Accessed: 2025-06-02. Disponível em: <<https://database.eohandbook.com/database/missionssummary.aspx?missionID=393>>.
- CHAMBOLLE, A. An algorithm for total variation minimization and applications. *Journal of Mathematical Imaging and Vision*, Springer, v. 20, n. 1-2, p. 89–97, 2004.
- CHO, J. W. S.; LEE, S. *Motion Deblurring: From Algorithms to Applications*. 2015. <https://openaccess.thecvf.com/content_iccv_2015/papers/Cho_Motion_Deblurring_From_ICCV_2015_paper.pdf>.
- COPERNICUS DATA SPACE ECOSYSTEM. *Sentinel-2 | Copernicus Data Space Ecosystem*. 2023. Accessed: 2025-06-02. Disponível em: <<https://dataspace.copernicus.eu/explore-data/data-collections/sentinel-data/sentinel-2>>.
- DEY, N. et al. Richardson-lucy algorithm with total variation regularization for 3d confocal microscope deconvolution. *Microscopy Research and Technique*, v. 69, n. 4, p. 260–266, 2006.
- FISH, D. A.; BRINICOMBE, A. M.; PIKE, E. R. Blind deconvolution by means of the richardson–lucy algorithm. *Journal of the Optical Society of America A*, v. 12, n. 1, p. 58–65, 1995.
- GONG, D. et al. Blind image deconvolution by automatic gradient activation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2016. p. 1827–1836.
- GONZALES, R. C.; WINTZ, P. *Digital image processing*. [S.l.]: Addison-Wesley Longman Publishing Co., Inc., 1987.
- HAJLAOUI, N. et al. Satellite image restoration in the context of a spatially varying point spread function. *JOSA A*, Optica Publishing Group, v. 27, n. 6, p. 1473–1481, 2010.
- HAJLAOUI, S.; KRICHEN, L.; BOUHLEL, M. S. Bayesian-based iterative method of image restoration. *International Journal of Computer Applications*, v. 1, n. 10, p. 1–5, 2010.

- HECKEL, R.; HAND, P. Deep image prior: denoising, inpainting, and deblurring with a convolutional network as a prior. *IEEE Transactions on Computational Imaging*, v. 6, p. 575–589, 2020.
- HORE, A.; ZIOU, D. Image quality metrics: Psnr vs. ssim. *20th International Conference on Pattern Recognition (ICPR)*, p. 2366–2369, 2010.
- HUANG, Z.; AL. et. Edge-based modulation transfer function measurement method using a variable oversampling ratio. *Optics and Lasers in Engineering*, v. 153, p. 106976, 2022.
- INPE. *About the satellite - INPE / Amazon Mission*. 2021. Accessed: 2025-06-02. Disponível em: <https://www.inpe.br/amazonia1/en/about_satellite/>.
- JANESICK, J. R. *Scientific Charge-Coupled Devices*. Bellingham, WA: SPIE Press, 2001. TT83. (SPIE Tutorial Texts in Optical Engineering, TT83).
- JANSSON, P. A. *Deconvolution of images and spectra*. [S.l.]: Courier Corporation, 2012.
- KAUFMAN, Y. J. Atmospheric effects on remote sensing of surface reflectance. In: *SPIE Proceedings, Vol. 475, Remote Sensing*. Bellingham, WA: Society of Photo-Optical Instrumentation Engineers (SPIE), 1984. p. 20–33.
- KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- LEMPITSKY, V.; VEDALDI, A.; ULYANOV, D. Deep image prior. In: *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2018. p. 9446–9454.
- LIANG, J.; ZENG, S. Image restoration based on point spread function estimation. In: SEN, R. (Ed.). *Image Restoration – Recent Advances and Applications*. InTech, 2012. cap. 3, p. 37–56. Disponível em: <<https://www.intechopen.com/chapters/26714>>.
- MAXAR TECHNOLOGIES. *WorldView-3*. 2023. Accessed: 2025-06-02. Disponível em: <<https://resources.maxar.com/data-sheets/worldview-3>>.
- PECH-PACHECO, J. L. et al. Diatom autofocusing in brightfield microscopy: A comparative study. *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000*, v. 3, p. 314–317, 2000.
- PENALOZA, P. T.; KOAY, C. G.; SONG, A. W. On the deconvolution of satellite imagery. *PeerJ*, v. 3, p. e722, 2015.
- PixeDFit. *List of Kernels and PSFs*. 2023. Accessed: 2025-06-04. Disponível em: <https://pixedfit.readthedocs.io/en/latest/list_kernels_psf.html>.
- RUCCI, M. A. et al. Atmospheric optical turbulence mitigation using iterative image registration and least squares lucky look fusion. *Appl. Opt.*, Optica Publishing Group, v. 61, n. 28, p. 8233–8247, Oct 2022. Disponível em: <<https://opg.optica.org/ao/abstract.cfm?URI=ao-61-28-8233>>.
- SHAN, Q.; JIA, J.; AGARWALA, A. High-quality motion deblurring from a single image. In: *ACM Transactions on Graphics (TOG)*. [S.l.: s.n.], 2008. v. 27, n. 3, p. 1–10.

SOUZA, M. I. S. et al. Hybrid semi-blind deconvolution based on richardson-lucy algorithm. *Instituto de Engenharia Nuclear: Progress Report*, n. 4, 2021.

TAN, K.-C.; LIM, H.; TAN, B. Restoration of real-world motion-blurred images. *CVGIP: Graphical Models and Image Processing*, v. 53, n. 3, p. 291–299, 1991. ISSN 1049-9652. Disponível em: <<https://www.sciencedirect.com/science/article/pii/104996529190051K>>.

TEMERINAC-OTT, M. et al. Spatially-variant lucy-richardson deconvolution for multiview fusion of microscopical 3d images. *IEEE International Symposium on Biomedical Imaging (ISBI)*, p. 899–902, 2011.

UMADEVI, N.; SUDHAMATHI, R. An efficient method for image restoration from motion blur and additive white gaussian denoising using richardson lucy deconvolution and fuzzy de-noising. *International Journal of Computer Science and Network Security (IJCSNS)*, v. 14, n. 12, p. 45–50, December 2014. Disponível em: <http://paper.ijcsns.org/07_book/201412/20141209.pdf>.

USGS. *Landsat 8 | U.S. Geological Survey*. 2021. Accessed: 2025-06-02. Disponível em: <<https://www.usgs.gov/landsat-missions/landsat-8>>.

VIALLEFONT-ROBINET, F. et al. Comparison of mtf measurements using edge method: towards reference data set. *Optics Express*, Optical Society of America, v. 26, n. 26, p. 33625–33648, dez. 2018. Open Access under the OSA Publishing Agreement. Disponível em: <<https://doi.org/10.1364/OE.26.033625>>.

WANG, Z. et al. Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, v. 13, n. 4, p. 600–612, 2004.

WYANT, J. C.; CREATH, K. Basic wavefront aberration theory for optical metrology. *Applied optics and optical engineering*, Academic New York, v. 11, n. part 2, p. 28–39, 1992.

ZHANG, Y.; WU, J. Multi-resolution short-time fourier transform image enhancement based on visual characteristics of human eyes. *International Journal of Computer Science Issues (IJCSI)*, IJCSI, v. 8, n. 1, p. 87–94, 2011.