




UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"

Câmpus de Presidente Prudente

Programa de Pós-Graduação em Ciências Cartográficas

CAIO FLÁVIO MARTINEZ FONTOURA JÚNIOR



AVALIAÇÃO DE MÉTRICAS DE *INPAINTING* DIGITAL
PARA AFERIÇÃO DA QUALIDADE NA EXTRAÇÃO DE
FEIÇÕES EM IMAGENS DE SENSORIAMENTO REMOTO

PRESIDENTE PRUDENTE
2024



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Presidente Prudente

Programa de Pós-Graduação em Ciências Cartográficas

CAIO FLÁVIO MARTINEZ FONTOURA JÚNIOR

**AVALIAÇÃO DE MÉTRICAS DE *INPAINTING* DIGITAL
PARA AFERIÇÃO DA QUALIDADE NA EXTRAÇÃO DE
FEIÇÕES EM IMAGENS DE SENSORIAMENTO REMOTO**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Faculdade de Ciências e Tecnologia — Universidade Estadual Paulista (UNESP), como parte dos requisitos para a obtenção do título de Doutor em Ciências Cartográficas. Área de concentração em aquisição, análise e representação de informações espaciais.

Orientador: Prof. Dr. Erivaldo Antonio da Silva

Coorientador: Prof. Dr. Wallace Correa De Oliveira Casaca

PRESIDENTE PRUDENTE
2024

F684a	Fontoura Júnior, Caio Flávio Martinez Avaliação de Métricas de Inpainting Digital para Aferição da Qualidade na Extração de Felções em Imagens de Sensoriamento Remoto / Caio Flávio Martinez Fontoura Júnior. -- Presidente Prudente, 2024 124 p. Tese (doutorado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Tecnologia, Presidente Prudente Orientador: Erivaldo Antonio da Silva Coorientador: Wallace Correa De Oliveira Casaca 1. Inpainting. 2. Métricas de Qualidade. 3. Sensoriamento Remoto. 4. Coeficiente de Correlação. 5. Processamento Digital de Imagens. I. Título.
-------	--

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Tecnologia, Presidente Prudente. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: AVALIAÇÃO DE MÉTRICAS DE INPAINTING DIGITAL PARA AFERIÇÃO DA QUALIDADE NA EXTRAÇÃO DE FEIÇÕES EM IMAGENS DE SENSORIAMENTO REMOTO

AUTOR: CAIO FLÁVIO MARTINEZ FONTOURA JÚNIOR

ORIENTADOR: ERIVALDO ANTONIO DA SILVA

COORIENTADOR: WALLACE CORREA DE OLIVEIRA CASACA

Aprovado como parte das exigências para obtenção do Título de Doutor em Ciências Cartográficas, área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:

 **WALLACE CORREA DE OLIVEIRA CASACA**
Data: 04/06/2024 07:43:31-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. WALLACE CORREA DE OLIVEIRA CASACA (Participação Virtual)
IBILCE / UNESP São José do Rio Preto SP

Profa. Dra. JUSSARA DE OLIVEIRA ORTIZ (Participação Virtual)
Divisão de Observação da Terra e Geoinformática – DIOTG / Instituto Nacional de Pesquisas Espaciais

Prof. Assoc. ROGÉRIO GALANTE NEGRI (Participação Virtual)
Departamento de Engenharia Ambiental / Instituto de Ciência e Tecnologia do Campus de São José dos Campos/UNESP

Prof. Dr. MESSIAS MENEGUETTE JUNIOR (Participação Virtual)
Departamento de Matemática e Computação / Faculdade de Ciências e Tecnologia de Presidente Prudente - FCT/Unesp

Prof. Dr. JOSÉ ROBERTO NOGUEIRA (Participação Virtual)
Departamento de Matemática e Computação / Faculdade de Ciências e Tecnologia de Presidente Prudente

Presidente Prudente, 03 de junho de 2024

DEDICATÓRIA

*Dedico este trabalho primeiramente a Deus,
que me deu capacidade e sabedoria para
realizá-lo, a todos os que sempre me
ampararam, apoiaram, incentivaram e
compreenderam, em especial aos meus pais,
Caio Flávio e Ana Maria Fontoura, minha
noiva, Lariane pela paciência e aos amigos que
contribuíram direta ou indiretamente.*

AGRADECIMENTOS

Expresso, em primeiro lugar, minha gratidão a Deus, que permite que todas as coisas se concretizem. Foi pela Sua vontade que consegui chegar até o final desta etapa, utilizando a sabedoria e o discernimento que Ele me concedeu. Agradeço também a Nossa Senhora, que sempre esteve presente comigo, intercedendo, guiando-me e livrando-me de todo o mal.

Expresso minha gratidão à minha família, especialmente à minha mãe, Ana Maria das Neves Valva Fontoura, pelo esforço e apoio dados para que fosse possível chegar até aqui. Ao meu pai, Caio Flávio Martinez Fontoura, que sempre esteve disponível para me ajudar no que fosse preciso. Agradeço também à minha noiva, que está caminhando para fazer definitivamente parte da família, pela compreensão, paciência, zelo e carinho que teve por mim nestes últimos nove anos e oito meses.

Aos Professores Doutores Wallace Correa De Oliveira Casaca e Erivaldo Antonio da Silva, expresso minha gratidão pela excelente orientação, compreensão, paciência e dedicação, que foram fundamentais para finalizar esta etapa.

Aos professores que compuseram a banca examinadora, os professores Doutora Jussara de Oliveira Ortiz, Doutor Rogério Galante Negri, Doutor Messias Meneguette Junior e Doutor José Roberto Nogueira, bem como Caroline de Oliveira Costa Souza Rosa, Douglas Almeida da Silva, Samara Azevedo, Fernando Baixo e Eduardo Nascimento, agradeço o tempo dedicado, valiosas colaborações e sugestões.

Expresso minha gratidão ao Programa de Pós-graduação em Ciências Cartográficas (PPGCC) e à Universidade Estadual Paulista (Unesp) pela infraestrutura e pelas oportunidades oferecidas. Aos professores do Departamento de Cartografia, bem como aos técnicos, em especial, Cinthia Onishi e Cátia Stocker, agradeço a ajuda para que esta etapa fosse concretizada. Aos colegas de pós-graduação, em especial Weverton da Costa, Mariana Thomaz, Letícia Ferrari e Gabriela Takahashi, agradeço pelas reflexões, críticas e sugestões recebidas.

Agradeço também aos amigos Nariane e Alisson por toda ajuda e oportunidade, assim como a todos da Catequese da Paróquia Mãe da Igreja, à família de Marlene e Vander, de Keli e Marcelo, e de Liliane, que me acolheram e ajudaram enquanto residia em Presidente Prudente.

Expresso minha gratidão pela compreensão de pessoas especiais nos momentos em que não foi possível estar presente, e quando minha preocupação e atenção pareciam se voltar exclusivamente a este trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

*“O dom da fala foi concedido aos homens
não para que eles enganassem uns aos
outros, mas sim para que expressassem*

seus pensamentos uns aos outros.”

Santo Agostinho.

RESUMO

Imagens de Sensoriamento Remoto (SR) têm sido utilizadas em várias aplicações de interesse para a sociedade. Apesar da precisão e robustez oriundas da tecnologia de imagens de SR, diversas cenas aéreas e orbitais apresentam imperfeições e não alcançam os padrões ideais de qualidade, já que algumas delas apresentam distorções, como ruído, borrão, listra e pixels comprometidos, incluindo objetos indesejáveis, nuvens e sombras. Uma abordagem alternativa para lidar com tais distorções é a técnica de *inpainting*, cuja aplicação tornou-se fundamental em diferentes finalidades relacionadas ao Processamento Digital de Imagens (PDI), incluindo imagens de SR e representações cartográficas. No entanto, em determinadas circunstâncias, esse tipo de abordagem requer aferição por métricas quantitativas, a fim de validar a qualidade final da reconstrução das imagens. Portanto, esta tese tem como objetivo a questão da avaliação quantitativa dos resultados de *inpainting* no contexto de SR, analisando e comparando novas medidas de avaliação em contraste com métricas clássicas da literatura de SR. Com base na pesquisa conduzida, foi possível medir o grau da subjetividade humana na avaliação dos resultados de modo a gerar critérios de validação mais robustos, confiáveis e passíveis de automatização de um computador. Os resultados de *inpainting* foram avaliados usando-se seis métricas quantitativas, a partir de avaliações qualitativas arbitradas por agentes humanos. Para tal, foram utilizados os coeficientes de correlação de *Spearman* e coeficiente de correlação de *Kendall*, para reforçar as análises dos resultados. As imagens foram, ainda, classificadas antes e depois da aplicação das técnicas de *inpainting*, de forma que o indicador de qualidade foi aplicado, a taxa de acurácia global, que constitui métrica clássica da literatura de classificação de imagens. Dentre as métricas analisadas neste estudo: MSE, PSNR, SSIM, FSIM, VSI e DISTS, pode-se concluir que as métricas DISTS e VSI são as candidatas mais promissoras para adaptação e aplicação dentro do contexto específico de *inpainting* em SR.

Palavra-chave: *Inpainting*; Processo de Extração de Feições; Análise Quantitativa; Métricas de Qualidade; Coeficiente de Correlação; Sensoriamento Remoto; Restauração de Imagens; Processamento Digital de Imagens.

ABSTRACT

Remote Sensing (RS) images have been used in various applications of societal interest. Despite the accuracy and robustness provided by RS image technology, many aerial and orbital scenes exhibit imperfections and do not meet ideal quality standards, as some of them present distortions such as noise, blur, striping, and compromised pixels, including unwanted objects, clouds, and shadows. An alternative approach to addressing such distortions is the Inpainting technique, whose application has become fundamental for various purposes related to Digital Image Processing (DIP), including RS images and cartographic representations. However, in certain circumstances, this type of approach requires assessment through quantitative metrics to validate the final quality of the reconstructed images. Therefore, this thesis aims to address the quantitative evaluation of inpainting results in the context of RS by analyzing and comparing new evaluation measures against classical metrics in RS literature. Based on the conducted research, it was possible to measure the degree of human subjectivity in evaluating the results to generate more robust, reliable, and computer-automatable validation criteria. The inpainting results were evaluated using six quantitative metrics, based on qualitative assessments arbitrated by human agents. For this purpose, Spearman's correlation coefficients and Kendall's correlation coefficient were used to reinforce the analysis of the results. The images were also classified before and after applying the inpainting techniques, so the quality indicator, the overall accuracy rate, which is a classical metric in image classification literature, was applied. Among the metrics analyzed in this study—MSE, PSNR, SSIM, FSIM, VSI, and DISTS—it can be concluded that the DISTS and VSI metrics are the most promising candidates for adaptation and application within the specific context of inpainting in RS.

Keywords: Inpainting; Feature Extraction Process; Quantitative Analysis; Quality Metrics; Correlation Coefficient; Remote Sensing; Image Restoration; Digital Image Processing.

Lista de Figuras

Figura 1 – Aplicações da reconstrução da técnica de inpainting e os propósitos de cada categoria.....	23
Figura 2 – Alguns tipos de degradação em imagens de SR.	24
Figura 3 – Mecanismo de preenchimento por blocos através da amostragem dinâmica.	28
Figura 4 – Pixels utilizados na discretização da equação de difusão do modelo TV.....	30
Figura 5 – Representações dos fenômenos espaciais.	33
Figura 6 – Exemplos de Estruturas Curvilíneas.	34
Figura 7 – Imagem do acervo aerofotogramétrico e cartográfico do IGC.	53
Figura 8 – Imagem do acervo da EOSDA LandViewer com resolução espacial de 3 metros da região de Presidente Prudente.	54
Figura 9 – Fluxograma sumarizado das etapas do trabalho, a fim avaliar as imagens por meio das métricas.	55
Figura 10 – (a) imagem aérea A de referência, (b) imagem com objeto artificial, (c) - (e) técnica de <i>inpainting</i> de Azevedo (2019), e (f) técnica de <i>inpainting</i> de Baixo (2022). 74	
Figura 11 – (a) imagem aérea B de referência, (b) imagem com objetos artificiais, (c) - (e) técnica de <i>inpainting</i> de Azevedo (2019), e (f) técnica de <i>inpainting</i> de Baixo (2022).	76
Figura 12 – (a) imagem aérea C de referência, (b) imagem com objeto artificial, (c) - (e) técnica de <i>inpainting</i> de Azevedo (2019), e (f) técnica de <i>inpainting</i> de Baixo (2022). 78	
Figura 13 – (a) imagem aérea D de referência, (b) imagem com objeto artificial, (c) - (e) técnica de <i>inpainting</i> de Azevedo (2019), e (f) técnica de <i>inpainting</i> de Baixo (2022). 80	
Figura 14 – (a) imagem aérea E de referência, (b) imagem com objetos artificiais, (c) - (e) técnica de <i>inpainting</i> de Azevedo (2019), e (f) técnica de <i>inpainting</i> de Baixo (2022).	82
Figura 15 – (a) imagem orbital F de referência, (b) imagem com objeto artificial, (c) - (f) técnica de <i>inpainting</i> de Azevedo (2019).	88
Figura 16 – (a) imagem orbital G de referência, (b) imagem com objeto artificial, (c) - (f) técnica de <i>inpainting</i> de Azevedo (2019).	91

Figura 17 – (a) imagem orbital H de referência, (b) imagem com objetos artificiais, (c) - (f) técnica de <i>inpainting</i> de Azevedo (2019).	94
Figura 18 – (a) imagem orbital I de referência, (b) imagem com objetos artificiais, (c) - (e) técnica de <i>inpainting</i> de Azevedo (2019).....	96
Figura 19 – Resultado da classificação não-supervisionada de imagens aéreas de SR . (a) – (e) imagens de referência (original); (f) - (j) imagens classificadas.	100
Figura 20 – Resultado da classificação não-supervisionada pelo k-médias das imagens aéreas A de SR. (a) – (d) imagens restauradas; (e) - (h) imagens classificadas.	101
Figura 21 – Resultado da classificação não-supervisionada pelo k-médias das imagens aéreas B de SR. (a) – (d) imagens restauradas; (e) - (h) imagens classificadas.	102
Figura 22 – Resultado da classificação não-supervisionada pelo k-médias das imagens aéreas C de SR . (a) – (d) imagens restauradas; (e) - (h) imagens classificadas.	104
Figura 23 – Resultado da classificação não-supervisionada pelo k-médias das imagens aéreas D de SR. (a) – (d) imagens de SR restauradas; (e) - (h) imagens classificadas.	105
Figura 24 – Resultado da classificação não-supervisionada pelo k-médias das imagens aéreas E de SR. (a) – (d) imagens de SR restauradas; (e) - (h) imagens classificadas.	106
Figura 25 – Resultado da classificação não-supervisionada de imagens orbital de SR. (a) – (d) imagens de referência; (e) - (h) imagens classificadas.....	108
Figura 26 – Resultado da classificação não-supervisionada pelo k-médias da imagem orbital F de SR. (a) – (d) imagens restauradas; (e) - (h) imagens classificadas.	109
Figura 27 – Resultado da classificação não-supervisionada pelo k-médias da imagem orbital G de SR. (a) – (d) imagens restauradas; (e) - (f) imagens classificadas.	110
Figura 28 – Resultado da classificação não-supervisionada pelo k-médias da imagem orbital H de SR 28. (a) – (d) imagens restauradas; (e) - (h) imagens classificadas.....	111
Figura 29 – Resultado da classificação não-supervisionada pelo k-médias da imagem orbital I de SR. (a) – (c) imagens restauradas; (d) - (f) imagens classificadas.....	113

Lista de Tabelas

Tabela 1 – Informações sobre a geométrica de aquisição da imagem de SR Orbital.....	52
Tabela 2 - Análise Quantitativa X Qualitativa da imagem A.....	64
Tabela 3 - Análise Quantitativa X Qualitativa da imagem B.	67
Tabela 4 - Análise Quantitativa X Qualitativa da imagem C.	68
Tabela 5 - Análise Quantitativa X Qualitativa da imagem D.....	69
Tabela 6 - Análise Quantitativa X Qualitativa da imagem E.	70
Tabela 7 - Análise média das imagens e suas respectivas métricas.	71
Tabela 8 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.	75
Tabela 9 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.	77
Tabela 10 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.	79
Tabela 11 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.	81
Tabela 12 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.	83
Tabela 13 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.	89
Tabela 14 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.	93
Tabela 15 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.	95
Tabela 16 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.	97
Tabela 17 – Acurácia da imagem A classificada pelo classificador K-médias.	102
Tabela 18 – Acurácia da imagem B classificada pelo classificador K-médias.	103
Tabela 19 – Acurácia da imagem C classificada pelo classificador K-médias.	104
Tabela 20 – Acurácia da imagem D classificada pelo classificador K-médias.	105
Tabela 21 – Acurácia da imagem E classificada pelo classificador K-médias.	107

Tabela 22 – Acurácia da imagem F classificada pelo classificador K-médias.....	109
Tabela 23 – Acurácia da imagem G classificada pelo classificador K-médias.	110
Tabela 24 – Acurácia da imagem H classificada pelo classificador K-médias.	112
Tabela 25 – Acurácia da imagem I classificada pelo classificador K-médias.....	113

Lista de Quadros

Quadro 1 – Descrição das principais métricas de avaliação de qualidade de imagem...	20
Quadro 2 – Intervalo de correlação do SRCC.	49
Quadro 3 – Descrição sobre coeficiente de <i>Kendall</i>	50
Quadro 4 – Visão geral das imagens aéreas de SR.....	61
Quadro 5 – Parâmetros relacionados a janela de alocação para a reconstrução das imagens aéreas de SR da técnica de inpainting de Azevedo (2019).	62
Quadro 6 - Análise qualitativa relacionada aos acertos das métricas quantitativas.	72
Quadro 7 – Visão geral das imagens orbitais de SR.	84
Quadro 8 – Parâmetros relacionados a janela de alocação para a reconstrução das imagens orbitais de SR da técnica de inpainting de Azevedo (2019).	85
Quadro 9 – Classificação das imagens de SR orbital do melhor e pior resultados entre os usuários.....	86

SUMÁRIO

1. INTRODUÇÃO	16
1.1 Contextualização e problemática	16
1.2 Hipótese de investigação	17
1.3 Estado da arte	18
1.4 Objetivos	21
2. FUNDAMENTAÇÃO TEÓRICA	22
2.1 Técnicas de <i>Inpainting</i>	22
2.1.1 Métodos de <i>Inpainting</i>	26
2.2 Taxonomia das técnicas de <i>inpainting</i>	31
2.3 Feições cartográficas curvilíneas	33
2.4 Métricas convencionais	35
2.4.1 Métricas aplicadas no contexto de imagens de SR	35
2.4.2 MSE (<i>Mean Square Error</i> – Erro Quadrático Médio)	37
2.4.3 PSNR (<i>Peak Signal to Noise Ratio</i> – Relação Pico Sinal-Ruído)	37
2.4.4 SSIM (<i>Structured Similarity Index Method</i> - Método de Indexação de Similaridade Estruturada)	39
2.4.5 FSIM (<i>Feature Similarity Index</i> - Índice de Similaridade de Feições)	40
2.5 Métricas aplicadas no contexto de imagens fotográficas convencionais	41
2.5.1 VSI (<i>Visual Saliency-Induced Index</i> – Índice induzido pela Saliência Visual)	42
2.5.2 DISTs (<i>Deep Image Structure and Texture Similarity</i> – Similaridade Profunda de Estrutura e Textura em imagens)	44
2.6 Medidas de Correlação	48
2.6.1 Coeficiente de correlação de classificação de <i>Spearman</i>	48

2.6.2	Coeficiente de correlação de classificação de Kendall	49
3.	METODOLOGIA	51
3.1	Materiais	51
3.2	Base de dados.....	52
3.3	Métodos	55
3.3.1	Aplicação das técnicas de <i>inpainting</i>	55
3.3.2	Aplicação das métricas quantitativas	56
3.3.3	Classificação de imagens de SR.....	57
3.3.4	Análise e validação das métricas por meio de medidores estatísticos	58
4.	RESULTADOS E DISCUSSÃO	60
4.1	Avaliação experimental	60
4.2	Análise estatística em imagens de SR.....	73
4.2.1.	Avaliação estatística entre métricas de qualidade e percepção visual em imagens aéreas de SR	73
4.2.2.	Avaliação estatística entre métricas de qualidade e percepção visual em imagens orbitais de SR	83
4.3	Análise da classificação das imagens de SR.....	98
4.3.1.	Avaliação estatística da classificação de imagens aéreas de SR.....	99
4.3.2.	Avaliação estatística da classificação de imagens orbitais de SR.....	107
5.	CONCLUSÃO	114
	REFERÊNCIAS	118

1. INTRODUÇÃO

1.1 Contextualização e problemática

Inpainting é uma técnica de restaurar imagens corrompidas por ruídos, borrões, arranhões, listras e pixels comprometidos, sendo útil, também, na remoção de objetos, nuvens, sombras, e textos em imagens digitais (QURESHI *et al.*, 2017). Empregar técnicas de *inpainting* tornou-se fundamental em diversas aplicações, como cinema digital, restauração de imagens arqueológicas e foto-edição de fotografias. Além disso, tais técnicas têm sido utilizadas em larga escala em diferentes áreas relacionadas ao Processamento Digital de Imagens (PDI), incluindo a área de Cartografia (ARIAS *et al.*, 2011; TRUNG *et al.*, 2013; QURESHI *et al.*, 2017; BASSO *et al.*, 2021).

Na literatura, as abordagens de *inpainting* mais conhecidas são a estrutural e a via propagação de blocos de informações e textura. O *inpainting* estrutural utiliza-se das informações geométricas e da interpolação de pixels para preencher as regiões danificadas na imagem, enquanto o *inpainting* via propagação de blocos preenche as regiões perdidas a partir da alocação de *patches* – blocos de informações e texturas obtidas nas vizinhanças das regiões danificadas (LI *et al.*, 2019).

Na área da Cartografia, o processo de extração de feições tem sido crucial em aplicações diversas. Esse processo visa à identificação de alvos presentes na superfície terrestre, por exemplo, rodovias, hidrovias, pistas de aeroportos, bem como para atualização de produtos cartográficos. Devido às alterações antrópicas e naturais da superfície terrestre, sua identificação é de suma importância a identificação para a cartografia no Brasil, em função de sua dimensão continental.

Dentre as técnicas de PDI mais empregadas no contexto da Cartografia, há métodos de extração de feições que, em diferentes circunstâncias, podem detectar feições parciais ou com informações corrompidas, impactando, assim, na qualidade e na aferição dos resultados (FIGUEIRA *et al.*, 2018). Dessa forma, as técnicas de *inpainting* visam aumentar a qualidade visual da imagem, criando estruturas mais detalhadas que, em razão das falhas ou da ausência de informação das feições, não eram visualizadas antes da etapa de *inpainting*. Porém, em geral, esse tipo de restauração necessita ser avaliado por métricas quantitativas, de forma a aferir a qualidade final da reconstrução (AZEVEDO, 2019; BASSO *et al.*, 2021). Qureshi *et al.* (2017) afirmam que a qualidade das imagens obtidas via *inpainting* continua a ser um problema complexo e desafiador.

Apesar da realização de estudos nessa direção, poucos trabalhos têm explorado o contexto de métricas quantitativas para avaliar a qualidade do *inpainting*, sobretudo, na área de Cartografia e Sensoriamento Remoto (SR). De fato, grande parte dos trabalhos publicados envolvendo métricas de validação está estritamente relacionada à elaboração ou ao uso de técnicas de *inpainting* em imagens digitais fotográficas convencionais. Nesse sentido, é importante ressaltar que o emprego de métricas de validação para aferir quantitativamente a qualidade da reconstrução de feições curvilíneas, parcialmente detectadas via *inpainting*, tem sido um campo com poucos avanços no contexto de SR, incluindo a tarefa de restauração de feições curvilíneas.

1.2 Hipótese de investigação

A utilização de técnicas de *inpainting* tem se tornado cada vez mais frequente e, até o presente momento, pesquisadores têm desenvolvido diferentes métodos de *inpainting* conforme necessidades específicas. Entretanto, identificar quantitativamente a qualidade dessa restauração em imagens de SR torna-se uma tarefa de suma importância, já que a área contempla grandes catálogos de imagens, tornando difícil uma avaliação qualitativa minuciosa por parte de um agente humano.

A avaliação das imagens de SR de alta e média resoluções espaciais, a partir de métricas de qualidade, permite validar numericamente a qualidade da reconstrução das imagens, e conseqüentemente, estabelecer um critério quantitativo da qualidade para as reconstruções de feições cartográficas. Assim, a aplicação de métricas de qualidade de *inpainting*, como *Deep Image Structure and Texture Similarity (DISTS) Index* (Ding et al, 2022); *Visual Saliency-Induced (VSI) Index*, para o contexto de SR pode estabelecer critérios de validação mais robustos e confiáveis, eliminando, dessa forma, o fator de subjetividade humana. Além disso, estimula a automatização do processo via computadores, dando lugar a uma avaliação quantitativa mais bem estabelecida, isto é, a partir da aferição de características específicas de imagens de SR como padrões, texturas, luminância e radiância.

Técnicas de *inpainting* no contexto do Aprendizado de Máquina (AM) e *Deep Learning* (DL) para imagens de SR também serão beneficiadas pelos resultados desta pesquisa, em razão de empregarem funções de perdas (*loss function*) que, em essência, necessitam quantificar numericamente o progresso da reconstrução em *pipelines* de Redes Neurais Artificiais. Portanto, o presente trabalho também pode contribuir para o uso de

novas funções de perdas e formas de avaliar a convergência de técnicas de AM e DL, no que concerne à aplicação de *inpainting*.

1.3 Estado da arte

Shen et al. (2010) criaram um método de reconstrução universal, a fim de melhorar e aumentar o potencial de aplicação em imagens de SR. O método foi desenvolvido com base no modelo da observação de imagem e estrutura MAP (Máximo a Posteriori), aplicado para a remoção de ruídos, interpolação, e reconstrução de imagens com alta resolução espacial. Cheng et al. (2014) realizaram testes em dados simulados e reais, utilizando algoritmo próprio, e constataram que o aparato computacional proposto remove objetos e reconstrói a imagem de maneira eficaz.

Singh e Kaur (2016) utilizaram técnicas de *inpainting* em imagens capturadas por satélites com o intuito de mostrar a particularidade de cada técnica. Ao utilizar os algoritmos em imagens de SAR (*Synthetic Aperture Radar* – Radar de Abertura Sintética), foi possível remover ruídos presentes nas imagens, propiciando um melhor resultado em termos de qualidade da imagem. Já Late e Dharashive (2017) desenvolveram um algoritmo para lidar com o problema de reconstrução de imagens de SR. O referido algoritmo foi aplicado para a remoção de faixas, ruídos, e letras indesejadas em mapas e objetos. Azevedo (2019), em seu trabalho, propõe uma estratégia automática para remoção de sombras, com o uso de um algoritmo de *inpainting* próprio para imagens multiespectrais de alta resolução espacial em regiões urbanas. Ainda na linha de SR, Baixo (2022) adaptou um algoritmo de Shen e Chan (2002), com o objetivo de avaliar a restauração das feições cartográficas a partir de modelos de minimização de energia em imagens. Vale ressaltar que o modelo adaptado por Baixo (2022) permite aplicar a técnica, tanto em imagens em nível de cinza, quanto em imagens coloridas (RGB).

Todos os trabalhos supracitados conseguiriam aplicar de maneira satisfatória as técnicas de *inpainting* em imagens de SR, considerando particularidades e com propósitos específicos. No entanto, é importante notar que, nos trabalhos de Cheng et al. (2014) e Azevedo (2019), não foram aplicadas métricas quantitativas de validação do *inpainting* e nos outros trabalhos não houve um tratamento quantitativo adequado quanto à qualidade da reconstrução das imagens de SR.

Ao longo das últimas décadas, houve avanços significativos no desenvolvimento de métricas de qualidade para o *inpainting*, cada uma com suas especificidades, ao serem

aplicadas em contextos mais gerais de imagens digitais (EGIAZARIAN et al., 2018). No âmbito do SR, as principais métricas de validação utilizadas incluem: o *Mean Squared Error* (MSE), o *Peak Signal-to-Noise Ratio* (PSNR), e a *Structural Similarity Index* (SSIM) (Basso et al., 2021). Embora o PSNR e o MSE avaliem as imagens com base em seu conteúdo comum e no tipo de distorção, essas métricas não apresentam uma correlação eficiente com avaliações subjetivas (HUANG E JING, 2020; CHENG et al., 2014). Consequentemente, MSE, PSNR e SSIM podem não captar de maneira apropriada a realidade visual das imagens de SR, demandando, assim, inspeções qualitativas combinadas com avaliações quantitativas, para propor métricas que representem mais precisamente a concordância entre a qualidade visual e a avaliação numérica. Trabalhos como de Sara, Akter e Uddin (2019) e Figueira et al. (2020) aplicaram parte das métricas acima em imagens de SR.

Na literatura geral de PDI, há ainda diferentes métricas que têm sido exploradas não no âmbito do SR, mas sim no cenário mais geral de edição de fotografias digitais de forma a validar a qualidade dos resultados obtidos pelas técnicas de *inpainting* (QURESHI et al., 2017). No Quadro 1, são elencadas, além das métricas clássicas, três métricas adicionais que apresentaram resultados satisfatórios nas últimas décadas: *Deep Image Structure and Texture Similarity Index* (DISTS) (Ding et al, 2022); *Visual Saliency-Induced Index* (VSI) (Zhang, Shen e Li, 2014); e, *A Feature Similarity Index* (FSIM) (Zhang et al, 2011).

A métrica FSIM é bastante empregada tanto no contexto de imagens convencionais, quanto em imagem de SR. Por exemplo, Su et al. (2022) utilizaram a métrica FSIM para avaliar a eficiência do processamento de filmes torácicos COVID-19, por meio de um método de segmentação de imagem com limiar multinível (MTIS), baseado em um otimizador multiverso aprimorado (CCMVO). Já no contexto de SR, Jiang et al. (2021) utilizaram a métrica FSIM para avaliar a qualidade de um método único de desembaçamento de imagens de SR baseado na arquitetura codificador-decodificador, que combina transformação *Wavelet* e tecnologia de aprendizado profundo.

Quadro 1 – Descrição das principais métricas de avaliação de qualidade de imagem.

Métricas	Descrição
MSE	Calcula o erro quadrático médio entre os pixels das duas imagens.
PSNR	Calcula a Relação Pico Sinal-Ruído baseada no MSE.
SSIM (Wang, 2004)	Avalia a similaridade estrutural entre duas imagens ao considerar tanto características de baixo nível, como luminância, contraste e detalhes estruturais.
FSIM (Zhang et al., 2011)	Analisa a similaridade entre duas imagens, levando em conta tanto atributos básicos quanto complexos de sua composição visual.
VSI (Zhang, Shen e Li, 2014)	Compara as áreas de interesse nas imagens de referência e processada para determinar sua similaridade.
DISTS (Ding et al., 2022)	Aplica uma rede neural convolucional (CNN) pré-treinada, projetada especificamente para prever a semelhança perceptual entre duas imagens.

Fonte: Autor (2023).

Em relação às métricas não utilizadas no contexto do SR, destacam-se o trabalho de Chen et al. (2023), que utilizaram a métrica DISTS para avaliar um método de restauração baseado na representação esparsa para medir a qualidade das imagens obtidas por transferência de estilo neural. A métrica DISTS apresentou a melhor performance entre diversas métricas analisadas, como o PSNR, SSIM e FSIM em relação à similaridade de textura e estrutura. Referente à métrica VSI, esta foi considerada por Yee et al. (2022), em que os autores aplicaram quatro métricas para mensurar e determinar a aplicabilidade dos métodos de normalização colorida: correspondência de histograma, equalização de histograma e métodos de separação de manchas.

Um aspecto importante a ser mencionado é que em nenhum dos casos anteriores as métricas levam em conta características encontradas em imagens de SR, por exemplo, reflectância, radiância e resoluções (espacial, espectral e radiométrica). Assim, a avaliação de métricas que sejam adequadas para tratar feições curvilíneas em imagens de SR reconstituídas pelo *inpainting* ainda carece de estudos específicos na literatura, tendo tal tópico sido explorado neste trabalho de doutorado.

1.4 Objetivos

O principal objetivo desta Tese é avaliar o uso de métricas de qualidade para quantificar os resultados de aplicação de técnicas de *inpainting* para melhoria da qualidade do processo de extração de feições cartográficas. Essa avaliação terá o destaque em feições curvilíneas parcialmente detectadas em imagens de SR, indicando quais métricas são mais adequadas para avaliar o resultado obtido após aplicação das técnicas de *inpainting*.

Alinhados ao objetivo geral, são elencados os seguintes objetivos específicos:

- Aplicar duas técnicas de *inpainting* – a proposta por Baixo (2022), e a elaborada por Azevedo (2019), em imagens digitais de alta resolução espacial;
- Reconstruir feições curvilíneas parcialmente detectadas a partir das técnicas supracitadas;
- Determinar quais são as métricas de qualidade de *inpainting* mais adequadas ao contexto do SR, com base em análises quantitativas e métodos de validação estatística, como o coeficiente de correlação. Tais métricas serão investigadas a fim de aferir o grau de reconstrução obtido pelos métodos de *inpainting* supracitados no tratamento de imagens de SR;
- Aplicar as métricas de qualidade selecionadas por meio do referencial teórico e adaptá-las quando pertinente, de forma a resultar e levar em consideração as propriedades específicas encontradas em imagens de SR, originando assim novas métricas com capacidade de captura e de mensuração de características específicas presentes em imagens de SR.
- Validar, através das métricas quantitativas customizadas no contexto de SR e a partir de análises qualitativas, a qualidade da reconstrução das técnicas de *inpainting* através de métricas identificadas com o melhor resultado;
- Avaliar a classificação de imagem de SR antes e depois do processo de aplicação das métricas, de forma a explorar o grau de assertividade das métricas selecionadas.

2. FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão apresentados alguns dos fundamentos teóricos essenciais para melhor compreender os assuntos abordados ao longo do desenvolvimento desta pesquisa, tais como: técnicas de *inpainting*, taxonomia das técnicas de *inpainting*, feições cartográficas, métricas de qualidade convencionais, métricas de qualidade aplicadas no contexto do SR e métodos estatísticos de correlação.

2.1 Técnicas de *inpainting*


Segundo Li e Wen (2012), a técnica de *inpainting* em imagens e gravuras é uma arte milenar, em que eram reparadas rachaduras das obras de artes, especialmente no período renascentista na Europa. As partes danificadas das pinturas eram reparadas e restauradas de modo integral. A partir da evolução dos computadores, as técnicas de *inpainting* em imagens digitais foram introduzidas por Bertalmio et al. (2000), no contexto computacional, consistindo no preenchimento das informações ausentes ou perdidas da imagem, com base em suas informações disponíveis.

Imagens de SR têm sido amplamente estudadas na frente de PDI, pois podem ser aplicadas em diversas áreas, tais como: agricultura, planejamento urbano e territorial, ciências da terra, meteorologia, monitoramento de desastres ambientais, condições de clima e áreas de defesa. As informações contidas nas imagens de SR fornecem atributos mais confiáveis para explorar, em larga escala, problemas como detecção de mudanças, classificação de uso e cobertura do solo, índices espectrais e identificação de diferentes tipos de rochas e minerais (LAKSHMANAN; GOMATHI, 2017). Porém, alguns elementos na imagem muitas vezes apresentam pixels danificados ou ausentes (*dead pixels*), ocasionados pela presença indesejada de nuvens e sombras. Além disso, alguns desses elementos podem estar oclusos, ruidosos, borrados ou manchados. Esses tipos de distorções limitam a execução dos métodos de pós-processamento tais como classificação e reconhecimento de alvos (INCE, 2019).

Uma das maneiras para resolver tais problemas a partir de informações da própria imagem digital é por meio da técnica de *inpainting*, que tem sido aplicada em diferentes trabalhos na área de PDI e visão computacional (VC), inclusive na linha da cartografia, conforme afirmam Arias et al. (2011), Trung et al. (2013), Qureshi et al. (2017) e Basso et al. (2021). O objetivo da técnica de *inpainting* é realizar a reconstrução,

ou retoque, na imagem de interesse, de modo a restaurar suas feições, reparar seus blocos de informação, bem como remover objetos indesejados nas imagens (ver Figura 1 para uma classificação dessas técnicas na literatura).

Figura 1 – Aplicações da reconstrução da técnica de *inpainting* e os propósitos de cada categoria.




Fonte: Adaptado de Elharrouss et al. (2019).

Conforme já salientado, técnicas de *inpainting* têm sido amplamente difundidas para tratar fotografias convencionais, remover ruídos, textos ou borrões. Porém, atualmente, tais técnicas foram estendidas para lidar também com diferentes aplicações envolvendo imagens de SR, com o intuito de obter imagens com qualidade equivalente às imagens originais sem a presença de distorções (LAKSHMANAN; GOMATHI, 2017).

Na Figura 2 são apresentados recortes de imagens de SR que contêm alguns dos problemas mais frequentes a serem restaurados pelas técnicas de *inpainting*. Tem-se que as seguintes degradações, como:

- i) Ruídos que podem ser criados pelo sensor ou condições de iluminação;
- ii) Pixels ausentes ou faixas que podem ser gerados por interferências eletrônicas, problemas ou desgaste no sensor;
- iii) Listras que podem ser consequências de interferências eletromagnéticas, erros de calibração geométrica ou processamento de imagem;
- iv) Nuvens que são geradas por condições meteorológicas e que são frequentes em determinadas regiões do globo terrestre.

Figura 2 – Alguns tipos de degradação em imagens de SR.



Fonte: Adaptado de Shen, Ai e Li (2008), Maalouf et al. (2009), Shen et al. (2010), Sophia, Lalitha e Chandar (2013), Cheng et al. (2014), e Lakshmanan e Gomathi (2017).

De acordo com Maalouf et al. (2009), uma das principais limitações presentes em imagens de SR óptico é a condição climática, pois, durante o processo de aquisição dessas imagens, as nuvens ou as sombras destas, acabam contaminando a cena de interesse. Nessa frente, técnicas de *inpainting* vem sendo desenvolvidas e adaptadas para tentar amenizar tais problemas, como presença de nuvens e sombras. Autores como:

- i) Sophia, Lalitha e Chandar (2013) desenvolveram um algoritmo de *inpainting*, baseado na abordagem *Patch-Based*, com o intuito de reconstruir imagens de SR contaminadas por nuvens;
- ii) Já Lin et al. (2014) também propuseram um algoritmo de reconstrução, baseado na abordagem *Pacth-Based*, com o intuito de reconstruir imagens de SR contaminadas por nuvens;
- iii) Ji et al. (2018) elaboraram um algoritmo cujo objetivo é reconstruir as informações perdidas ou contaminadas por nuvens em imagens de SR multitemporal;
- iv) Azevedo et al. (2019) criaram um algoritmo de detecção e remoção automática dos efeitos das sombras em áreas urbanas utilizando imagens multiespectrais com alta resolução espacial;
- v) Basso et al. (2021) implementaram uma técnica de *inpainting* baseada na abordagem *Patch-Based* que direciona o fluxo e a forma de como a reconstrução é conduzida em imagens de SR.

São notórios os avanços no desenvolvimento e na adaptação de novos algoritmos de *inpainting* para remoção de nuvens, sombras e demais objetos indesejáveis, utilizando-se abordagens diferenciadas, a fim de gerar resultados mais acurados. De fato, é importante destacar que cada algoritmo possui uma particularidade, dependendo, por exemplo, do tamanho da imagem, ou tamanho do objeto (nuvem ou sombra de nuvens), ou ainda se a nuvem está no meio ou nas bordas da imagem, entre outras especificidades.

Em relação às demais técnicas de *inpainting* que são aplicadas para remoção de outros tipos de distorções, tem-se os seguintes trabalhos:

- i) Cheng et al. (2014) desenvolveram um algoritmo baseado na abordagem *Multichannel Nonlocal Total Variation Model* que procurou preencher os pixels ausentes, remover ruídos e objetos indesejados nas imagens de SR;
- ii) Song et al. (2018) elaboraram um algoritmo capaz de remover ruídos de faixas em imagens de SR utilizando o método *Double Sparse Regulation and Region Separation*;
- iii) Ji et al. (2018) criaram um método baseado na técnica *Nonlocal Tensor Completion for Multitemporal*, cujo propósito foi remover listras de imagens de SR;
- iv) Song e Wu (2019) construíram um algoritmo de *inpainting* para imagens hiperespectrais, baseado na abordagem *Robust Spectral Dictionary Learning*, com o intuito de reconstruir o sinal esparso com observações incompletas, para solucionar os problemas dos pixels ausentes e listras defeituosas em imagens de SR;

Apesar de existirem diferentes técnicas de *inpainting* disponíveis na área de PDI, tal como discutido acima, cada técnica apresenta vantagens e desvantagens. Assim, um fator chave que irá contribuir para a escolha adequada de uma determinada técnica será o problema que se deseja solucionar e quais tipos de dados tem-se à disposição para empregar no processo de reconstrução.

As técnicas de reconstrução de imagens de SR podem ser classificadas quanto a quatro grupos básicos: método baseado no espaço, na textura, no tempo ou ser híbrido. A seguir, são apresentados cada um deles.

- i) O método baseado no espaço tem como vantagem a capacidade de prescindir de uma imagem referência para proceder à restauração. Já sua desvantagem está em não ser adequado para reconstruir uma grande região

ausente, devido à falta de informação de referência. Esse método inclui outros métodos de interpolação, de difusão propagada, métodos baseados em variação, e baseados em exemplares;

- ii) O método baseado em textura, características espectrais, utiliza-se de informações espectrais da imagem para reconstruir a região ausente. Apesar de ser um método aplicado para grandes áreas e resultar em uma reconstrução mais acurada quando comparado ao grupo anterior, as imagens de SR apresentam limitações devido a todas as bandas apresentarem a mesma região ausente;
- iii) No caso do método temporal, é utilizado para restaurar áreas ausentes, com base nos dados obtidos na mesma região, porém, em períodos distintos. Esse método tem sido mais direcionado para a tarefa de remoção de nuvens;
- iv) O método híbrido extrai informações complementares de dois ou mais domínios como espacial-temporal, espacial-espectral e espectral-temporal. Dessa maneira, quando combinados, os métodos tendem apresentar resultados significativamente mais acurados, se comparados aos outros três grupos anteriores (JI et al., 2018).

2.1.1 Métodos de *inpainting*

Dentre as diversas técnicas de *inpainting* estudadas até o momento, foram priorizadas duas delas no referido projeto: os algoritmos propostos por Baixo (2022) e o elaborado por Azevedo (2019). A escolha desses dois algoritmos justifica-se em função de ambos serem formulados para trabalhar com imagens de SR e por serem propostas recentes. O algoritmo automático proposto por Azevedo (2019) consiste em três etapas: nas duas primeiras, o objetivo é obter as regiões da imagem de SR dotadas de sombras. Como dados de entrada são utilizadas as imagens pré-processadas, com base em duas propriedades que caracterizam as sombras nas imagens. A primeira propriedade: os pixels, com valores menores de resposta registrada pelo sensor, pertencem à área de sombra. A segunda propriedade: as sombras, que apresentam maior saturação na banda do azul, ocasionado pelo espalhamento.

As sombras nas imagens apresentam baixo padrão de repostas espectrais e, para realçar essas regiões, é aplicado por meio de uma combinação da transformação *top-hat*

por fechamento com uma injeção de um parâmetro de área, calculado em função do índice de sombras NSDVI (*Normalized Saturation-Value Difference Index*). Essa transformação, é uma ferramenta do processamento morfológico de imagens que tem como objetivo recuperar estruturas relevantes das imagens por meio de operações matemáticas entre a imagem de referência e a imagem a ser corrigida. Para detalhes sobre filtragem morfológica, indica-se a referência (MA, QIN e SHEN, 2008).

Na terceira etapa, são geradas as máscaras que contém as sombras detectadas e que são usadas a fim de orientar o processo de reconstrução das regiões de sombras, por meio de uma variante do método de *inpainting* descrito em Casaca et al. (2014), o qual emprega um mecanismo específico de replicação por blocos de pixels. Nesse tipo de abordagem, a ideia é copiar “blocos de pixels” que tenham as mesmas características dos pixels que se deseja reconstruir. Essa replicação é feita mediante o cálculo de uma distância, a qual embute a informação de estrutura (regiões homogêneas e bordas) da imagem.

A Figura 3(a) apresenta uma ilustração de como o método preenche a imagem pela amostragem dinâmica. A partir de uma região de amostragem dinâmica a ser reconstruída ($H_L(p)$), toma como base a prioridade de buscar o bloco mais adequado, ou seja, o ideal ($H_m(\hat{q})$) a ser preenchido na região alvo de interesse (Ω), em uma vizinhança específica (p). Para esse propósito, foi aplicada uma medida de similaridade embasada na NRMSD (*Normalized Root Mean-Square Deviation* – Distância da Raiz Quadrada dos Quadrados Médios normalizada) (Equações 1 e 2) (AZEVEDO, 2019).

$$d(p, q) = \frac{\|p - q\|_{\Delta U}}{\sqrt{\|p\|_{\Delta U}^2 + \|q\|_{\Delta U}^2}} \quad (1)$$


em que,

$$\begin{aligned} \|p - q\|_{\Delta U} &= \sqrt{(p - q)^T \Delta U (p - q)}, \\ \|p\|_{\Delta U} &= \sqrt{p^T \Delta U p}, \\ \|q\|_{\Delta U} &= q^T \Delta U q \end{aligned} \quad (2)$$

Nas Equações (1) e (2), o termo ΔU é a matriz diagonal determinada pelo Laplaciano aplicado a uma imagem de suporte, a qual contém apenas as informações de estruturas e bordas da imagem original (CASACA, 2015), isto é, u : $\Delta U_{ii} = \Delta U_{pi}, p_i \in$

$H_n(p) \cap \Lambda\Omega_p$. Dentro da região de amostragem ($\Lambda\Omega_p$) (Figura 3(b)), a medida de NRMSD compara o bloco fixo $H_n(p)$ com todos os possíveis blocos candidatos $H_n(\hat{q})$. O bloco que minimizar a distância NRMSD entre $H_n(p)$ e $H_n(\hat{q})$ será o bloco ideal $H_m(\hat{q})$, para todo $H_n(q) \in \Lambda\Omega_p$. Com base no bloco ideal encontrado, uma pequena região $H_m(\hat{q})$, é selecionada como válida para reconstruir a região ausente na vizinhança $H(p)$ de p (Figura 3(c)) (AZEVEDO, 2019).

Figura 3 – Mecanismo de preenchimento por blocos através da amostragem dinâmica.



Fonte: Adaptada de Azevedo (2019).

O modelo proposto por Baixo (2022) foi escolhido para aplicação do *inpainting* e avaliação das imagens pelo fato da proposta configurar-se como um aprimoramento do modelo clássico *Total Variation* (TV), inicialmente proposto por Shen e Chan (2002). Posteriormente, aprimorado por Schonlieb (2015), mas que foi redesenhado para recompor partes faltantes de imagens de SR, o que inclui o *inpainting* de diferentes bandas de SR. Desse modo, serão apresentadas algumas formulações matemáticas para compreender como o modelo TV-SR, de Baixo (2022), atua em imagens de SR.

De acordo com Silva (2005), o modelo original TV consiste em minimizar a Equação 3 a seguir:

$$J_\lambda(u) = \int_I |\nabla u| dx dy + \frac{\lambda}{2} \int_{I/\Omega} |u - u_0|^2 dx dy, \quad (3)$$

em que λ é o multiplicador de Lagrange que, na prática, é adotado como sendo uma constante arbitraria no intervalo (0,1), Ω é a região faltante da imagem, I representa o domínio da imagem, o qual inclui Ω , enquanto I/Ω é a região complementar de I da qual é possível extrair as informações confiáveis não corrompidas, pois é a região não danificada, e u_0 é a imagem de entrada (BAIXO, 2022).

Após algumas simplificações e manipulações matemáticas, é possível obter a Equação Diferencial Parcial (EDP) da Equação 4. Para mais detalhes sobre o desenvolvimento completo do algoritmo, consultar Schonlieb (2015).

Por meio da Equação 4, é possível aplicar o processo de difusão sobre o domínio de retoque da imagem. Assim, chega-se à Equação 5, conhecida como o modelo de retoque TV-SR (SCHONLIEB, 2015; BAIXO, 2022).

$$u_t = |\nabla u| \operatorname{div} \left(\frac{\nabla u}{|\nabla u|} \right) \quad (4)$$

com

$$u|_{\delta\Omega} = u_0|_{\delta\Omega} \quad (5)$$

em que $\operatorname{div}(f)$ representa o operador de divergência, sendo que a condição de contorno impõe que a imagem de saída, $u = u(x, y, t)$, deverá ser igual à imagem inicial em relação às informações contidas na fronteira da região de restauração em $\delta\Omega$.

A partir da referida EDP, é formulado o modelo de retoque TV, que envolve uma função incógnita, isto é, a imagem digital. Desse modo, pretende-se estimar numericamente as soluções vinculadas a essas equações. Para tal, é necessário discretizar a região Ω (domínio de retoque). Posteriormente, são discretizadas as derivadas parciais utilizando-se o Método de Diferenças Finitas (MDF) (SILVA, 2005, BAIXO, 2022).

O termo u_t é aproximado numericamente via o MDF, através da Equação 6:


$$u_t = \frac{\partial u}{\partial t} = \frac{u(t + \Delta t) - u(t)}{\Delta t} \quad (6)$$

Considerando-se que, a cada evolução numérica de $u(t)$ em relação à variável temporal t , de passo Δt , cada iteração transforma $u(t)$ em $u(t + \Delta t)$ (SILVA, 2005, BAIXO, 2022). Após o desenvolvimento e simplificações, chega-se na Equação 7, que consiste em um processo iterativo que transforma uma determinada imagem u^n (imagem danificada) e uma nova imagem u^{n+1} (imagem restaurada):

$$u^{n+1} \cong u^n + \Delta t u_t^n \quad (7)$$

Para a implementação numérica do modelo de retoque TV, é necessário apresentar os pixels envolvidos na discretização da equação de difusão do modelo em um determinado ponto genérico (i, j) (SILVA, 2005) (Figura 4).

Figura 4 – Pixels utilizados na discretização da equação de difusão do modelo TV.



Fonte: Adaptada de Silva (2005).

O círculo preto preenchido ● simboliza os pixels conhecidos, e o triângulo vazado △ representa o pixel procurado. A equação de difusão do modelo TV é apresentada na Equação (8) e, após manipulações e simplificações, chega-se na equação de difusão do modelo de retoque TV final (Equação 9).

$$u_t^n = |\nabla u^n| \operatorname{div} \left(\frac{\nabla u^n}{|\nabla u^n|} \right) \quad (8)$$

$$u_t^n = \frac{u_{xx}^n (u_y^n)^2 + u_{yy}^n (u_x^n)^2 - 2(u_x^n u_y^n u_{xy}^n)}{(u_x^n)^2 + (u_y^n)^2}, \quad (9)$$

em que u_x^n , u_y^n , u_{yy}^n , u_{xx}^n e u_{xy}^n são calculados por meio das seguintes discretizações (BAIXO, 2022):

$$|\nabla u^n| = \sqrt{(u_{i,j}^n)^2 + (u_{i,j}^n)^2};$$

$$u_x^n(i, j) \approx \frac{u_{i+1,j}^n - u_{i-1,j}^n}{2};$$

$$u_y^n(i, j) \approx \frac{u_{i,j+1}^n - u_{i,j-1}^n}{2};$$

$$u_{xy}^n(i, j) \approx \frac{u_{i+1,j+1}^n - u_{i-1,j+1}^n - u_{i+1,j-1}^n + u_{i-1,j-1}^n}{4};$$

$$u_{xx}^n(i, j) \approx u_{i+1,j}^n - 2u_{i,j}^n + u_{i-1,j}^n;$$

$$u_{yy}^n(i, j) \approx u_{i,j+1}^n - 2u_{i,j}^n + u_{i,j-1}^n.$$

Com base no modelo discreto da Equação 9, é possível implementar computacionalmente o modelo (SCHONLIEB, 2015). Os dados de entrada são: a imagem a ser restaurada, o domínio da restauração (a máscara), o passo temporal e a quantidade total máxima de iterações.

Segundo Baixo (2022), o algoritmo funciona em quatro etapas. Na primeira etapa, o código efetua a leitura de todos os dados de entrada. Na segunda etapa, são executadas n iterações do cálculo da Equação 7 em conjunto com a Equação 9, em que a imagem danificada será atualizada em uma nova imagem a cada alteração. Na terceira etapa, a cada iteração é verificado o critério de parada pré-estabelecido, de maneira que a imagem seja retocada pelo modelo, caso o critério de parada tenha sido respeitado. O critério de parada se baseia em uma dada quantidade de iterações, que tendem a convergir. A quarta etapa consiste em estabelecer o número máximo de iterações, de modo a evitar que o algoritmo entre em um processo de não convergência (*looping*).

2.2 Taxonomia das técnicas de *inpainting*

Segundo Hu et al. (2019), as pesquisas sobre restauração (*inpainting*) de imagens apresentaram grandes avanços nos últimos anos. Uma classe de métodos nessa linha são os baseados em regularização, utilizados, sobretudo, para remover ruídos em imagens de SR e que podem ser categorizados em dois subtipos: o método local e o método não local. A estratégia local é utilizada para recuperar o valor dos pixels a partir de informações locais vizinhas, e é mais adequada para tratar formas geométricas como cantos ou arestas de imagens. Tem-se como exemplos representativos de métodos locais: suavização de imagem e filtros adaptativos. Já o método não local recupera o valor dos pixels a partir da avaliação de toda a imagem, baseando-se na limiarização global da imagem. A partir desse limiar, é possível identificar se há ruído na imagem ou não. Exemplos de métodos não locais: N-L (*Nonlocal*), NLTV (*Nonlocal Total-Variation*), e MNLTV (*Multichannel Nonlocal Total Variation*) (SINGH; KAUR, 2016).

Já para Elharrouss et al. (2019), a tarefa de reconstrução das imagens pode ser dividida em três abordagens principais: sequencial, baseada em Redes Neurais Convolucionais Profunda (*Deep Convolutional Network* – CNN) e baseada em Redes Adversárias Generativas (*Generative Adversarial Network* – GAN). Esta pesquisa irá focar apenas na classe das técnicas sequenciais, as quais podem ser reagrupadas em: modelos baseados em fragmentos e baseados em difusão. A abordagem baseada em fragmentos tem o intuito de preencher a região ausente, fragmento a fragmento, com base nas regiões correspondentes não danificadas, enquanto a abordagem baseada em difusão ou Equações Diferenciais Parciais (EDPs) tem o intuito de preencher áreas vazias propagando as informações não danificadas das bordas (limite) para as regiões vazias do interior (ELHARROUSS et al., 2019).

Uma das técnicas mais utilizadas no contexto clássico de *inpainting* tem sido a abordagem *Total Variation* (TV), que se trata de um método efetivo de difusão, de fácil implementação e ampla diversidade de uso. Shen e Chan (2002) foram os criadores do modelo *Total Variation* (TV), método baseado em EDPs e difundido por Bertalmio et al. (2000). Em Guo e Qiao (2007) os resultados via aplicação do modelo TV em relação ao tempo de processamento e restauração das feições geométricas apresentaram resultados mais acurados comparados a outros modelos. Além disso, Chauhan e Meniya (2014) revisaram e analisaram diferentes técnicas de *inpainting* em imagens fotográficas e concluíram que o método baseado no modelo TV apresentou melhor qualidade e maior confiabilidade quando comparado aos métodos do tipo *Exemplar Based* e *Wavelets*. A partir do método de Shen e Chan (2002) surgiram diferentes técnicas para realizar o *inpainting*, sendo que os algoritmos advindos de adaptações do modelo TV têm sido utilizados em diferentes contextos de aplicação (CHENG; SHEN, 2014; INCE, 2019).


Além de contribuir em aplicações de *inpainting*, o modelo TV também pode ser empregado para remoção de ruído a partir da regularização do modelo matemático TV. A aplicação de regularizadores minimiza a flutuação do resultado do sinal em semelhança com o primeiro sinal, e elimina o ruído indesejado enquanto preserva detalhes como bordas e arestas nas imagens. Por exemplo, o modelo NLTV (GILBOA; OSHER, 2009) oferece resultados satisfatórios para tratar texturas, porém, ele não é aconselhável para processar imagens coloridas (SINGH; KAUR, 2016). Segundo Cheng e Shen (2014), o modelo MNLTV é a versão aprimorada do modelo NLTV. O modelo atribui as opções de um operador não local, além de apresentar uma alta performance no tratamento de

imagens texturizadas e reconstruir regiões em grande escala. Além disso, possui a vantagem de utilizar informações multicanais de imagens de SR (SINGH; KAUR, 2016).

2.3 Feições cartográficas curvilíneas

Feições cartográficas são representações espaciais que podem ser categorizadas como pontos, conjuntos de linhas e polígonos (áreas). Um ponto é definido como um objeto cartográfico situado no espaço por meio de um par de coordenadas (X, Y). Dependendo da escala, pode ser utilizado para representar um fenômeno geográfico ou uma localidade (Figura 5a). A linha, por sua vez, é definida por pelo menos dois pontos (dois pares de coordenadas (X, Y)). Geralmente, são utilizadas para representar rios, rodovias, estradas ou limites administrativos (Figura 5b). Por fim, um polígono é definido por um conjunto de pontos (coordenadas (x, y)), que formam um segmento de linha e delimitam uma área ou região. Essas feições são utilizadas, por exemplo, para representar a extensão geográfica de um município, uma represa ou uma área desmatada (Figura 5c) (QUEIROZ; FERREIRA, 2006).

Figura 5 – Representações dos fenômenos espaciais.



Fonte: Adaptado de Queiroz e Ferreira (2006).

Há diversas aplicações e áreas de atuação onde as feições curvilíneas são analisadas. Na cartografia, em extração de estradas em imagens de SR e em ciência de materiais, na segmentação de vasos sanguíneos em imagens médicas e detecção de fibras (MERVEILLE et al., 2017).

A extração de feições cartográficas no âmbito do SR é uma tarefa essencial, especialmente no que diz respeito à extração de estradas. A extração de objetos em imagens digitais pode ser classificada em dois tipos: semiautomática e automática. Esse processo não é apenas desafiador, mas também de extrema importância para a aquisição

de dados e atualização de bancos de dados, como as estradas, que são fundamentais para um Sistema de Informações Geográficas (SIG). Além disso, o SIG apresenta uma ampla gama de aplicações, como navegação, mapeamento, gerenciamento de tráfego, planejamento urbano e atualização de informações cartográficas. Nas últimas décadas, apesar do aumento expressivo na extração de estradas em imagens de SR, a extração de estradas em imagens de SR ainda é uma tarefa árdua e desafiadora devido a ruídos, oclusões e à complexidade da superfície terrestre representada nas imagens de SR (MENA, 2003; MENA E MALPICA, 2005; WANG; QIAN; MA, 2013; ZHANG; LIU; WANG, 2018).

As feições lineares podem ser categorizadas como feições ou estruturas curvilíneas. Em imagens de SR, as feições curvilíneas incluem estradas e rios (Figura 6).

Figura 6 – Exemplos de Estruturas Curvilíneas.



Fonte: Instituto Geográfico e Cartográfico de São Paulo (IGC) (2010) e Maiores e Melhores (2022).

Em imagens de SR, as feições cartográficas curvilíneas apresentam geometria complexa, de difícil avaliação. Além disso, pequenos ruídos podem ser suficientes para danificar seu contorno, ou seja, a sua descontinuidade, ou causar conexão incorreta. Esses

problemas acontecem devido a sua estrutura frágil (LEMAITRE et al., 2011; MERVEILLE et al., 2017).

Há outras dificuldades, como aquelas que incluem uma topologia mais complexa próxima de cruzamentos e pontes. Além disso, há problemas com a oclusão por objetos no solo, sombras e árvores, condições de iluminação e meteorológica, entre outras (GAO; BISCHOF, 2009).

2.4 Métricas convencionais

2.4.1 Métricas aplicadas no contexto de imagens de SR

Segundo Sara, Akter e Uddin (2019), os meios de avaliar a qualidade das imagens podem ser objetivo (numérica) e subjetivo (visual). A avaliação subjetiva costuma ser mais árdua e mais demorada comparado com a avaliação objetiva. As métricas de qualidade de imagem que tem como base diferentes aspectos em seu desenvolvimento.

Ao longo do tempo, foram desenvolvidos e implementados vários métodos e métricas e que estão disponíveis para serem utilizados na avaliação objetiva da qualidade da imagem. Por exemplo, de acordo com Søgaaard et al. (2016), tais métodos podem ser classificados de duas maneiras: Sem Referência (SRe) e Com Referência (CR).

O método SRe tem como objetivo avaliar a qualidade da imagem com distorções com base em características ou feições da própria imagem, sem utilizar uma imagem de referência para comparação. Além disso, as métricas de qualidade são utilizadas para mensurar algum tipo específico de distorção, como desfoque, bloqueio ou perda do sinal nas imagens digitais (SARA; AKTER; UDDIN, 2019).

Já o método CR tem como intuito avaliar a qualidade da imagem ou do vídeo por meio de uma comparação entre a imagem com distorções e a outra de referência. A imagem de referência é, em geral, a imagem original, sem distorção e em ótima qualidade. Apesar de serem dois tipos de abordagem que foram desenvolvidas para imagens digitais, atualmente, essas abordagens são comumente utilizadas em imagens remotamente detectadas (SARA; AKTER; UDDIN, 2019).

Há diversas métricas para avaliar a qualidade de restauração das imagens, as quais são amplamente utilizadas tanto imagens fotográficas digitais quanto em imagens

de SR. Dentre elas, MSE (*Mean Square Error* – Erro Quadrático Médio), PSNR (*Peak Signal to Noise Ratio* – Relação Pico Sinal-Ruído), SSIM (*Structured Similarity Index Method* - Método de Indexação de Similaridade Estruturada) e DSIM (*Dynamic Structural Similarity Index* - Índice de Similaridade Estrutural Dinâmica), entre outras (SARA; AKTER; UDDIN, 2019). De acordo com Figueira et al. (2020), as métricas mais utilizadas na área de PDI são MSE, PSNR e SSIM.

Com base em referências teóricas pesquisadas até o momento, as métricas VSI (*Visual Saliency-Induced Index*) e DISTs (*Deep Image Structure and Texture Similarity Index*) ainda não foram aplicadas a imagens de SR. Particularmente, as pesquisas encontradas na literatura informaram a aplicação dessas métricas em imagens fotográficas convencionais (Zhu et al., 2022) e em imagens biomédicas (Du et al., 2022). No estudo de Zhu et al. (2022), a avaliação da qualidade da imagem foi usada em uma nova perspectiva de agrupamento em imagens fotográficas convencionais. Dentre essas métricas, a VSI foi identificada como aquela que gerou os melhores resultados, refletindo a realidade do estudo.

Já no estudo de Du et al. (2022), um método de fusão foi desenvolvido para preservar informações de textura de alta intensidade e cor. Portanto, foi necessário empregar a métrica VSI para a avaliação quantitativa das imagens. Além disso, a métrica VSI também aparece em trabalhos relacionados à criação de outras métricas para validação, como em Huang et al. (2022). Por fim, em Lu et al. (2022), a métrica VSI foi empregada para validar a criação de uma rede de aprimoramento de baixa luminosidade com assistência de gradiente anterior (GPANet). Essa rede é responsável por extrair características de borda e remover ruídos indesejados, introduzindo recursos do Filtro Sobel e do Filtro Laplaciano.

Embora o DISTs seja uma métrica recente, tem sido usada com sucesso em várias aplicações. No entanto, no campo do SR, não foram encontrados estudos relacionados. Liu e Yeoh (2021) criaram uma abordagem automatizada para reconhecer padrões de fissuras em concreto, e para fins de validação, a DISTs foi usada para reconhecer padrões de fissuras por meio de comparações de similaridade. A métrica DISTs também aparece como uma ferramenta de validação em trabalhos científicos relacionados à geração de novas métricas, como no Aprimoramento de Imagens Subaquáticas (*Underwater Image Enhancement* - UIF) (Zheng et al., 2022a) e na Média e Desvio da Similaridade Profunda e Local (*Deviation of Deep and Local Similarity* - MaD-DLS) (Sim et al., 2020). Por fim, em Zheng et al. (2022b), a métrica DISTs foi

aplicada junto com outras métricas de avaliação, como FSIM, para avaliar a qualidade de artefatos de aprimoramento de resolução espacial de imagens.

2.4.2 MSE (*Mean Square Error – Erro Quadrático Médio*)

A métrica MSE pode ser compreendida como o Desvio Quadrado Médio (MSD) de um estimador estatístico. O MSE apresenta valores sempre positivos e quando mais próximo de zero indica melhores resultados. É também considerada como uma métrica tradicional, que requer uma imagem de referência para sua validação (FIGUEIRA et al., 2020; SARA; AKTER; UDDIN, 2019; WAFY; EBAID, 2016).

O MSE entre duas imagens é definido na Equação 10 (KAY, 1993):

$$MSE = \frac{1}{NM} \sum_{i=1}^N \sum_{j=1}^M (z'(i, j) - z''(i, j))^2 \quad (10)$$

Na Equação 10, tem-se que $z'(i, j)$ e $z''(i, j)$ são as imagens de referência e a imagem com distorções, respectivamente, e M e N são os números de linhas e colunas das imagens, respectivamente.

No processo de geração de imagens, o real intuito de qualquer que seja a técnica de *inpainting* ou de remoção de ruído é melhorar a fidelidade e a qualidade visual de uma imagem com distorções. No entanto, a MSE, embora quantifique a distorção entre a imagem de referência e uma imagem processada, acaba não considerando certas características importantes de uma imagem como textura, ordens e padrões (NDAJAH et al., 2010).

2.4.3 PSNR (*Peak Signal to Noise Ratio – Relação Pico Sinal-Ruído*)

O PSNR é utilizado para calcular a razão entre o valor máximo do sinal e o valor do ruído de distorção que prejudica a qualidade da representação. Em outras palavras, esse é calculado pela razão do número de níveis de cinza na imagem e seu pixel correspondente na imagem de referência. Quando maior for o valor do PSNR, melhor o resultado, ou seja, indica que a imagem teste e a de referência são semelhantes. No contexto da aplicação da técnica de *inpainting*, quando o resultado do PSNR entre a imagem de referência e a imagem que foi aplicada o *inpainting* for alto, indica que ambas

são semelhantes e quando esse valor for baixo, indica que as imagens são mais distintas uma da outra. Para realizar os cálculos dessa métrica, é necessário utilizar o MSE (JAGALINGAM; HEGDE, 2015; TIEFENBACHER et al., 2015; SARA; AKTER; UDDIN, 2019; FIGUEIRA et al., 2020).

O PSNR é calculado utilizando a função logarítmica, pois os sinais apresentam uma faixa dinâmica muito ampla. Além disso, o PSNR consegue medir a diferença entre os valores dos pixels de maneira individual. Em geral, a relação entre duas imagens é calculada em forma de decibéis (dB) (TIEFENBACHER et al., 2015; SARA; AKTER; UDDIN, 2019).

O PSNR pode ser expresso conforme a Equação 11 (RABBANI; JONES; 1991):

$$PSNR = 20 \log_{10} \left(\frac{L}{\frac{1}{NM} \sum_{i=1}^N \sum_{j=1}^M (z'(i,j) - z''(i,j))^2} \right) \quad (11)$$

Na Equação 11, o termo L representa o número total de níveis de cinza da imagem. Valores usuais adotados para representar L são 256 e 512.

Uma outra maneira de expressar a equação do PSNR (SARA; AKTER; UDDIN, 2019) é a partir da expressão abaixo (Equação 12):

$$PSNR = 10 \log_{10} \left(\frac{(max)^2}{MSE} \right) \quad (12)$$

Nesse caso, o valor de pico (*max*) na Equação 12 significa o máximo dentre os pixels das duas imagens/sinais. Por exemplo, a razão sinal-ruído é um método que consegue avaliar a qualidade da restauração de *codecs* de compressão de imagens com distorções ou perdas. Neste caso, o sinal representa o dado original e o ruído é o erro produzido pela distorção. Este método é um dos mais utilizados na avaliação de qualidade de imagens digitais, de acordo com Sara et al. (2019).

As métricas PSNR e MSE são bastante aplicadas devido a sua simplicidade de uso e fácil implementação matemática (SARA; AKTER; UDDIN, 2019). Porém, são métricas não normalizadas na representação.

2.4.4 SSIM (*Structured Similarity Index Method* - Método de Indexação de Similaridade Estruturada)

O SSIM é um método de avaliação baseado na percepção de estrutura. Desse modo, a degradação da imagem ocorre quando existe uma mudança de percepção na informação estrutural. A função do SSIM é comparar padrões locais de intensidade entre os pixels da imagem teste e a de referência. Seu resultado varia na escala de -1 a 1; à medida que esse resultado se aproxima do valor 1, indica-se que a imagem teste e a imagem de referência são semelhantes (JAGALINGAM; HEGDE, 2015; SARA; AKTER; UDDIN, 2019).

A métrica SSIM pertence à abordagem CR e fornece o valor médio normalizado de similaridade estrutural entre a imagem distorcida/teste e a imagem de referência (SARA; AKTER; UDDIN, 2019). O SSIM mede as distorções por meio da combinação de três fatores: perda de correlação, distorção de luminância e do contraste (NDAJAH et al., 2013).

A equação do SSIM pode ser expressa como (Equação (13)) (WANG et al., 2004):

$$SSIM = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (13)$$

Na Equação 13, μ é média e σ é o desvio padrão da imagem; x é a imagem original e y a imagem teste; σ_{xy} é a covariância entre x e y ; e C_1 e C_2 são constantes que evitam a instabilidade numérica, ou seja, quando $\mu_x^2 + \mu_y^2$ e $\sigma_x^2 + \sigma_y^2$ estão próximos de zero. Geralmente, a métrica SSIM utiliza janela de filtros Gaussianas e podem ser calculadas globalmente e localmente (SØGAARD et al., 2016).

O SSIM é uma métrica que prediz a qualidade de imagens e vídeos, quando se tem a necessidade de medir a semelhança estrutural entre a imagem teste e a referência. O SSIM é mais eficiente quando comparado com o PSNR e o MSE (FIGUEIRA et al., 2020).

A partir da métrica SSIM, foi deduzida uma outra métrica chamada de DSSIM. Essa métrica foi utilizada no trabalho Ataei, Alirezaie e Babyn (2020) e apresentou certas melhorias em relação ao contraste da imagem. A expressão matemática dessa métrica pode ser definida pela Equação 14 a seguir (SARA; AKTER; UDDIN, 2019):

$$DSSIM(x, y) = \frac{1 - SSIM(x, y)}{2} \quad (14)$$

2.4.5 FSIM (*Feature Similarity Index* - Índice de Similaridade de Feições)

A métrica FSIM mede o grau de similaridade entre a imagem original e a imagem distorcida. Para calcular o FSIM, é necessário utilizar dois critérios: Fase de Congruência (FC) e Magnitude de Gradiente (MG) (Zhang et al., 2011).

A FC é o método para detectar características na imagem. Além disso, a FC é invariante para o contraste. Enquanto o MG é o cálculo do gradiente da imagem, que utiliza máscaras de convolução para expressar os operadores dos gradientes (SARA, AKTER E UDDIN, 2019; HOUSSEIN et al, 2022). A Similaridade é calculada entre as duas imagens por meio da Equação 15 (Zhang et al., 2011):

$$S_{PC} = \frac{2PC_1 \cdot PC_2 + T_1}{PC_1^2 + PC_2^2 + T_1} \quad (15)$$

Na Equação 15, PC_1 e PC_2 são as imagem original e distorcida respectivamente; e, T_1 é utilizada como uma constante positiva para aumentar a estabilidade de S_{PC} (HOUSSEIN et al, 2022). A similaridade do gradiente da imagem é calculada por meio da Equação 16 (Zhang et al., 2011):

$$S_G = \frac{2G_1G_2 + T_2}{G_1^2 + G_2^2 + T_2} \quad (16)$$

Na equação 16, o G_1 e G_2 são os gradientes da imagens original e distorcida respectivamente; e o T_2 é uma constante positiva que varia conforme a faixa dinâmica dos valores de MG (HOUSSEIN et al, 2022).

Finalmente, utilizando os resultados de FC e MG, a similaridade é calculada pela Equação 17 (Zhang et al., 2011):

$$S_L(x) = [S_{PC}(x)]^\alpha \cdot [S_G(x)]^\beta \quad (17)$$

Na Equação 17, α e β representam os parâmetros responsáveis pelos ajustes de importância relativa das características de FC e MG. Os valores de FSIM são normalizados e quanto maior o valor, no intervalo de zero a um, mais próximo o grau de similaridade entre a imagem distorcida e a imagem original.

A similaridade geral entre a imagem distorcida e a imagem original é calculada ao ponderar a similaridade local com a importância perceptual dos locais, no qual as bordas e estruturas de FC são mais significativas para o HVS. O valor máximo de FC em cada local é usado para esse peso. Dessa maneira, o índice FSIM reflete a relevância perceptual das características na imagem (Zhang et al., 2011).

A FSIM é definida pela Equação 18 (Zhang et al., 2011):

$$FSIM = \frac{\sum_{x \in \Omega} S_L(x) \cdot FC_m(x)}{\sum_{x \in \Omega} FC_m(x)} \quad (18)$$

Na Equação 18, o termo Ω representa todo o domínio espacial da imagem.

2.5 Métricas aplicadas no contexto de imagens fotográficas convencionais

Além do contexto das imagens de SR, há diferentes propostas de métricas que são utilizadas para avaliar a qualidade de imagens fotográficas digitais convencionais, a exemplo das métricas VSI e DISTs, já mencionadas nas seções anteriores. Por meio de diversas leituras em pesquisas de artigos internacionais, no qual a investigação do referencial teórico contribuiu para o discernimento da utilização dessas duas métricas para o contexto do SR.

As métricas de interesse para esta pesquisa são aquelas definidas a partir dos seguintes paradigmas de interpretação: estrutura e saliência. As métricas baseadas em estrutura estão relacionadas com a diferença de estrutura entre a imagem de referência e aquela na qual foi aplicada a técnica de *inpainting*. Já a métrica baseada em saliência procura destacar a área para a qual a visão humana é mais reativa ou interessada, ou seja, objeto de maior atenção na imagem (KADIAN; KHADANGA, 2019).

2.5.1 VSI (*Visual Saliency-Induced Index* – Índice induzido pela Saliência Visual)

A métrica de qualidade VSI avalia a preservação da saliência visual (SV) após o processamento da imagem, comparando a similaridade entre as imagens distorcida e original. A métrica VSI parte do pressuposto de que o HSV é sensível a características proeminentes na imagem, como bordas e contraste, e considera crucial preservar essas características para manter a qualidade visual da imagem.

A SV tem sido utilizada em diversas aplicações ao longo das últimas décadas, incluindo neurobiologia e ciência da computação. A VSI utiliza a SV como um recurso para calcular o mapa de qualidade da imagem processada. Em seguida, a pontuação de qualidade é agregada e a SV é aplicada como uma função de ponderação para refletir a importância de regiões específicas. Além disso, a VSI é uma métrica de baixa complexidade que oferece resultados satisfatórios em comparação a outras métricas utilizadas no processo de validação de imagens convencionais (ZHANG, SHEN E LI, 2014).

Segundo Kumar, Bhandari e Kumar (2022), quanto mais próximo o valor do VSI estiver de 1, melhor será a saída da SV entre a imagem de referência e a distorcida. Em outras palavras, quanto maior o valor do VSI, melhor o resultado e menor a distorção da SV. Por outro lado, a VSI não é adequada para avaliar imagens em tons de cinza, ou seja, imagens com apenas uma banda (GRIGAS, MASKELIUNAS E DAMAŠEVICIUS, 2023).

Para abordar algumas propriedades no processo de avaliação das métricas no processo de AQI (Avaliação de Qualidade de Imagem - *Image Quality Assessment*), como distorções das cores e informação de cromaticidade, a VSI realiza uma transformação em um espaço de cores, por meio de uma matriz de transformação, isto é, Equação 19. Os pesos são otimizados para o sistema visual humano (HVS) (ZHANG, SHEN e LI, 2014). O termo L representa os canais da imagem, e os termos M e N são os canais de cromaticidade; os termos RGB refere-se as bandas das imagens coloridas.

$$\begin{bmatrix} L \\ M \\ N \end{bmatrix} = \begin{bmatrix} 0,06 & 0,63 & 0,27 \\ 0,30 & 0,04 & -0,35 \\ 0,34 & -0,6 & 0,17 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (19)$$

Devido à falta de sensibilidade ao contraste da SV, foram utilizados os módulos de gradiente (*Gradient Modulus* - GM). Para calcular o gradiente da imagem, o operador de gradiente *Scharr* foi escolhido devido a resultados satisfatórios. São calculadas derivadas parciais $G_x(x)$ e $G_y(x)$ de uma imagem $f(x)$, por meio das Equações 20 e 21 (ZHANG, SHEN E LI, 2014):

$$G_x(x) = \frac{1}{16} \begin{bmatrix} 3 & 0 & -3 \\ 10 & 0 & -10 \\ 3 & 0 & -3 \end{bmatrix} * f_{(x)} \quad (20)$$

$$G_y(x) = \frac{1}{16} \begin{bmatrix} 3 & 10 & 3 \\ 0 & 0 & 0 \\ -3 & -10 & -3 \end{bmatrix} * f_{(x)} \quad (21)$$

Então, o GM de $f_{(x)}$ é calculado na Equação 22:

$$G_x = \sqrt{G_x^2(x) + G_y^2(x)} \quad (22)$$

O mapa de SV calculado no processo anterior é utilizado para calcular a semelhança entre diferentes recursos da imagem como mapa da SV, GM e elementos de crominância. A similaridade entre o mapa de SV é calculado por meio da Equação 23 (ZHANG, SHEN e LI, 2014; GRIGAS, MASKELIUNAS e DAMAŠEVICIUS, 2023):

$$S_{VS}(x) = \frac{2SV_1(x) \cdot SV_2(x) + C_1}{2SV_1^2(x) \cdot SV_2^2(x) + C_1} \quad (23)$$

Na Equação 23, o termo C_1 é uma constante utilizada para aumentar a estabilidade de S_{SV} . Do mesmo modo, os valores de GM entre as imagens são calculados por meio da Equação 24.

$$S_G(x) = \frac{2G_1(x) \cdot G_2(x) + C_2}{G_1^2(x) \cdot G_2^2(x) + C_2} \quad (24)$$

Na Equação 24, o termo C_2 é uma outra constante positiva. A crominância é calculada depois da transformação da imagem coloridas (RGB), canais L, M e N. Assim, a similaridade entre os componentes de crominância é calculada na Equação 25.

$$S_c(x) = \frac{2M_1 \cdot M_2 + C_3}{M_1^2(x) + M_2^2(x) + C_3} \cdot \frac{2N_1 \cdot N_2 + C_3}{N_1^2(x) + N_2^2(x) + C_3} \quad (25)$$

As constantes C_1 , C_2 e C_3 nas Equações 23, 24 e 25 foram todas fixadas de forma que a VSI pudesse convenientemente ser aplicado em todos os conjuntos de dados. Então, a partir das semelhanças identificadas, é calculada a medida de similaridade conforme descrito na Equação 26.

$$S(x) = S_{VS}(x) \cdot [S_G(x)^\alpha] \cdot [S_C(x)^\beta] \quad (26)$$

Na equação 26, α e β são parâmetros utilizados para ajustar a importância da saliência visual, modulo de gradiente e componente de crominância.

Finalmente, a Equação 27 da VSI pode ser expressa da seguinte maneira (ZHANG, SHEN e LI, 2014):

$$VSI = \frac{\sum_{x \in \Omega} S(x) \cdot SV_m(x)}{\sum_{x \in \Omega} SV_m(x)} \quad (27)$$

Na equação 27, o Ω representa todo o domínio espacial; o $S(X)$ representa a similaridade calculada na localização x , e $SV_m(X)$ avalia a importância de $S(X)$ na similaridade geral.

2.5.2 DISTs (*Deep Image Structure and Texture Similarity* – Similaridade Profunda de Estrutura e Textura em imagens)

A métrica DISTs permite calcular distorções estruturais (artefatos causados por ruído ou desfoque) com uma tolerância para remapeamento de texturas, onde uma região de textura é transformada em uma nova amostra, na qual os pixels são diferentes. No entanto, em termos de perspectiva visual, a textura é idêntica do ponto de vista visual (LIU e YEOH, 2021).

A DISTs utiliza uma rede neural convolucional (CNN) para transformar as imagens de referência e distorcidas em novas representações. Os autores optaram por utilizar o modelo chamado VGG16, uma CNN já treinada para reconhecer objetos em um grande banco de dados chamado *ImageNet*. Esta rede é composta por várias camadas que

processam as imagens em etapas, realizando operações como detecção de características e redução de informações. A vantagem de escolher essa rede é que suas operações são suaves e podem ser facilmente diferenciadas matematicamente, o que é útil para uma técnica de AQI Além disso, a rede será usada para melhorar sistemas de processamento de imagens (DING et al., 2022).

Para melhor adaptar a rede CNN ao objetivo da métrica DISTS, foram necessárias duas modificações muito importantes. Para evitar a criação de artefatos visuais indesejados após a transformação inicial da imagem, os autores modificaram uma operação específica chamada "*max pooling*", que habitualmente é usada, pois essa operação pode criar esses artefatos. Além disso, notou-se que outras propriedades matemáticas seriam úteis para o propósito específico da métrica. Por exemplo, pretendia-se que cada entrada (imagem) produzisse uma saída (representação) única, sem duplicações, pois isso ajudaria a garantir que a medida final de qualidade de imagem funcionasse com relação matemática correto. Essa propriedade matemática é importante, pois a igualdade entre representações finais não deve ser afetada por diferentes maneiras de representar a mesma imagem (DING et al., 2022).

Como a maioria das transformações das CNN, a VGG, mantém-se informações importantes ao processar as imagens, durante a análise em rede, pois algumas informações podem ser perdidas a cada etapa de transformação. Isso, para garantir que o processo seja "injetivo", ou seja, para que cada entrada única tenha uma saída correspondente única (evitando que várias entradas sejam mapeadas para a mesma saída). Para tanto, os autores criaram uma estratégia que consiste em utilizar a própria imagem de entrada (zero) como uma camada adicional (chamada de *zeroth*), antes das etapas de processamento normais. Em seguida, eles anexam as informações obtidas das respostas de convolução de cinco camadas específicas da VGG, Equação 28 (DING et al., 2022):

$$f(x) = \{\tilde{x}_j^{(i)}; i = 0, \dots, m; j = 1, \dots, n_i\} \quad (28)$$

Na Equação 28, o termo m pode ser representado até o quinto termo, que significa o número de camadas de convolução escolhidas para construir f ; n_i é o número de mapas de características na i -ésima camada de convolução e $\tilde{x}_j^{(0)} = x$. De modo análogo, a representação da imagem distorcida também é computada, Equação 29 (DING et al., 2022):

$$f(y) = \{\tilde{y}_j^{(i)}; i = 0, \dots, m; j = 1, \dots, n_i\} \quad (29)$$

Essa estratégia da imagem de entrada ser incluída na CNN como um mapa adicional de características, auxilia a criar uma representação mais rica e detalhada da imagem, preservando informações valiosas em cada etapa do processamento.

Para demonstrar a importância da abordagem descrita acima, é importante tentar recuperar a imagem de referência a partir de uma imagem inicial. Por meio da otimização, de uma nova imagem para que se assemelhasse ao máximo possível à imagem de referência, utiliza-se uma medida de AQI completa. A ideia é mostrar como preservar informações valiosas desde o início, o que pode ajudar no aperfeiçoamento da qualidade da imagem final (DING et al., 2022).

Em seguida, é criado um conjunto de medidas para capturar a aparência visual das texturas da imagem. Posteriormente, os parâmetros de textura e medidas estruturais globais são combinados para formar uma avaliação da qualidade da imagem (DING et al., 2022). Os autores descobriram em seus experimentos que para criar um modelo eficaz de texturas visuais, é suficiente usar um conjunto estatístico muito reduzido, especificamente as médias espaciais dos mapas de características. Então, os autores usaram esse modelo para criar texturas sintéticas, a partir de uma imagem de textura alvo, através de um processo de otimização, Equação 30 (DING et al., 2022):

$$y^* = \arg_y \min D(x, y) = \arg_y \min \sum_{i,j} (\mu_{\tilde{x}_j}^{(i)} - \mu_{\tilde{y}_j}^{(i)})^2 \quad (30)$$

Na Equação 30, o termo x representam a imagem de textura a ser replicada, e o termo y representa a imagem de textura sintética resultante desse processo, utilizando da média espacial dos canais das camadas de CNN para guiar esse processo de criação da textura sintética; e, o $\mu_{\tilde{x}_j}^{(i)}$ e $\mu_{\tilde{y}_j}^{(i)}$ são as médias dos canais $\tilde{x}_j$ e $\tilde{y}_j$, respectivamente.

Ao considerar estatísticas das camadas iniciais da rede, a textura sintética capturou informações básicas de intensidade e cor. Em contrapartida, ao incluir estatísticas das camadas mais avançadas, a textura sintética conseguiu resumir informações mais complexas relacionadas à forma e estrutura da textura. Ao coincidir estatísticas até uma camada específica da rede neural pré-treinada, denominada conv5_3, a textura sintetizada assemelhou-se visualmente à imagem de textura de referência,

demonstrando a eficácia desse método para reproduzir fielmente texturas visuais (DING et al., 2022).

Foram realizadas medições de qualidade com base na forma da métrica SSIM, essas medições foram feitas de maneira separada para a textura, avaliada pela média global, e a estrutura, avaliada pela correlação global, de cada par de mapas de características correspondentes. As Equações 31(similaridade de textura - $l(\tilde{x}_j^{(i)}, \tilde{y}_j^{(i)})$) e 32 (similaridade de estrutura - $s(\tilde{x}_j^{(i)}, \tilde{y}_j^{(i)})$) funcionam como um mecanismo de normalização para equalizar a magnitude dos mapas de características de diferentes etapas (DING et al., 2022):

$$l(\tilde{x}_j^{(i)}, \tilde{y}_j^{(i)}) = \frac{2\mu_{\tilde{x}_j}^{(i)}\mu_{\tilde{y}_j}^{(i)} + C_1}{(\mu_{\tilde{x}_j}^{(i)})^2 + (\mu_{\tilde{y}_j}^{(i)})^2 + C_1} \quad (31)$$

$$s(\tilde{x}_j^{(i)}, \tilde{y}_j^{(i)}) = \frac{2\sigma_{\tilde{x}_j\tilde{y}_j}^{(i)} + C_2}{(\sigma_{\tilde{x}_j}^{(i)})^2 + (\sigma_{\tilde{y}_j}^{(i)})^2 + C_2} \quad (33)$$

Nas Equações 31 e 32, os $\mu_{\tilde{x}_j}^{(i)}$, $\mu_{\tilde{y}_j}^{(i)}$, $\sigma_{\tilde{x}_j}^{(i)}$, $\sigma_{\tilde{y}_j}^{(i)}$ e $\sigma_{\tilde{x}_j\tilde{y}_j}^{(i)}$ representam as médias globais e variâncias de $\tilde{x}_j^{(i)}$ e $\tilde{y}_j^{(i)}$; e a covariância global entre $\tilde{x}_j^{(i)}$ e $\tilde{y}_j^{(i)}$, respectivamente; são adicionadas constantes pequenas positivas C_1 e C_2 , para evitar instabilidade numérica quando o denominador aproxima-se de zero.

De acordo com DING et al. (2022), a DISTS é uma métrica robusta em relação a distorções geométricas leves e demonstra um desempenho satisfatório na classificação e recuperação de texturas. Ela varia de 0 a 1, onde 0 indica que a imagem distorcida se assemelha à imagem de referência.

A Equação 33 do DISTS combina as medidas de qualidade de diferentes camadas de convolução usando uma soma ponderada e pode ser expressa como (DING et al., 2022):

$$D(x, y; \alpha, \beta) = 1 - \sum_{i=0}^m \sum_{j=0}^{ni} \left(\alpha_{ij} l(\tilde{x}_j^{(i)}, \tilde{y}_j^{(i)}) + \beta_{ij} s(\tilde{x}_j^{(i)}, \tilde{y}_j^{(i)}) \right) \quad (33)$$

Na Equação 33, o α_{ij} e o β_{ij} são pesos aprendíveis positivo, $l(\tilde{x}_j^{(i)}, \tilde{y}_j^{(i)})$ representa a função de similaridade de textura e $s(\tilde{x}_j^{(i)}, \tilde{y}_j^{(i)})$ representa a função de similaridade de estrutura. Os pesos percentuais de $\{\alpha, \beta\}$ foram otimizados em conjunto para a percepção humana da qualidade da imagem e invariância de textura.

2.6 Medidas de Correlação

Há diversos métodos de correlação, como o coeficiente de *Pearson*, o coeficiente de *Spearman* e o coeficiente de *Kendall*. Embora o coeficiente de correlação de *Pearson* seja mais comum, tanto o coeficiente de *Spearman* quanto o coeficiente de *Kendall* são mais robustos. Eles são especialmente aplicados quando se deseja avaliar a confiabilidade de dados em conjuntos menores e ordenados; ou quando a distribuição dos dados é desconhecida ou não segue uma distribuição normal padrão. Além disso, esses dois coeficientes de correlação são medidas não paramétricos, ao passo que o coeficiente de *Pearson* é uma medida paramétrica (SIEGEL, 1956; CHEN et al, 2023; MALOVIĆ et al, 2023).

Há diversas áreas de atuação em que os coeficientes de correlação são aplicados, inclusive na área de SR. No trabalho de Kazakeviciute-Januskeviciene et al. (2020), o coeficiente de correlação de *Spearman* foi utilizado para avaliar as imagens de satélite após aplicação de um algoritmo de agrupamento *k-means* baseado em informações de cores. Já no trabalho de Ieremeiev et al. (2020) foi utilizado o coeficiente de correlação de *Spearman* e o coeficiente de correlação *Kendall* entre métricas de avaliação quantitativa e o MOS (*Mean Opinion Score*), que é uma análise de qualidade perceptível (análise subjetiva), em um conjunto de imagens de SR. Por fim, Huang et al. (2022) utilizaram Coeficiente de Correlação de *Spearman* e o Coeficiente de Correlação de *Kendall* para avaliar o desempenho de vários modelos de avaliação de qualidade de imagem.

2.6.1 Coeficiente de correlação de classificação de *Spearman*

O Coeficiente de Correlação de Classificação de Spearman (*Spearman Rank Correlation Coefficient* - SRCC) mede a monotonicidade da relação entre duas variáveis ou dois fenômenos, ou seja, não segue uma relação de ordem consistente entre as

variáveis. Quando ambas as variáveis aumentam ou diminuem em conjunto, a relação entre elas será positiva, se uma variável diminui enquanto a outra aumenta, a relação entre elas será negativa (ALI ABD AL-HAMEED, 2022; CHAUDHARY et al., 2022).

O intervalo de correlação do SRCC varia de -1 a 1. O Quadro 2 apresenta os intervalos de correlação entre as duas variáveis, neste caso, apresenta apenas o lado positivo, sendo semelhante para o lado negativo.

Quadro 2 – Intervalo de correlação do SRCC.

Valor do coeficiente de correlação	Caracterização da Correlação
0	Nenhuma
0,01 a 0,49	Fraca
0,50 a 0,69	Média
0,70 a 0,99	Alta
1	Perfeita

Fonte: Adaptado de (Ali Abd Al-Hameed, 2022).

Primeiro, classificam-se os valores de cada variável, dando a cada valor uma posição com base em uma ordem de importância. Se houver valores idênticos, atribui-se a eles a média das posições que ocupariam. Em seguida, é calculada a diferença entre as posições, para cada par de valores, e encontrada a diferença entre as posições, ou seja, se um valor está na posição 1 e o outro está na posição 4, a diferença é 3 (4 - 1). Assim, eleva-se ao quadrado e somam-se as diferenças ao quadrado. Por fim, é aplicada a fórmula do coeficiente de correlação que é definido na Equação 34 (SIEGEL, 1956):

$$\rho_s = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (34)$$

Na Equação 34, o d_i representa a diferença entre cada observação entre as duas variáveis; e, o n representa o número de pares ordenados.

2.6.2 Coeficiente de correlação de classificação de Kendall

O Coeficiente de Correlação de Classificação de *Kendall* (KRCC - *Kendall Rank Correlation Coefficient*), τ , mede a correlação entre duas variáveis e avalia o grau de concordância entre suas classificações. Amplamente utilizado em variáveis classificadas

de forma ordenada, o KRCC demonstra baixa sensibilidade a valores discrepantes dentro das variáveis. Em relação ao coeficiente de *Pearson*, o KRCC é mais robusto e exibe maior eficiência estatística quando comparado ao SRCC (*Spearman Rank Correlation Coefficient*), e se torna bastante adequado para a tarefa de correspondência de características (CHEN et al., 2022).

O intervalo da correlação varia de -1 a 1, conforme indicado no Quadro 3. Similar ao SRCC, o coeficiente de *Kendall* classifica os valores de cada variável, atribuindo a cada valor uma posição com base em sua ordem. Em seguida, são contados os pares de observações e identificados quais pares de variáveis concordam e discordam na lista. Os pares concordam quando a ordem relativa entre as variáveis nas duas listas é a mesma, e discordam quando essa ordem relativa difere.

Quadro 3 – Descrição sobre coeficiente de *Kendall*.

τ	Representação da informação
1	Quanto mais próximo de 1, indica uma concordância perfeita entre as classificações.
0	Quanto mais próximo de 0, indica aleatoriedade entre as classificações
-1	Quanto mais próximo de -1, indica uma discordância perfeita entre as classificações.

Fonte: (SIEGEL, 1956).

O KRCC é representada pela Equação 35 (Kendall, 1938):

$$\tau = \frac{n_c - n_d}{n_k} \quad (35)$$

Na equação 35, o n_c representa o número de pares concordante; o n_d representa o número de pares discordantes; e, o n_k representa o número total de pares únicos de observações.

3. METODOLOGIA

Neste capítulo, são descritos os processos adotados para a realização deste trabalho, incluindo a descrição dos recursos cartográficos e computacionais utilizados. Posteriormente, é apresentado o banco de dados de imagens utilizado nas análises, e por fim, os procedimentos metodológicos adotados, incluindo um fluxograma com as etapas implementadas.

3.1 Materiais

- Computador pessoal Dell *Inspiron* 15 3567 com processador Intel Core i5, 8 GB de memória RAM e disco rígido de 1 T;
- Software MATLAB (R2022b), versão 9.13.0.2193358;
- Image Processing Toolbox for MATLAB;
- Software de Sistema de Informação Geográfica ArcGIS 10.3, versão 10.3.0.4322, desenvolvido pela empresa ESRI (*Environmental Systems Research Institute*);
- Software ENVI (*Environment for Visualizing Images*) desenvolvido pela empresa Exelis *Visual Information Solutions* (VIS);
- Imagens do acervo aerofotogramétrico e cartográfico do Instituto Geográfico e Cartográfico de São Paulo – IGC do ano de 2010, com resolução espacial de 45 centímetros;
- Imagens de satélite do acervo da EOSDA *LandViewer Crop Monitoring*, com resolução espacial de 3 metros, sensor da *Planetscope*.

Referentes aos recursos computacionais, o software ArcGIS foi utilizado para extrair a banda de georreferenciamento das imagens aéreas, em vista a técnica de Baixo (2022) só é aplicada em imagens com três bandas (RGB). As imagens pré-processadas são os dados de entrada utilizados pelas técnicas de *inpainting* no software MATLAB, o qual faz o uso de funções disponíveis na *toolbox* de processamento de imagem. O software ENVI 4.8 foi utilizado no processo de classificação não-supervisionada pelo classificador k-médias (*k-means*) das imagens restauradas.

3.2 Base de dados

Foram utilizadas, uma base cartográfica, composta por imagens do acervo aerofotogramétrico e cartográfico do IGC da região de Pirapozinho, SP, Figura 7. Este acervo faz parte do Projeto Mapeia São Paulo, responsável pela atualização cartográfica do Estado de São Paulo da empresa de Planejamento Metropolitano S/A – EMPLASA. Com sistema de coordenadas na projeção UTM (Universal Transversa de Mercator), no fuso 22 Sul, Datum SIRGAS 2000. A base da ortorretificação foi no MDS (Modelo Digital de Superfície) e as imagens foram obtidas com as câmeras Ultracam, modelos X e XP, com GSD (*Ground Sample Distance*) de 45 centímetros.

A outra base cartográfica é composta por imagens do acervo da EOSDA *LandViewer* com resolução espacial de 3 metros da região de Presidente Prudente, SP. O sensor da *Planetscope* apresenta quatro bandas espectrais: Azul (455-515nm), Verde (500-590nm), Vermelho (590-670nm) e Infravermelho Próximo (780-860nm). Na Tabela 1, são apresentados as informações sobre a geometria de aquisição junto aos metadados das imagens.

A região escolhida para a pesquisa foi de Pirapozinho-SP, Figura 7, e de Presidente Prudente-SP, Figura 8, pois é uma área que contém feições cartográficas como vegetação (textura), cultivos agrícolas (padrões) e estradas (feições curvilíneas). Além disso, deveria ser uma região que fosse possível de verificar melhor as classes após aplicação da técnica de *inpainting*.


Tabela 1 – Informações sobre a geométrica de aquisição da imagem de SR Orbital

Informações	<i>Planetscope</i>
Data de aquisição	10/01/2024
Horário	13:53:59
Elevação solar	67°35'59,99"
Azimute solar	93°42'00"
Azimute do sensor	69°5'59,99"
Ângulo de visada (off-nadir)	05°00'00"

As imagens originais de SR dos acervos apresentavam um *frame* de 10.000 x 10.000 pixels. A fim de otimizar o tempo de processamento e utilizar regiões das imagens com feições de interesse; as imagens foram recortadas no software MATLAB. Dessa

maneira, foram criadas milhares de imagens com *frames* de 300 x 300 pixels aproximadamente estabelecidos pelo algoritmo.

Figura 7 – Imagem do acervo aerofotogramétrico e cartográfico do IGC.




Fonte: IGC (2010); elaborado pelo autor (2024).

Em relação as imagens de SR aéreas, dos milhares de recortes criados foram selecionados cinco recortes que contêm feições cartográficas de interesse, como: textura, padrão e feições curvilíneas. Desses recortes foram gerados milhares de imagens devido a técnica de *inpainting* de Azevedo (2019) ter como base três tamanhos de janelas para a sua execução, como já mencionado anteriormente. A parte manual e onerosa foi realizada por meio do software MATLAB no processo de identificação visual para encontrar os melhores resultados subjetivos.

Similar as imagens aéreas de SR, foram gerados sete recortes das imagens orbitais de SR que contêm feições cartográficas de interesse. No entanto, foram utilizados apenas quatro recortes, pois apresentavam os melhores resultados no processo de restauração. Desses quatro recortes foram gerados 650 de imagens devido a particularidade da técnica de *inpainting* de Azevedo (2019) explicada no parágrafo anterior.

Figura 8 – Imagem do acervo da EOSDA LandViewer com resolução espacial de 3 metros da região de Presidente Prudente.




Fonte: EOSDA LandViewer(2024); elaborado pelo autor (2024).

3.3 Métodos

O principal intuito da pesquisa foi estabelecer métricas que são utilizadas no contexto tradicional de imagens fotográficas e aplicá-las em imagens de SR, levando em consideração a suas particularidades. Para isto, a proposta metodológica consiste em quatro grandes etapas: aplicação das técnicas de *inpainting*, aplicação das métricas, classificação de imagens, e avaliação e análise dos resultados por meio de medidores estatísticos. A Figura 9, sumariza as etapas a serem seguidas para identificar quais métricas podem ser aplicadas no contexto do SR.

Figura 9 – Fluxograma sumarizado das etapas do trabalho, a fim avaliar as imagens por meio das métricas.



3.3.1 Aplicação das técnicas de *inpainting*

Para a aplicação da técnica de *inpainting* de Azevedo (2019) nesta pesquisa, não foi necessário utilizar tratamentos como calibração radiométrica, correção atmosférica e fusão de imagens, que foram essenciais no trabalho de Azevedo (2019). Enquanto Azevedo (2019) focava em resolver problemas relacionados a sombras, exigindo esses tratamentos, o objetivo desta pesquisa é diferente, demandando um procedimento distinto.

Para restaurar as imagens de SR com a técnica de *inpainting* de Azevedo (2019), foi necessário determinar o tamanho de três janelas: *win*, *winsize* e *winLarge*. O parâmetro “*win*” representa o tamanho da janela para preencher o bloco ideal; o “*winsize*” representa o tamanho da janela para escanear a amostra, que é delimitada por “*winLarge*”; e *winLarge* representa o tamanho da janela para determinar a região de amostragem na imagem. Essas janelas estão relacionadas ao preenchimento por blocos através da amostragem dinâmica. A partir disso, foram escolhidos três resultados referentes a técnica de Azevedo (2019) devido as restaurações apresentarem resultados muitos semelhantes.

Para restaurar as imagens, foram inseridos objetos artificiais nas imagens de SR representando as distorções. Antes da aplicação da técnica de Azevedo (2019), foi necessário criar máscaras para remover esses objetos indesejados. Em contrapartida, na técnica de *inpainting* de Baixo (2022), a máscara é desenhada dentro do próprio algoritmo durante o processo de restauração da imagem.

3.3.2 Aplicação das métricas quantitativas

Com as imagens restauradas pelas duas técnicas de *inpainting* supracitada, foram feitas duas avaliações. A primeira avaliação, avaliação experimental, consiste em analisar os resultados do processo de qualidade numérica das restaurações através das métricas mais utilizadas no contexto do SR: MSR, PSNR e SSIM.

Com base nas buscas realizadas nos referencias teóricos, outras três métricas foram aplicadas no processo de verificação da qualidade da restauração. Assim, a outra avaliação consiste em analisar os resultados das três métricas mais utilizadas no contexto do SR juntos de outras três métricas, sendo duas delas aplicadas em contexto de imagens fotográficas convencionais: DISTS e VSI.

Por fim, os resultados das seis métricas foram comparadas com a análise subjetiva com o intuito de verificar assertividade dos valores numéricos em relação a restauração visual após a aplicação das técnicas de *inpainting*. Em relação a análise subjetiva, para avaliação experimental, apenas um agente humano foi necessário para ranquear as imagens dos resultados mais satisfatórios aos menos satisfatórios ou piores.

As métricas apresentadas no Quadro 1 serviram de apoio na seleção das métricas voltadas às necessidades do tratamento das imagens de SR. A priori, foram utilizados as seguintes métricas: FSIM, VSI e DISTS.

Cada uma dessas métricas possui características e vantagens específicas como:

- i) A métrica FSIM apoia-se em características estruturais da imagem, como bordas, texturas e padrões, considerando informações espaciais. Além disso, compreende modelos de percepção visual, ou seja, como o ser humano recebe e percebe as estruturas nas imagens;
- ii) A métrica VSI tem como base uma modelagem da percepção humana, ou seja, como indivíduos percebem e avaliam a qualidade visual da imagem, considerando contraste, ruídos e cores entre as duas imagens. Além disso, consegue reconhecer as regiões de maior significância nas imagens, o que a torna uma métrica muito importante a ser aplicada como medida de avaliação quantitativa no processo de validação de imagens no contexto do SR;
- iii) A métrica DISTS utiliza de análises estatísticas das diferenças entre as duas imagens, e calcula a similaridade entre elas, considerando características visuais e estatísticas. Essa métrica, foi desenvolvida para avaliar apenas imagens RGB. Como a imagem analisada tinha quatro bandas, houve a necessidade de adaptá-la para analisar os resultados.

3.3.3 Classificação de imagens de SR

As imagens de SR foram classificadas no software ENVI 4.8 antes e depois da aplicação das métricas de forma a mensurar o impacto do *inpainting* em tarefas clássicas, por exemplo, classificação de imagens.

O classificador não supervisionado k-médias (*K-means*) foi aplicado à imagem de SR. O classificador K-médias foi escolhido devido à sua interpretabilidade e simplicidade de compreensão das classes. Além disso, é um dos classificadores mais utilizados, sendo aplicado em mais de 40 mil artigos de renome da área científica (IKOTUN et al., 2023).

Nesse sentido, foram utilizados três indicadores de qualidade para validação de Tsai (2006): P_c (taxa de acurácia do produtor), Equação (36); U_c (taxa de acurácia do usuário), Equação (37) e τ (taxa de acurácia global), Equação (38), que são métricas clássicas da literatura de classificação de imagens.

$$P_c = \frac{TP}{TP+FN} \quad (36)$$

$$U_c = \frac{TP}{TP+FP} \quad (37)$$

$$\tau = \frac{TP+TN}{TP+TN+FP+FN} \quad (38)$$

Nas equações acima, tem-se: TP - *True Positive* (Verdadeiro Positivo), TN - *True Negative* (Verdadeiro Negativo), FP - *False Positive* (Falso Positivo) e FN - *False Negative* (Falso Negativo) (TSAI, 2006). Posteriormente, com o intuito de validar a metodologia, um novo conjunto de imagens de SR foi testado.

3.3.4 Análise e validação das métricas por meio de medidores estatísticos

A restauração por meio de técnicas de *inpainting* foi avaliada aplicando seis métricas de avaliação a imagens de alta resolução espacial de SR, criando um sólido referencial para validação das métricas.

Dois coeficientes de correlação também foram utilizados como critérios de avaliação: o SRCC e o KRCC. O SRCC foi calculado para verificar a correlação entre a análise qualitativa e quantitativa, ou seja, a análise visual/subjetiva das métricas. Além disso, foram realizadas comparações qualitativas para cada métrica de avaliação: MSE, PSNR, SSIM, FSIM, VSI e DISTs.

Para avaliar a questão subjetiva das escolhas dos melhores resultados na imagens orbitais de SR, foi realizada uma análise qualitativa entre os agentes humanos, o KRCC foi aplicado como parte da análise. Para a inspeção com KRCC, dois usuários foram convidados a classificar as imagens na tela de um monitor de acordo com a melhor restauração do ponto de vista subjetivo/visual após a aplicação do *inpainting*. Ambos os usuários são estudantes de doutorado no Programa de Pós-graduação em Ciências Cartográficas (PPGCG), sendo um deles da área de Geodésia e o outro, é da área de Sensoriamento Remoto. O objetivo é investigar se as métricas quantitativas existentes são compatíveis ou não com os resultados visuais/qualitativos para características básicas presentes em imagens de SR. A escolha de apenas dois usuários se deram pelo fato do coeficiente de correlação de *Kendall* comumente avaliar concordância ou discordantes entre duas variáveis qualitativas.

As reconstruções via *inpainting* foram avaliadas por meio de seis métricas, aplicadas nas imagens de SR de alta resolução espacial, a fim de se criar um *benchmark*

a partir do uso dessas métricas. A partir dos resultados da avaliação das métricas nas imagens restauradas pelas técnicas de *inpainting* de Azevedo (2019) e Baixo (2022) junto com os indicadores de qualidade responsável por avaliar as classificações de imagens, foram capazes de indicar métricas potenciais a serem utilizadas no contexto de SR.

4. RESULTADOS E DISCUSSÃO

Nesta seção são apresentados os resultados da aplicação das técnicas de *inpainting* aplicadas neste projeto em imagens remotamente detectadas. Também se apresenta uma comparação entre as métricas existentes na literatura, como: MSE, PSNR e SSIM. Como objetivo central, propõe-se investigar se as métricas quantitativas existentes são compatíveis ou não com os resultados visuais qualitativos para determinadas características presentes em imagens de SR.

4.1 Avaliação experimental

Nesta seção foram conduzidos testes e análises experimentais para avaliar o desempenho das métricas clássicas no contexto do SR. Esses experimentos foram realizados em imagens aéreas com o objetivo de verificar se as métricas eram capazes de fornecer resultados numéricos coerentes com as restaurações realizadas por meio das técnicas de *inpainting* de Azevedo (2019) e Baixo (2022). O experimento utilizou um conjunto de imagens contendo feições cartográficas, incluindo feições curvilíneas e diferentes texturas, conforme apresentado no Quadro 4.

O Quadro 4 apresenta as imagens originais utilizadas e suas respectivas máscaras de reconstrução, isto é, domínios de aplicação das técnicas de *inpainting*, que visam simular objetos artificiais em recortes de imagens de SR. Dos quatro resultados, Resultado 1 ao Resultado 4, os três primeiros correspondem à aplicação da técnica proposta por Azevedo ou Azd (2019), e o último é o resultado da aplicação da técnica de Baixo ou Bax (2022). No Quadro 5 são apresentadas as janelas de alocação de cada uma das imagens de A à E para os três resultados aplicados pela técnica de Azevedo (2019). A escolha desses três resultados para análise das métricas deve-se ao fato de que alguns apresentaram restaurações muito semelhantes. Vale ressaltar que esses resultados foram considerados os melhores do ponto de vista subjetivo.

A fim de eliminar a questão da subjetividade humana, foram implementadas e aplicadas três métricas de validação supracitadas. A partir dos resultados gerados, foi possível constatar que as métricas não conseguiram, de uma forma geral, traduzir em termos numéricos os resultados obtidos em algumas das imagens amostradas, devido ao

fato delas não considerarem em seus cálculos, certas características específicas em imagens digitais, como a presença de textura.

Quadro 4 – Visão geral das imagens aéreas de SR.

Resultados	Recortes de imagens				
	A	B	C	D	E
Imagem original					
Objeto artificial					
1 (Azd, 2019)					
2 (Azd, 2019)					
3 (Azd, 2019)					
4 (Bax, 2022)					

Quadro 5 – Parâmetros relacionados a janela de alocação para a reconstrução das imagens aéreas de SR da técnica de inpainting de Azevedo (2019).

Imagens	Resultados	<i>Win</i>	<i>Winsize</i>	<i>WinLarge</i>
A	1	7	9	113
	2	7	9	125
	3	9	11	65
B	1	7	9	75
	2	3	5	35
	3	3	5	71
C	1	7	9	65
	2	7	9	95
	3	9	11	115
D	1	5	7	39
	2	5	7	41
	3	7	9	35
E	1	3	5	59
	2	5	7	45
	3	9	11	45

Na Tabela 2, são apresentados os valores das métricas MSE, PSNR e SSIM para cada uma das imagens reconstruídas referentes a imagem A, bem como uma avaliação qualitativa realizada a partir de um agente humano, ranqueando cada um dos resultados de acordo com seus critérios subjetivos. Em destaque, na cor vermelha, tem-se os melhores resultados, tanto numericamente quanto em termos de seleção visual, e em destaque, na cor azul, indica-se o segundo melhor resultado.

A partir da Tabela 2, foi possível verificar que o resultado 4 apresentou as melhores métricas quantitativas, porém, em termos visuais, tal imagem reconstruída apresentou o resultado menos satisfatório. Em vista disso, surge naturalmente a seguinte

pergunta: “*Por que a métrica indicou este como melhor resultado?*” Isso pode ser justificado pelo fato da técnica de *inpainting* de Baixo (2022) suavizar a imagem e não preservar padrões de texturas.

Ao analisar apenas os valores das métricas de qualidade, estas métricas sugerem que os melhores resultados ocorrem quando os alvos são excessivamente suavizados, embora na inspeção humana, o resultado possa parecer artificial. De fato, é notório, em termos visuais, que a imagem não foi reconstruída de maneira adequada, pois ao se observar pelo ponto de vista qualitativo, foi o resultado menos satisfatório, já que reproduziu uma distorção/desfoque na imagem.

Por outro lado, a métrica SSIM, em destaque azul, apresentou o segundo melhor resultado em comparação com o resultado subjetivo. Como a métrica SSIM é baseada em estrutura, conseguiu aferir um resultado mais condizente com a natureza visual humana para essa imagem em particular, embora esse não seja um comportamento predominante, ao se considerar outras características específicas de imagens de SR.

Tabela 2 - Análise Quantitativa X Qualitativa da imagem A.

Imagem Original		Imagem com o Objeto Artificial			
					
Imagens		Método de avaliação quantitativo			Método de avaliação qualitativo
		MSE	PSNR	SSIM	Escolha subjetiva da melhor imagem
Resultado 1 (Azd, 2019)		1056,7	17,9	0,9690	1 ^a
Resultado 2 (Azd, 2019)		1126,2	17,2	0,9684	2 ^a
Resultado 3 (Azd, 2019)		1007,8	18,1	0,9677	3 ^a
Resultado 4 (Bax, 2022)		995,4	18,2	0,9766	4 ^a

A Tabela 3 apresenta quatro resultados, sendo que os três primeiros resultados são da aplicação da técnica elaborada por Azevedo (2019), enquanto o último contempla a aplicação da técnica de Baixo (2022). Com resultados semelhantes ao da Tabela 2, as quatro métricas apontaram que a “melhor reconstrução” foi aquela alcançada no Resultado 4, embora, sob o aspecto visual, também tenha apresentado um resultado qualitativo menos satisfatório.

Dessa vez, foi possível observar que as imagens na Tabela 3, reconstruídas pelo método criado por Azevedo (2019), obtiveram uma pequena alteração nos níveis de cinza, tornando os três primeiros resultados diferentes da imagem original. Tal comportamento pode explicar o “porquê” do Resultado 4 ter-se apresentado como o melhor resultado, numericamente, por não ter sofrido mudanças abruptas (contraste) ao longo do processo de reconstrução da imagem.

Tais resultados evidenciam que tomar como parâmetro apenas a avaliação numérica, sem fundamentação de uma métrica adequada, pode levar a conclusões equivocadas com relação aos resultados qualitativos, já que visam preservar o aspecto natural da imagem. Por exemplo, os Resultados 1 e 3 da Tabela 3 apresentaram os melhores resultados qualitativos, ou seja, melhor reconstrução visual, embora, as métricas não correspondam à avaliação humana para essas reconstruções. Logo, outra pergunta também surge, naturalmente, nesse contexto: *“é melhor tomar como parâmetro uma avaliação qualitativa ou uma avaliação quantitativa?”* Dentro do contexto do SR, o método de avaliação qualitativa é uma importante ferramenta de análise, pois considera o resultado esperado conforme a interpretação humana. Por outro lado, avaliar grandes conjuntos de imagens pode se tornar uma tarefa exaustivamente árdua ou, até mesmo, impraticável para um agente humano, o que leva à necessidade de sistematizar o processo avaliativo por meio do emprego de medidas numéricas.

Na sequência, apresentam-se nas Tabelas 4 e 5, os resultados numéricos e qualitativos de uma imagem com feições cartográficas como vias e uso da terra. É possível visualizar que as métricas coincidem com a análise visual, apesar dos valores muito próximos entre o primeiro e o segundo “melhor” resultado. A partir dos resultados, levanta-se o seguinte questionamento: *“por que uma métrica quantitativa pode indicar um resultado mais preciso para uma imagem do que para outra?”* Vale ressaltar que as métricas propostas na literatura geral de *inpainting* não foram concebidas para avaliar padrões e determinadas particularidades de imagens remotamente detectadas, isto é, não

consideram características específicas de imagens SR, tais como padrões, e sim, para fotografias tradicionais de lugares, pessoas e paisagens em geral.

No próximo exemplo (Tabela 6), foi analisada uma imagem com uma via e uma região de textura obstruída. A partir dos resultados obtidos com as técnicas de *inpainting* e uso das métricas e avaliação humana, é possível inspecionar que, nesse caso em particular, o resultado da escolha subjetiva e o resultado do método quantitativo foram os mesmos.

Tabela 3 - Análise Quantitativa X Qualitativa da imagem B.


Imagem Original		Imagem com o Objeto Artificial			
					
Imagens		Método de avaliação quantitativo			Método de avaliação qualitativo
		MSE	PSNR	SSIM	Escolha subjetiva da melhor imagem
Resultado 1 (Azd, 2019)		923,7	18,5	0,9096	1ª
Resultado 2 (Azd, 2019)		806,5	19,1	0,9128	3ª
Resultado 3 (Azd, 2019)		1028,5	18,0	0,9080	2ª
Resultado 4 (Bax, 2022)		176,62	25,66	0,9442	4ª

Tabela 4 - Análise Quantitativa X Qualitativa da imagem C.


Imagem Original		Imagem com o Objeto Artificial			
					
Imagens		Método de avaliação quantitativo			Método de avaliação qualitativo
		MSE	PSNR	SSIM	Escolha subjetiva da melhor imagem
Resultado 1 (Azd, 2019)		205,6	25,0	0,9776	1ª
Resultado 2 (Azd, 2019)		444,9	21,6	0,9756	3ª
Resultado 3 (Azd, 2019)		187,9	25,4	0,9779	2ª
Resultado 4 (Bax, 2022)		2553,7	14,1	0,9628	4ª

Tabela 5 - Análise Quantitativa X Qualitativa da imagem D.

Imagem Original		Imagem com o Objeto Artificial			
					
Imagens		Método de avaliação quantitativo			Método de avaliação qualitativo
		MSE	PSNR	SSIM	Escolha subjetiva da melhor imagem
Resultado 1 (Azd, 2019)		931,0	18,4	0,9828	2 ^a
Resultado 2 (Azd, 2019)		1132,7	17,6	0,9820	1 ^a
Resultado 3 (Azd, 2019)		1321,2	16,9	0,9812	3 ^a
Resultado 4 (Bax, 2022)		4923,3	11,2	0,9754	4 ^a

Tabela 6 - Análise Quantitativa X Qualitativa da imagem E.

Imagem Original		Imagem com o Objeto Artificial			
					
Imagens		Método de avaliação quantitativo			Método de avaliação qualitativo
		MSE	PSNR	SSIM	Escolha subjetiva da melhor imagem
Resultado 1 (Azd, 2019)		686,0	19,8	0,9675	1 ^a
Resultado 2 (Azd, 2019)		842,5	18,9	0,9662	2 ^a
Resultado 3 (Azd, 2019)		735,2	19,5	0,9666	3 ^a
Resultado 4 (Bax, 2022)		739,3	19,4	0,9574	4 ^a

Com base nos resultados sumarizados nas tabelas anteriores, as quais contêm as imagens e as métricas de validação computadas, foi elaborada a Tabela 7, contendo apenas o valores (escores) médio referente às três métricas por imagem, e o Quadro 6, para comparar os resultados quantitativos com os qualitativos, isto é, com base no julgamento humano. Assim, a partir desses valores, foi computado o desvio padrão (DP) para cada métrica a fim de auxiliar na análise dos resultados.

Tabela 7 - Análise média das imagens e suas respectivas métricas.

Imagens		MSE	PSNR	SSIM
A	1	1056,7	17,9	0,9690
	2	1226,2	17,2	0,9684
	3	1007,8	18,1	0,9677
	4	995,4	18,2	0,9766
Média		1071,52	17,85	0,9704
DP		106,46	0,42	0,0042
B	1	923,7	18,5	0,9096
	2	806,5	19,1	0,9128
	3	1028,5	18,0	0,9080
	4	176,6	25,7	0,9442
Média		733,85	20,30	0,9187
DP		382,39	3,60	0,0171
C	1	205,6	25,0	0,9776
	2	444,9	21,6	0,9756
	3	187,9	25,4	0,9779
	4	2553,7	14,1	0,9628
Média		848,03	21,52	0,9735
DP		1143,14	5,25	0,0072
D	1	931,0	18,4	0,9828
	2	1132,7	17,6	0,9820
	3	1321,2	16,9	0,9812
	4	4923,3	11,2	0,9754
Média		2077,05	16,04	0,9804
DP		1904,18	3,28	0,0034
E	1	686,0	19,8	0,9675
	2	842,5	18,9	0,9662
	3	735,2	19,5	0,9666
	4	739,3	19,4	0,9574
Média		750,77	19,39	0,9644
DP		65,79	0,37	0,0047

Os valores em destaque em vermelho na Tabela 7 indicam que eles ficaram fora do desvio padrão. As técnicas de *inpainting* aplicadas, a de Baixo (2022), é representada na última linha de cada imagem, resultou nos valores menos satisfatórios para a métrica PSNR, se comparada à técnica de *inpainting* proposta por Azevedo (2019). Isso ocorreu porque a técnica proposta por Baixo (2022) tende a suavizar excessivamente as imagens, o que pode gerar resultados visualmente incoerentes e artificiais.

Para fornecer uma síntese comparativa entre os valores quantitativos e a percepção visual, foi elaborado o Quadro 6, a fim de compreender quais métricas apresentaram os melhores resultados numéricos em comparação com a análise subjetiva após a restauração das imagens. As colunas representam as três métricas, enquanto as linhas representam as cinco imagens. O valor zero (0) indica que houve discordância entre a análise quantitativa e a análise qualitativa, o valor um (1) indica que a análise quantitativa correspondeu à melhor opção na análise visual, e o valor dois (2) indica que a análise quantitativa correspondeu à segunda melhor opção na análise qualitativa.

Quadro 6 - Análise qualitativa relacionada aos acertos das métricas quantitativas.

Imagens	MSE	PSNR	SSIM
A	0	0	2
B	0	0	0
C	2	2	2
D	2	2	2
E	1	1	1

Os resultados 4, das Tabelas 2 e 3, apresentaram os melhores resultados em todas as métricas. No entanto, quando comparadas ao Quadro 6 de análise qualitativa, a imagem A só obteve um acerto em relação à métrica SSIM. Já a imagem E apresentou o melhor resultado quantitativo na primeira opção em todas as métricas, comparando-se ao método qualitativo. Esses resultados reforçam a teoria de que nem sempre os melhores resultados quantitativos refletem os melhores resultados qualitativos. Entretanto, é necessário que ambas as análises “*caminhem paralelamente*”, para identificar os resultados que melhor exprimem a realidade, padrões e características específicas no contexto de imagens de SR na área da Cartografia.

A partir da avaliação experimental, foi possível perceber que as métricas clássicas utilizadas no contexto de SR não conseguiram avaliar de maneira assertiva relação entre os valores numéricos e análise subjetiva. Em grande parte dos resultados

foram notadas algumas divergências, exceto a imagem E que conseguiu apresentar os mesmos resultados do ponto de vista visual e numérico.

4.2 Análise estatística em imagens de SR

A fim de comparar os resultados das métricas clássicas da literatura no contexto do SR e as métricas desenvolvidas e aplicadas no contexto das imagens fotográficas digitais das últimas décadas, foram aplicadas as técnicas de *inpainting* de Azevedo (2019) e Baixo (2022). As seis métricas (MSE, PSNR, SSIM, FSIM, VSI e DISTs) foram aplicadas em um conjunto de imagens aéreas e orbitais de SR com características curvilíneas, diferentes texturas e resolução espacial.

4.2.1. Avaliação estatística entre métricas de qualidade e percepção visual em imagens aéreas de SR

Para eliminar o problema da subjetividade humana, todas as seis métricas de validação foram aplicadas na imagem A (Figura 10). A Tabela 8 apresenta os resultados das métricas obtidos por meio das técnicas de *inpainting* nas imagens de SR aéreas com resolução espacial de 45 centímetros. As setas incluídas a cada métrica nas tabelas indicam as direções dos melhores resultados.

A partir da avaliação desses resultados, como apresentado na Figura 10, constatou-se que as métricas clássicas (MSE, PSNR e SSIM) geralmente não conseguem traduzir os resultados obtidos em termos numéricos para algumas das imagens amostradas, uma vez que não consideram certas características específicas presentes em imagens digitais, como textura. A Tabela 8 apresenta os valores (escores) das seis métricas de avaliação para cada imagem reconstruída, juntamente com o exame qualitativo realizado por um agente humano, que classificou os resultados de acordo com seus critérios subjetivos.

As métricas MSE e PSNR apresentaram resultados semelhantes, porém divergente das outras métricas. Na verdade, pode-se verificar que, em termos visuais, a imagem não foi reconstruída adequadamente, reproduzindo uma distorção/borrão como parte da imagem. No entanto, as métricas SSIM, FSIM, VSI e DISTs indicaram resultados coerentes em comparação à análise subjetiva. Dessa forma, o SRCC demonstrou ser perfeito tanto entre as métricas quanto entre a análise qualitativa (1,0).

Figura 10 – (a) imagem aérea A de referência, (b) imagem com objeto artificial, (c) - (e) técnica de *inpainting* de Azevedo (2019), e (f) técnica de *inpainting* de Baixo (2022).




Tabela 8 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.

	Fig. 10(c)	Fig. 10(d)	Fig. 10(e)	Fig. 10(f)
MSE ↓	3	4	2	1
PSNR ↑	3	4	2	1
SSIM ↑	1	2	3	4
FSIM ↑	1	2	3	4
VSI ↑	1	2	3	4
DISTS ↓	1	2	3	4
Score Subjetivo	1	2	3	4
MSE ↓	1056,7	1226,2	1007,8	995,4
PSNR ↑	17,9	17,2	18,1	18,2
SSIM ↑	0,9690	0,9684	0,9677	0,9766
FSIM ↑	0,9826	0,9807	0,9806	0,9785
VSI ↑	0,9943	0,9937	0,9935	0,9893
DISTS ↓	0,0365	0,0387	0,0457	0,0481

O experimento da imagem B, Figura 11, apresenta os resultados das técnicas de *inpainting* em feições curvilíneas. Na Tabela 9, é possível observar que tanto a DISTS quanto a VSI apresentaram resultados satisfatório e com correlações compatíveis com as análises subjetivas comparadas às métricas clássicas.

As métricas clássicas, como PSNR e SSIM, apontaram a Figura 11(f) como a de melhor resultado. Apenas a métrica VSI conseguiu capturar o melhor e o pior resultado em linha com o ponto de vista qualitativo, enquanto a DISTS só conseguiu determinar o melhor resultado. Como mencionado anteriormente, a técnica de Baixo (2022) suaviza a imagem, o que dificulta que as métricas forneçam resultados coerentes com a realidade.

Houve uma correlação alta de 0,8 entre a DISTS e a VSI. Por meio do SRCC, as métricas MSE e a DISTS tiveram uma correlação alta com análise subjetiva de 0,8, enquanto a VSI apresentou uma correlação perfeita de 1,0. São duas métricas promissoras a serem utilizadas no contexto do SR.

Figura 11 – (a) imagem aérea B de referência, (b) imagem com objetos artificiais, (c) - (e) técnica de *inpainting* de Azevedo (2019), e (f) técnica de *inpainting* de Baixo (2022).



(a)



(b)



(c)



(d)



(e)



(f)

Tabela 9 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.

	Fig. 11(c)	Fig. 11(d)	Fig. 11(e)	Fig. 11(f)
MSE ↓	3	2	4	1
PSNR ↑	3	2	4	1
SSIM ↑	4	2	3	1
FSIM ↑	2	3	4	1
VSI ↑	1	3	2	4
DISTS ↓	1	4	2	3
Score Subjetivo	1	3	2	4
MSE ↓	923,7	806,5	1028,5	176,62
PSNR ↑	18,5	19,1	18	25,66
SSIM ↑	0,9096	0,9128	0,9080	0,9442
FSIM ↑	0,9495	0,9487	0,9441	0,9508
VSI ↑	0,9853	0,9829	0,9841	0,9736
DISTS ↓	0,093	0,1342	0,1042	0,111

Referente ao experimento da imagem C, Figura 12, do ponto de vista numérico, as métricas MSE, PSNR e SSIM classificaram as imagens sob um mesmo prisma (Tabela 10), isto é, considerando o coeficiente de correlação de *Spearman*, apresentaram uma correlação perfeita entre si, de 1,0. As métricas DISTS e VSI foram capazes de identificar tanto os piores quanto os melhores resultados em relação à análise subjetiva. Ao comparar a métrica VSI e a DISTS com as outras métricas, os resultados foram divergentes.

A métrica VSI apresentou uma correlação perfeita apenas com a métrica FSIM (1,0), enquanto a DISTS apresentou uma correlação alta de 0,8 com as outras métricas. No entanto, a DISTS foi a única métrica que coincidiu todos os resultados subjetivos com os resultados numéricos, apresentando uma correlação perfeita de 1,0. Tanto a DISTS quanto a VSI apresentaram resultados satisfatórios e obtiveram comportamentos semelhantes com às métricas clássicas, chegando até a superá-las em alguns casos.

Figura 12 – (a) imagem aérea C de referência, (b) imagem com objeto artificial, (c) - (e) técnica de *inpainting* de Azevedo (2019), e (f) técnica de *inpainting* de Baixo (2022).




Tabela 10 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.

	Fig. 12(c)	Fig. 12(d)	Fig. 12(e)	Fig. 12(f)
MSE ↓	2	3	1	4
PSNR ↑	2	3	1	4
SSIM ↑	2	3	1	4
FSIM ↑	1	2	3	4
VSI ↑	1	2	3	4
DISTS ↓	1	3	2	4
Score Subjetivo	1	3	2	4
MSE ↓	205,6	444,9	187,9	2553,7
PSNR ↑	25,0	21,6	25,4	14,1
SSIM ↑	0,9776	0,9756	0,9779	0,9628
FSIM ↑	0,9864	0,9789	0,9779	0,9641
VSI ↑	0,9961	0,994	0,9884	0,9737
DISTS ↓	0,0078	0,0128	0,0104	0,0445

Ao analisar o experimento apresentado na imagem D, Figura 13, com o apoio da Tabela 11, todas as métricas conseguiram identificar os resultados menos satisfatórios. No entanto, nem todas as métricas conseguiram identificar o melhor resultado em comparação à análise visual. Apenas as métricas DISTS e a FSIM conseguiram apresentar uma correlação perfeita com o resultado qualitativo. As métricas MSE, PSNR, SSIM e VSI apresentaram o mesmo resultado entre si, com uma correlação perfeita de 1,0. Já em relação à métrica DISTS, a correlação foi alta, com o SRCC de 0,8. Consequentemente, o SRCC entre a DISTS e a análise subjetiva foi igual a 1, e o SRCC entre a VSI e a análise subjetiva foi de 0,8. Essa pequena diferença no SRCC deve-se à inversão entre a primeira e a segunda posições.

Figura 13 – (a) imagem aérea D de referência, (b) imagem com objeto artificial, (c) - (e) técnica de *inpainting* de Azevedo (2019), e (f) técnica de *inpainting* de Baixo (2022).




Tabela 11 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.

	Fig. 13(c)	Fig. 13(d)	Fig. 13(e)	Fig. 13(f)
MSE ↓	1	2	3	4
PSNR ↑	1	2	3	4
SSIM ↑	1	2	3	4
FSIM ↑	2	1	3	4
VSI ↑	1	2	3	4
DISTS ↓	2	1	3	4
Score Subjetivo	2	1	3	4
MSE ↓	931,0	1132,7	1321,2	4923,3
PSNR ↑	18,4	17,6	16,9	11,2
SSIM ↑	0,9828	0,9820	0,9812	0,9754
FSIM ↑	0,9896	0,9900	0,9891	0,9810
VSI ↑	0,9952	0,9950	0,9948	0,9776
DISTS ↓	0,0245	0,0242	0,0247	0,3475

O experimento referente à imagem E, Figura 14, apresenta os resultados das técnicas de *inpainting* em feições curvilíneas e texturas como a vegetação. Na Tabela 12, é possível observar que tanto a DISTS quanto a VSI apresentaram resultados e correlações compatíveis com as análises subjetivas. Além disso, apresentam resultados coerentes com algumas das métricas clássicas, como SSIM e FSIM.

Para a imagem da Figura 13, todas as métricas conseguiram encontrar o melhor resultado. No entanto, as métricas MSE e PSNR não conseguiram encontrar o pior resultado em relação à análise subjetiva. O SRCC entre VSI e a DISTS foi perfeita (1,0) e com as métricas SSIM e FSIM e obteve uma correlação perfeita de 1,0. Comparados à análise subjetiva, as métricas VSI, DISTS, SSIM e FSIM apresentam correlação perfeita. Esses resultados mostram que essas métricas conseguem ser aplicadas e avaliadas tanto em contexto de imagens fotográficas quanto em imagens de SR, que contém feições cartográficas.

Figura 14 – (a) imagem aérea E de referência, (b) imagem com objetos artificiais, (c) - (e) técnica de *inpainting* de Azevedo (2019), e (f) técnica de *inpainting* de Baixo (2022).




Tabela 12 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.

	Fig. 14(c)	Fig. 14(d)	Fig. 14(e)	Fig. 14(f)
MSE ↓	1	4	2	3
PSNR ↑	1	4	2	3
SSIM ↑	1	3	2	4
FSIM ↑	1	3	2	4
VSI ↑	1	3	2	4
DISTS ↓	1	3	2	4
Score Subjetivo	1	3	2	4
MSE ↓	686	842,5	735,2	739,3
PSNR ↑	19,8	18,9	19,5	19,4
SSIM ↑	0,9675	0,9662	0,9666	0,9574
FSIM ↑	0,9853	0,9836	0,9839	0,9672
VSI ↑	0,9961	0,9956	0,9958	0,9868
DISTS ↓	0,0185	0,0207	0,0189	0,0897



4.2.2. Avaliação estatística entre métricas de qualidade e percepção visual em imagens orbitais de SR

As seis métricas também foram aplicadas no processo de avaliação de imagens multiespectrais de SR orbital da *Planet*, com resolução espacial de 3 metros. Neste contexto, as métricas avaliaram o processo de reconstrução das feições cartográficas nas imagens por meio da técnica de *inpainting*, considerando características de imagens de SR, como texturas, padrões e feições curvilíneas. No entanto, após a análise dos resultados das métricas nas imagens aéreas de SR, decidiu-se utilizar apenas a técnica de Azevedo (2019) no processo de restauração das imagens. Esta decisão foi tomada devido aos resultados insatisfatórios obtidos com a aplicação da técnica de Baixo (2022), tanto em termos de métricas quanto de análise subjetiva.

Na análise em imagens orbitais de SR, a técnica de *inpainting* foi aplicada apenas em quatro recortes, pois estes representaram os melhores processos de restauração, conforme mostrado no Quadro 7. No Quadro 8 são apresentadas as janelas de alocação

de cada uma das imagens de F a G para os quatro resultados e para I foram apenas três resultados aplicados pela técnica de Azevedo (2019).

Quadro 7 – Visão geral das imagens orbitais de SR.

Imagem original				
Objeto artificial				
Resultado 1				
Resultado 2				
Resultado 3				
Resultado 4				
Imagens	F	G	H	I

Quadro 8 – Parâmetros relacionados a janela de alocação para a reconstrução das imagens orbitais de SR da técnica de *inpainting* de Azevedo (2019).

Imagens	Resultados	Win	Winsize	WinLarge
A	1	9	11	63
	2	9	11	75
	3	9	11	85
	4	9	11	95
B	1	7	9	75
	2	7	9	145
	3	7	9	185
	4	9	11	65
C	1	9	11	55
	2	9	11	45
	3	9	11	65
	4	9	11	35
D	1	5	7	101
	2	9	11	57
	3	9	11	95

Nesta parte da pesquisa, as métricas avaliaram a restauração da técnica de *inpainting* em imagens de SR orbital. A partir dos quatro recortes foram gerados um conjunto de dados com aproximadamente 650 imagens devido a janela de alocação da técnica de *inpainting* de Azevedo (2019). Destas, foram selecionadas os melhores resultados do ponto de vista subjetivo, considerando a imagem original de cada uma e comparando-as em relação a cada detalhe da restauração, como alteração de texturas, cores, formas e feições curvilíneas.

Para avaliar a questão subjetiva dos usuários em relação às reconstruções das imagens, após utilização da técnica de *inpainting*, foi aplicada a correlação de *Kendall*

entre os usuários, para reforçar os resultados, com relação aos melhores e piores. Isso ocorreu porque cada usuário possui sua própria acuidade visual, ou seja, capacidade de percepção. Dessa maneira, os dois usuários classificaram as imagens do melhor para o pior resultado, ver Quadro 9. A escolha de apenas dois usuários deve-se ao fato de que o coeficiente de *Kendall* geralmente mede a correlação apenas entre duas variáveis. Além disso, aplicação desse coeficiente apenas nos conjuntos de imagens orbitais de SR se justificou pelo fato das restaurações terem sido muito semelhantes.

Quadro 9 – Classificação das imagens de SR orbital do melhor e pior resultados entre os usuários.

Figuras	Imagens	Usuário 1	Usuário 2
15	F	4	4
		2	1
		1	2
		3	3
16	G	4	4
		3	2
		2	3
		1	1
17	H	1	1
		2	2
		3	3
		4	4
18	I	1	1
		3	2
		2	3

Ao analisar o Quadro 9, os participantes demonstraram habilidades consistentes em identificar os melhores e os piores resultados em quase todas as imagens apresentadas. Entretanto, uma pequena divergência foi observada especificamente na imagem I, na qual apenas o melhor resultado foi claramente identificado, enquanto a avaliação do resultado menos satisfatório apresentou alguma incerteza.

Uma peculiaridade foi observada nas imagens F e G, ocorrendo uma inversão entre a segunda e a terceira posições. Essa inversão pode ser atribuída às variações sutis e praticamente imperceptíveis entre as imagens. Portanto, a utilização de métricas de

qualidade torna-se essencial para identificar e analisar essas diferenças mais detalhadamente. Por outro lado, na imagem H, as restaurações são mais proeminentes e perceptíveis; isso possibilitou aos participantes discernir com mais clareza quais resultados eram considerados os melhores e os piores. Como consequência, foi observada uma consonância significativa entre as avaliações dos usuários 1 e 2.

Considerando o Quadro 9 como um todo, houve uma discrepância moderada nas avaliações da imagem I, indicando alguma variação nas percepções dos participantes. Por outro lado, uma concordância perfeita foi alcançada na avaliação da imagem H, sugerindo uma uniformidade de opiniões entre os participantes. Quanto às imagens F e G, a inversão entre a segunda e a terceira posição resultou em uma concordância moderada entre as avaliações dos participantes. Por fim, foi adotado o arqueamento subjetivo nas tabelas com base nas avaliações do Usuário 1, devido ao seu maior domínio em imagens de SR.


Uma outra maneira de determinar quais são as métricas de qualidade mais adequadas ao contexto do SR foi por meio da análise do SRCC. Esse coeficiente foi aplicado entre as seis métricas de qualidade e a análise subjetiva. Além disso, as métricas DISTS e a métrica VSI, consideradas promissoras, foram analisadas em conjunto às outras métricas.

Com relação ao experimento da imagem F, Figura 15, a Figura 15(c) apresentou o resultado menos satisfatório. Apesar do encontro da estrada e da vegetação estar bem restaurado, resultando em um leve deslocamento, como se pode perceber em relação à imagem original, onde a restauração não foi executada com precisão. Em contrapartida, a Figura 15(f) foi classificada como o terceiro melhor resultado, principalmente devido a uma restauração mais completa se comparada à Figura 15(c). Nesse caso, apenas um dos lados da estrada foi reconstruído, demonstrando uma melhoria em relação à Figura 15(c), embora ainda haja margem para aprimoramento.

Figura 15 – (a) imagem orbital F de referência, (b) imagem com objeto artificial, (c) -
(f) técnica de *inpainting* de Azevedo (2019).



(a)



(b)



(c)



(d)



(e)



(f)

Por outro lado, o experimento referente à Figura 15(e) foi ranqueado como o melhor resultado de ponto de vista subjetivo, devido a uma boa restauração das áreas de encontro entre a vegetação e a estrada, bem como da própria estrada. No entanto, o resultado apresentado na Figura 15(d) ficou muito próximo de um resultado tão satisfatório quanto o primeiro; a pequena diferença está em uma feição que foi criada na imagem, que parece ser uma cerca ou parte de uma vegetação um pouco acima do encontro das vegetações com a estrada.

Quanto à análise quantitativa, as métricas conseguiram medir satisfatoriamente os resultados em relação à avaliação subjetiva, conforme evidenciado na Tabela 13. Ao utilizar o SRCC, foi possível mensurar a correlação entre as métricas, considerada perfeita (1,0) dentre quase todas métricas e entre as métricas e a avaliação subjetiva.

Tabela 13 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.

	Fig. 15(c)	Fig. 15(d)	Fig. 15(e)	Fig. 15(f)
MSE ↓	4	2	1	3
PSNR ↑	4	3	1	2
SSIM ↑	4	3	1	2
FSIM ↑	4	2	1	3
VSI ↑	4	2	1	3
DISTS ↓	4	2	1	3
Score Subjetivo	4	2	1	3
MSE ↓	15,424	13,701	13,41	13,794
PSNR ↑	36,248	32,763	36,856	36,733
SSIM ↑	0,9804	0,9808	0,9815	0,9812
FSIM ↑	0,9885	0,9903	0,9906	0,9898
VSI ↑	0,9969	0,9977	0,9978	0,9975
DISTS ↓	0,0155	0,0082	0,0079	0,0097

As métricas VSI e DISTS obtiveram resultados satisfatórios em relação às métricas classificadas, como MSE e FSIM, e uma correlação perfeita (1,0). No entanto, as métricas PSNR e SSIM obtiveram uma correlação alta de 0,8 entre a avaliação subjetiva e entre as métricas VSI e DISTS. Apesar disso, tal métrica conseguiu definir que o

experimento da Figura 15(c), obteve o resultado menos satisfatório e o experimento da Figura 15(e) o melhor resultado.

Por fim, é importante ressaltar que a métrica SSIM inverteu a classificação entre a segunda e a terceira imagens, contrariando as outras métricas e a avaliação subjetiva. Isso se explica pelo fato da métrica SSIM avaliar mais eficazmente as alterações na estrutura da imagem. Por exemplo, no experimento da Figura 15(d), classificado como o segundo melhor resultado, uma nova feição foi criada após a restauração. Portanto, a métrica foi capaz de avaliar mais precisamente a Figura 15(d) em comparação à Figura 15(f).

Ao realizar a avaliação do experimento referente à imagem G, Figura 16, sob uma perspectiva subjetiva, foram consideradas as alterações nas feições, cores e texturas das imagens. O experimento da Figura 16(f) se destacou-se como o mais satisfatório tanto qualitativamente quanto quantitativamente, devido à preservação das características originais da região de cultivo. No entanto, uma observação notável foi a manutenção de uma parte da estrada com a mesma cor até a presença de uma árvore próxima à sua margem. Isso contrasta com a imagem original, onde essa área da estrada exibe duas tonalidades distintas.

Por outro lado, na Figura 16(d), uma parte da vegetação apresentou uma concentração maior em relação à imagem original e a parte da região de cultivo sofreu uma pequena alteração. Acredita-se que uma parte dessa região esteja em fase de crescimento. A técnica de *inpainting* restaurou essa região com base nos pixels da vizinhança, ou seja, restaurou a parte da imagem que continha o objeto artificial, baseando-se na vizinhança. Isso fez com que parte dessa região da vegetação, na região da área de cultivo, se estendesse até a estrada de terra. Situações semelhantes foram identificadas nos experimentos das Figuras 16(c) e 16(e). Nessas imagens, as restaurações não afetaram a cor da estrada, nem a vegetação, apenas promoveram alterações na região de cultivo.

Figura 16 – (a) imagem orbital G de referência, (b) imagem com objeto artificial, (c) -
(f) técnica de *inpainting* de Azevedo (2019).



(a)



(b)



(c)



(d)



(e)



(f)

No que diz respeito à análise quantitativa, conforme apresentado na Tabela 14, as métricas aplicadas conseguiram apresentar, por meio dos resultados numéricos, uma classificação semelhante à do ponto de vista subjetivo, com exceção a métrica DISTS. Esta métrica, indicou o experimento da Figura 16(d) como o de melhor resultado e o experimento da Figura 16(f) como o de resultado menos satisfatório, contrariando o ponto de vista qualitativo. Essa divergência se explica pelo fato da DISTS basear-se, principalmente, em análises estatísticas entre as imagens, sendo menos dependente de uma modelagem direta da percepção humana.

Por outro lado, a métrica VSI, baseada em modelos de percepção humana, apresentou resultados muito próximos em todas as quatro imagens, diferenças mínimas, porém, conseguiu identificar os melhores e os piores resultados. As métricas clássicas da literatura, como o PSNR e o MSE, indicaram o melhor resultado, porém, não conseguiram determinar corretamente o pior resultado em relação à percepção subjetiva. A métrica SSIM conseguiu determinar o melhor resultado, porém o segundo melhor resultado obteve o mesmo valor que o terceiro resultado do ponto de vista numérico. Como a SSIM é uma métrica baseada em estrutura, ambas as imagens conseguiram restaurar muito bem a estrutura, no entanto não conseguiram avaliar a questão de percepção visual como a VSI. A única métrica que apresentou um resultado semelhante ao resultado subjetivo foi a métrica FSIM, que conseguiu identificar o pior e o melhor resultados.

O SRCC mostrou que não houve correlação entre a VSI e a DISTS, tampouco com as outras métricas, nem com a avaliação subjetiva. Apesar de cada métrica ter as suas características específicas nos seus quesitos de avaliação, para determinadas reconstruções, uma métrica vai indicar um resultado melhor do que outra. A métrica VSI apresentou praticamente o mesmo resultado para todas as análises para do experimento da imagem G, Figura 16, ou seja, a métrica concluiu que a reconstrução foi satisfatória em cada resultado baseado na percepção humana. Dessa forma, no processo de avaliação da métrica, uma feição reconstruída em uma imagem acabou sendo “*recompensada*” por uma outra feição reconstruída diferentemente em outra parte da imagem, devido a imagem apresentar dois objetos artificiais.

A métrica FSIM foi a única métrica que apresentou uma correlação alta. A SSIM apresentou uma correlação moderada de 0,6. Vale ressaltar que a métrica FSIM é uma extensão da métrica SSIM, sendo que a FSIM considera características adicionais, como bordas e padrões, o que pode resultar em uma avaliação mais precisa da similaridade entre as imagens.

Tabela 14 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.

	Fig. 16(c)	Fig. 16(d)	Fig. 16(e)	Fig. 16(f)
MSE ↓	2	3	4	1
PSNR ↑	2	3	4	1
SSIM ↑	2	3	2	1
FSIM ↑	4	2	3	1
VSI ↑	2	2	1	1
DISTS ↓	3	1	2	4
Score Subjetivo	4	3	2	1
MSE ↓	3,340	3,668	4,005	3,137
PSNR ↑	42,892	42,485	42,104	43,165
SSIM ↑	0,9922	0,9921	0,9922	0,9926
FSIM ↑	0,9958	0,9960	0,9959	0,9963
VSI ↑	0,9990	0,9990	0,9991	0,9991
DISTS ↓	0,0052	0,0043	0,0046	0,0063

O experimento referente à imagem H, Figura 17, apresentou um resultado no qual foi mais fácil visualizar a restauração das imagens, em relação à classificação das imagens do ponto de vista subjetivo. Apesar dessa imagem ter apresentado dois objetos artificiais, o enfoque principal recaiu sobre a região da estrada, visto que a região da vegetação é muito difícil de visualizar e de dizer qual apresentou o melhor resultado subjetivo. No entanto, os valores quantitativos desempenham um papel crucial na identificação dos melhores resultados em situações com essas particularidades.

O experimento da Figura 17(c) foi considerado o melhor resultado sob a óptica subjetiva. Em relação aos resultados estatísticos, apenas a métrica FSIM conseguiu classificar as imagens da mesma maneira que os resultados subjetivos. As métricas SSIM e DISTS conseguiram mostrar o pior e o melhor resultados, conforme apresentado na Tabela 15. No entanto, o segundo melhor resultado apresentado pelas métricas foi o experimento da Figura 17(e), sendo invertido em relação ao experimento da Figura 17(d). Essa inversão aconteceu por causa da reconstrução da região da vegetação, cujas alterações não são tão fáceis de identificar apenas pela percepção humana. Por isso, a importância de realizar análises quantitativas junto a análises qualitativas. Essa situação também ocorreu com as métricas VSI e MSE, que indicaram como melhor resultado o experimento da Figura 17(d), em vez do experimento da Figura 17(c).

Por fim, a métrica PSNR só conseguiu identificar que o experimento da Figura 18(f) apresentou o pior resultado, mas não conseguiu identificar o melhor resultado, o que indica que o melhor resultado foi o experimento da Figura 17(d). O experimento da Figura 18(f) apresentou o pior resultado qualitativo. Já em relação às métricas, foi possível identificar que todas apresentaram o mesmo resultado que a análise visual.

Figura 17 – (a) imagem orbital H de referência, (b) imagem com objetos artificiais, (c) - (f) técnica de *inpainting* de Azevedo (2019).




Tabela 15 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.

	Fig. 17(c)	Fig. 17(d)	Fig. 17(e)	Fig. 17(f)
MSE ↓	2	1	3	4
PSNR ↑	3	1	2	4
SSIM ↑	1	3	2	4
FSIM ↑	1	2	3	4
VSI ↑	2	1	3	4
DISTS ↓	1	3	2	4
Score Subjetivo	1	2	3	4
MSE ↓	32,875	32,680	34,184	39,024
PSNR ↑	32,692	32,987	32,762	32,217
SSIM ↑	0,9749	0,9744	0,9747	0,9731
FSIM ↑	0,9878	0,9876	0,9875	0,9865
VSI ↑	0,9963	0,9964	0,9962	0,9957
DISTS ↓	0,0109	0,0133	0,0122	0,0139

Referente ao experimento da imagem I, Figura 18, observou-se que essa foi a única imagem que apresentou apenas os três melhores resultados. Isso se deve ao fato de que a feição de interesse nessa imagem é circular, representando um pivô de irrigação, o que dificultou sua reconstrução completa através da técnica de *inpainting* de Azevedo (2019). Nesse contexto, a escolha dos melhores resultados foi desafiadora, uma vez que a feição não foi reconstruída integralmente em relação à imagem original.

Observou-se uma correlação alta entre o DISTS e o FSIM (0,8) e uma correlação perfeita entre o DISTS e o SSIM (1,0). Como ambas são baseadas em estruturas, os resultados entre elas mostraram-se semelhantes. Uma situação diferente ocorreu entre o VSI e as outras métricas, apresentando uma correlação alta apenas com o PSNR e o FSIM (0,8) e uma correlação perfeita com a MSE (1,0), enquanto apresentou uma correlação mais fraca em torno de 0,4 com a métrica SSIM e a métrica DISTS.

Do ponto de vista qualitativo, as métricas MSE, DISTS e VSI apresentam correlação alta de 0,8 com os resultados subjetivos. Por outro lado, a métrica FSIM foi a única que apresentou a correlação de SRCC perfeita de 1,0 entre métrica e resultado subjetivo.

Figura 18 – (a) imagem orbital I de referência, (b) imagem com objetos artificiais, (c) -
(e) técnica de *inpainting* de Azevedo (2019).



(a)



(b)



(c)



(d)



(e)

Quase todas as métricas conseguiram indicar o melhor e o pior resultados, tendo a Figura 18(c) e 18(e), respectivamente, conforme apresentado na Tabela 16, os mesmos

resultados para as análises subjetivas. No entanto, a métrica DISTTS apresentou um resultado divergente das outras métricas, tendo uma inversão entre o experimento da Figuras 18(e) e 18(c). Essa discrepância no resultado pode ser explicada pelo fato de que as feições circulares envolvem padrões ou texturas que não são adequadamente modelados por métodos estatísticos lineares. Além disso, a presença de um objeto artificial em uma área específica da feição circular pode ter interferido ou confundido o processo de reconstrução da feição, afetando o processo de avaliação da métrica, que se baseia na medição da diferença de similaridade entre as imagens.

Tabela 16 – Rank das imagens classificadas de acordo com sua qualidade calculada por cada métrica.

	Fig. 18(c)	Fig. 18(d)	Fig. 18(e)
MSE ↓	1	3	2
PSNR ↑	1	3	2
SSIM ↑	1	3	2
FSIM ↑	1	3	2
VSI ↑	1	2	2
DISTS ↓	3	1	2
Score Subjetivo	1	3	2
MSE ↓	14,505	17,849	14,823
PSNR ↑	36,515	35,614	36,421
SSIM ↑	0,9694	0,9689	0,9690
FSIM ↑	0,9859	0,9845	0,9846
VSI ↑	0,9969	0,9965	0,9965
DISTS ↓	0,0492	0,0442	0,0463

Quanto à correlação entre as métricas e a análise subjetiva, observou-se uma correlação perfeita ou alta entre elas. A métrica DISTTS apresentou uma correlação negativa perfeita com as métricas MSE, PSNR, SSIM e FSIM (-1,0), indicando que, à medida que o valor de uma variável aumenta, o valor da outra variável diminui de forma linear. Em relação à VSI, a correlação foi moderadamente negativa, atingindo -0,5. Por outro lado, a VSI apresentou uma correlação forte com as métricas MSE, PSNR, SSIM e FSIM, registrando um valor de 0,75.

Quanto à correlação entre as métricas e a análise subjetiva, observou-se uma correlação perfeita entre as métricas MSE, PSNR, SSIM e FSIM (1,0) e uma correlação moderada de 0,75 com a VSI. Já em relação à DISTS, houve uma correlação moderadamente negativa. Esses resultados podem ser atribuídos à quantidade de dados analisados, sugerindo que, quanto maior o conjunto de dados, mais precisa tornar-se a análise. Comparando as correlações anteriores entre outras imagens, observou-se uma diferença maior entre elas, possivelmente devido à inclusão de uma observação adicional.

Nesse caso específico, foram consideradas apenas três imagens, devido às dificuldades enfrentadas no processo de restauração das feições utilizando-se a técnica de *inpainting* de Azevedo (2019).

4.3 Análise da classificação das imagens de SR

Conforme discutido nas seções anteriores, as métricas foram empregadas para avaliar o processo de reconstrução das imagens de SR por meio da técnica de *inpainting*. Entretanto, é importante ressaltar que, no contexto geral, a imagem reconstruída não é o produto definitivo, mas sim utilizada como etapa intermediária para aplicações, tais como análise espacial, detecção de mudança, análise estatística e classificação de imagem.

Dessa forma, nesta seção a classificação de imagem foi realizada como tarefa final para avaliar a performance das métricas de qualidade. Para tal, foi empregado o classificador não supervisionado K-médias (*K-means*). Este classificador realiza a classificação em grupo (clusters) e, nesse experimento, foram adotadas quatro ou cinco classes, a depender das feições em cada imagem estudada. A partir dessas classes pré-determinadas, cada pixel na imagem é associado ao cluster cujo vetor médio (centroide) possui características espectrais mais próximas. O processo de atribuição dos pixels as classes é realizado de forma iterativa, no qual o critério de parada ocorre quando não há mudanças significativas dos pixels alocados as classes.

É importante mencionar que este classificador frequentemente pode confundir grupos com vetores médios muito próximos, o que resultou em uma certa sobreposição entre a região que apresentava vegetação do tipo grama e o grupo de solo exposto. No entanto, devido à presença de terra/solo nessa área de vegetação, o classificador uniu os dois grupos em um só. Apesar desse incidente, o classificador conseguiu agrupar os clusters de forma consistente tanto nas imagens de referência quanto nas imagens

restauradas. Vale ressaltar que o objetivo deste trabalho não é verificar se o classificador cometeu erros na distinção entre as classes, mas sim determinar em quais casos ele foi capaz de distingui-las com precisão.

Portanto, o objetivo da classificação de imagens nesse trabalho consistiu em certificar-se de que o processo de restauração foi realizado corretamente pela técnica de *inpainting*. Além disso, buscou-se assegurar que os valores dos pixels foram atribuídos de forma adequada, especialmente considerando que os pixels, na região restaurada inicialmente, apresentavam valores iguais a zero. Além disso, buscou-se certificar-se de que as métricas DISTs e VSI conseguem avaliar de maneira satisfatória as imagens após a restauração das feições e que são aplicáveis ao contexto do SR.


Ao avaliar a qualidade da classificação de imagens, tanto do ponto de vista subjetivo quanto do ponto de vista quantitativo, foram aplicadas métricas que permitem verificar a qualidade numérica da classificação. Nesse contexto, a acurácia global foi utilizada para determinar se o número total de pixels classificados corretamente corresponde ao número total de pixels na imagem, especialmente avaliando a região após a restauração. É relevante ressaltar que quanto maior o valor da acurácia, maior a precisão do modelo de classificação em identificar corretamente as diferentes classes presentes na imagem.

4.3.1. Avaliação estatística da classificação de imagens aéreas de SR

Do ponto de vista visual, o classificador k-médias conseguiu fazer uma distinção satisfatória entre as classes, sendo possível visualizá-las na imagem classificada, conforme apresentado na Figura 19. Os experimentos apresentados nas Figuras 20, 22 e 23 foram pré-determinados com quatro classes, enquanto os experimentos apresentados nas Figuras 21 e 24 foram pré-determinados com três classes. Nos experimentos referentes às Figuras 20, 22 e 23, as classes foram distintas, permanecendo quatro grupos: vegetação densa ou arbórea, vegetação rasteira, solo exposto ou estrada. Houve a diferença de uma classe a menos nos experimentos apresentados nas Figuras 21 e 24. Optou-se por essas classes devido à melhor percepção visual das alterações nas feições após a classificação das imagens.


Figura 19 – Resultado da classificação não-supervisionada de imagens aéreas de SR .

(a) – (e) imagens de referência (original); (f) - (j) imagens classificadas.



Referente ao experimento da imagem A, Figura 20, as imagens foram agrupadas em quatro categorias distintas. Apesar de nenhuma das técnicas aplicadas ter sido capaz de restaurar a feição de maneira adequada, ao observar as Figuras 20 (e) – (g), a classificação foi aplicada de modo satisfatório. Por outro lado, a Figura 20 (h) apresentou a classificação menos satisfatória. No entanto, como a técnica de Baixo (2022) tem a tendência em suavizar as restaurações, algumas métricas e análises apresentam valores satisfatórios.

Figura 20 – Resultado da classificação não-supervisionada pelo k-médias das imagens aéreas A de SR. (a) – (d) imagens restauradas; (e) - (h) imagens classificadas.



No contexto numérico da Tabela 17, o melhor e o pior resultados revelaram uma acurácia global de 98,38% e 95,48%, respectivamente. Já em relação as classificações das Figuras 20(e) e 20 (g) exibiram acurácias globais de 98,38% e 98,24%, respectivamente, diferindo em aproximadamente 0,14%. Embora as métricas SSIM, FSIM, VSI e DISTS tenham apontado a Figura 20(a) como a melhor restauração alinhada à percepção visual, a classificação da Figura 20(g) apresentou a mais alta acurácia global. No entanto, dado o pequeno intervalo entre as acurácias das duas imagens, essa discrepância não teve impacto significativo no resultado.


Tabela 17 – Acurácia da imagem A classificada pelo classificador K-médias.

Imagens	Figura 20	Acurácia Global (%)	Técnicas de <i>inpainting</i>
A	(e)	98,24	Azevedo (2019)
	(f)	98,14	
	(g)	98,38	
	(h)	95,48	Baixo (2022)

Em relação ao experimento da imagem B, Figura 21, devido às poucas feições na imagem, a classificação foi feita por meio de três classes. Apesar de nenhuma das técnicas aplicadas ter sido capaz de restaurar a feição de maneira adequada, ao observar as Figuras 21 (e) – (g), a classificação foi aplicada de forma adequada. Por outro lado, a Figura 21(h) apresentou a classificação menos satisfatória.

Ao analisar as imagens classificadas, foi possível perceber que o experimento da Figura 21(e) apresentou um melhor resultado comparado à classificação, no entanto, as métricas clássicas não conseguiram apresentar os mesmos resultados. Apenas a métrica VSI conseguiu informar o melhor e o pior resultados do ponto de vista subjetivo, comparáveis aos da classificação das imagens. Apesar da métrica DISTS ter conseguido encontrar o primeiro e o segundo melhores resultados do ponto de vista quantitativo, semelhante ao da classificação, não foi capaz de informar corretamente o resultado menos satisfatório.

Figura 21 – Resultado da classificação não-supervisionada pelo k-médias das imagens aéreas B de SR. (a) – (d) imagens restauradas; (e) - (h) imagens classificadas.



Ao examinar as acurácias na Tabela 18, tanto o melhor quanto o pior resultados revelaram uma acurácia global de 93,47% e 85,69%, respectivamente. A classificação das Figuras 21(e) e 21(g) exibiram acurácias globais de 93,15% e 93,47%, respectivamente. Apesar de percepções subjetivas, a classificação da Figura 21(e) foi destacada pelo melhor resultado na avaliação das métricas, enquanto a classificação da Figura 21(g) alcançou o melhor valor numérico, com uma acurácia global de 93,47%. Isso ressalta a importância de harmonizar análises subjetivas e quantitativas. Embora os resultados avaliados pelas métricas sejam semelhantes à análise subjetiva, quando comparados aos valores da acurácia global da classificação, a diferença é mínima.

Tabela 18 – Acurácia da imagem B classificada pelo classificador K-médias.

Imagens	Figura 21	Acurácia Global (%)	Técnicas de <i>Inpainting</i>
B	(e)	93,15	Azevedo (2019)
	(f)	93,01	
	(g)	93,47	
	(h)	85,69	Baixo (2022)

Ao analisar o experimento da imagem C, Figura 22, com o apoio das acurácias da Tabela 19, fica evidente que o experimento da Figura 22(a) obteve o melhor resultado, enquanto o experimento da Figura 22(d) alcançou o desempenho menos satisfatório, em consonância com as métricas DISTS e VSI. Ao examinar as imagens tratadas com a técnica de *inpainting* de Azevedo (2019), notou-se uma similaridade marcante nas acurácias das Figuras 22(e) e 22(g), o que indicou uma restauração satisfatória. Por outro lado, o experimento da Figura 22(b) exibiu uma característica única em sua reconstrução, destacando-se pela feição gerada, a qual foi devidamente classificada. Em contrapartida, a imagem restaurada por Baixo (2022), Figura 22(d), apresentou um borrão perceptível, classificado como solo exposto, evidenciando uma suavização excessiva que levou ao seu desempenho inferior.

Ao examinar as acurácias, tanto o melhor quanto o pior resultados revelaram uma acurácia global de 97,44% e 90,43%, respectivamente. É perceptível que a classificação das Figuras 22(e) e 22(g) exibiram acurácias globais muito próximas, 97,44% e 97,43%, respectivamente, devido às semelhanças em suas restaurações. No entanto, outras métricas apresentaram resultados contrastantes entre as classificações das Figuras 22(g) e 22(e), destacando-se a necessidade de métricas capazes de identificar os

melhores resultados de forma mais alinhada com avaliações subjetivas, já que métricas tradicionais, como MSE, PSNR e SSIM, às vezes falham nesse aspecto.

Figura 22 – Resultado da classificação não-supervisionada pelo k-médias das imagens aéreas C de SR . (a) – (d) imagens restauradas; (e) - (h) imagens classificadas.





Tabela 19 – Acurácia da imagem C classificada pelo classificador K-médias.

Imagens	Figura 22	Acurácia Global (%)	Técnicas de <i>inpainting</i>
C	(e)	97,44	Azevedo (2019)
	(f)	96,69	
	(g)	97,43	
	(h)	90,43	Baixo (2022)

Em relação ao experimento da imagem D, Figura 23, devido à simplicidade das feições na imagem, a classificação foi dividida em três classes distintas. Uma análise das Figuras 23 (e) – (g) indica uma classificação satisfatória. No entanto, a Figura 23 (h) apresentou o desempenho menos satisfatório em termos de classificação. Ao observar a classificação, quase não se percebe a diferença entre elas. Por isso, é necessário utilizar métricas de qualidade para indicar a qualidade numérica de modo satisfatório. Apenas as métricas FSIM e DISTS conseguiram apresentar os mesmos resultados do ponto de vista subjetivo, as outras métricas conseguiram identificar o resultado menos satisfatório, que é a Figura 23(d). No entanto, quando comparados ao primeiro e ao segundo melhores

resultados, as métricas MSE, PSNR, SSIM e VSI obtiveram uma inversão no ranqueamento.

Figura 23 – Resultado da classificação não-supervisionada pelo k-médias das imagens aéreas D de SR. (a) – (d) imagens de SR restauradas; (e) - (h) imagens classificadas.



De acordo com os dados apresentados na Tabela 20, o desempenho variou consideravelmente, com o melhor e o pior resultados alcançando acurácias globais de 99,26% e 95,95%, respectivamente. As classificações das Figuras 23(e) e 23(f) demonstraram acurácias globais de 99,26% e 99,23%, respectivamente. A discrepância entre esses valores numéricos foi de apenas 0,03%, um valor considerado insignificante. Uma análise mais detalhada da classificação das feições restauradas revelou diferenças mínimas entre essas imagens. É relevante destacar que a métrica VSI produziu resultados consistentes em comparação com os dados da acurácia global.


Tabela 20 – Acurácia da imagem D classificada pelo classificador K-médias.

Imagens	Figura 23	Acurácia Global (%)	Técnicas de <i>inpainting</i>
D	(e)	99,26	Azevedo (2019)
	(f)	99,23	
	(g)	99,16	
	(h)	95,95	Baixo (2022)

Em relação ao experimento da imagem E, Figura 24, as imagens foram agrupadas em quatro classes distintas. Uma seção específica, localizada no canto inferior direito da imagem, destaca uma região com características vegetativas específicas, resultando em múltiplas classes durante a classificação. O número de grupos ou classes não foi reduzido, pois outras características na imagem seriam enquadradas em diferentes classes, devido ao vetor médio do classificador.

Similar ao resultado do experimento da Figura 21, ao observar as Figuras 24 (e) – (g), a classificação foi aplicada de modo satisfatório. Por outro lado, a Figura 24 (h) apresentou a classificação menos satisfatória. Apesar da feição curvilínea ter sido reconstruída e classificada de maneira correta na Figura 24(e), a região da vegetação não foi classificada de maneira adequada em comparação com a imagem original. Isso causou uma compensação em relação à Figura 24(g), que teve a região da estrada mais bem classificada, enquanto a região da vegetação não teve o mesmo resultado.

Figura 24 – Resultado da classificação não-supervisionada pelo k-médias das imagens aéreas E de SR. (a) – (d) imagens de SR restauradas; (e) - (h) imagens classificadas.



No contexto numérico da Tabela 21, o melhor resultado e o menos satisfatório revelaram uma acurácia global de 97,41% e 92,80%, respectivamente. Como já mencionado, a métrica VSI e a DISTs conseguiram refletir os resultados numéricos e subjetivos. No entanto, a acurácia global apresentou uma pequena diferença entre os

resultados revelados por essas métricas. Apesar disso, os valores se diferenciaram em uma escala muito pequena, de aproximadamente 0,14%, um valor aceitável. A diferença entre a primeira e a segunda imagens foi de 0,01%, um valor irrelevante. Ao analisar a classificação na região em que as feições foram restauradas, indica-se quase nenhuma diferença entre essas imagens.

Tabela 21 – Acurácia da imagem E classificada pelo classificador K-médias.


Imagens	Figura 24	Acurácia Global (%)	Técnicas de <i>inpainting</i>
E	(e)	97,27	Azevedo (2019)
	(f)	97,28	
	(g)	97,41	
	(h)	92,80	Baixo (2022)

4.3.2. Avaliação estatística da classificação de imagens orbitais de SR

Os experimentos apresentados nas Figuras 25(F), (G) e (H) foram pré-determinados com quatro classes, enquanto o experimento apresentado na Figura 25(I) foi pré-determinado com cinco classes. As classes foram: vegetação densa ou arbórea, vegetação rasteira, vegetação em crescimento, e solo exposto ou estrada. A diferença de uma classe a mais na Figura 25(I) justifica-se pela presença de área antropizada. Do ponto de vista visual, o classificador k-médias conseguiu fazer uma distinção adequada entre as classes, sendo possível visualizá-las na imagem classificada.

Figura 25 – Resultado da classificação não-supervisionada de imagens orbital de SR.

(a) – (d) imagens de referência; (e) - (h) imagens classificadas.



O experimento apresentado na imagem F, Figura 26, apresentou resultados satisfatórios em relação à classificação visual por meio do classificador K-médias e pelos resultados das acurácias, principalmente a acurácia global, que também foram superiores a 98%. Vale destacar, também, que a imagem avaliada pelas métricas apresentou acurácia global coerente com avaliação das métricas, ou seja, conseguiram identificar o melhor e o pior resultados.

A Tabela 22 indicou que a classificação referente à Figura 26(e) registrou uma acurácia global de 98,17%, enquanto a classificação referente à Figura 26(g) obteve 98,26%, representando o desempenho menos satisfatório e mais satisfatório, respectivamente. Resultados semelhantes aos das métricas DISTS e VSI, no que se refere à avaliação do processo de restauração das imagens, o que reforça, mais uma vez, que as

métricas utilizadas na avaliação de imagens tradicionais, DISTs e VSI, também servem para imagens no contexto do SR.

Figura 26 – Resultado da classificação não-supervisionada pelo k-médias da imagem orbital F de SR. (a) – (d) imagens restauradas; (e) - (h) imagens classificadas.




Tabela 22 – Acurácia da imagem F classificada pelo classificador K-médias.

Imagens	Figura 28	Acurácia Global (%)	Técnica de <i>inpainting</i>
F	(e)	98,17	Azevedo (2019)
	(f)	98,18	
	(g)	98,26	
	(h)	98,24	

O experimento apresentado na imagem G, Figura 27, foi identificado como um dos mais desafiadores para avaliar as restaurações qualitativamente. Após a classificação das imagens, que agrupa os valores dos pixels com base em vetores médios, a visualização das restaurações tornou-se mais clara por meio das classes (clusters) criados pelo classificador. As discrepâncias entre as restaurações foram mínimas, o que dificultou a distinção dos melhores resultados qualitativos.

No que diz respeito à acurácia global, na Tabela 23, a classificação referente ao experimento apresentado na Figura 27(h) obteve um resultado de 99,22%, alinhado com os resultados de quase todas as métricas, que classificaram essa imagem como a melhor,

com exceção da DISTS. No entanto, como as imagens foram classificadas de forma muito semelhante em relação aos resultados das outras imagens, a diferença foi insignificante, apenas 0,04%. Nesse contexto, a métrica VSI atribuiu valores praticamente idênticos para a avaliação das imagens após a restauração pela técnica de *inpainting*.

Figura 27 – Resultado da classificação não-supervisionada pelo k-médias da imagem orbital G de SR. (a) – (d) imagens restauradas; (e) - (f) imagens classificadas.





Tabela 23 – Acurácia da imagem G classificada pelo classificador K-médias.

Imagens	Figura 27	Acurácia Global (%)	Técnica de <i>inpainting</i>
G	(e)	99,19	Azevedo (2019)
	(f)	99,19	
	(g)	99,18	
	(h)	99,22	

Referente ao experimento da imagem H, Figura 28, é possível observar que as imagens foram classificadas de modo coerente com as respectivas classes (clusters), inclusive a região densa da vegetação que não era possível diferenciar a olho nu, indicada pela seta vermelha na Figura 28. O classificador conseguiu identificar adequadamente a

classe de vegetação densa/arbórea, e a classificação foi aplicada de modo satisfatório, conforme apresentado nas Figuras 28 (e) – (h).

Figura 28 – Resultado da classificação não-supervisionada pelo k-médias da imagem orbital H de SR 28. (a) – (d) imagens restauradas; (e) - (h) imagens classificadas.



De acordo com os dados apresentados na Tabela 24, o desempenho variou de forma insignificante, com o melhor e o pior resultados alcançando acurácias globais de 99,09% e 98,96%, respectivamente. A classificação das Figuras 28(e) e 28(g) apresentaram o mesmo valor na acurácia global de 99,09%. No entanto, ao analisar a Figura 25(H), que é a imagem de referência, percebe-se haver um pequeno deslocamento na parte da estrada em relação à Figura 28(e). Assim, o classificador conseguiu perceber essa alteração após a classificação da imagem e avaliou o experimento da Figura 28(h) com desempenho similar ao experimento da Figura 28(e), em que metade da estrada foi deslocada. No entanto, o classificador foi capaz de atribuir adequadamente as classes respectivas aos grupos de feições.

Observa-se que todas as acurácias relacionadas ao experimento da imagem H excederam 98%, o que indica que as restaurações foram realizadas de maneira satisfatória. Além disso, por meio do valor numérico da classificação, foi possível

identificar que o experimento da Figura 28(g) apresentou o desempenho menos satisfatório. Esse resultado evidencia que as métricas DISTs e VSI foram eficazes na avaliação do processo de restauração, conforme proposto por Azevedo (2019).

Tabela 24 – Acurácia da imagem H classificada pelo classificador K-médias.

Imagens	Figura 28	Acurácia Global (%)	Técnica de <i>inpainting</i>
H	(e)	99,09	Azevedo (2019)
	(f)	99,08	
	(g)	98,96	
	(h)	99,09	

Os resultados referentes ao experimento da imagem I, Figura 29, diferem um pouco dos resultados das outras imagens, pois a técnica de *inpainting* de Azevedo (2019) não restaurou corretamente as feições. Além disso, uma feição não restaurada corretamente na região da máscara da imagem foi compensada por uma outra feição restaurada corretamente na região da outra máscara na mesma imagem, quando a imagem apresenta dois objetos artificiais, e vice-versa em outras imagens. Dessa maneira, o resultado da acurácia global em relação à classificação foi semelhante, no qual um resultado bom compensou um ruim. Contudo, ao observar as Figuras 29 (d) – (f), a classificação foi aplicada de modo adequado.

Na classificação da Figura 29 (d), a acurácia global obteve o menor valor entre as imagens, com 97,57%, conforme apresentado na Tabela 25, a qual apresenta as imagens e as suas acurácias globais. Na classificação do experimento da Figura 29(e), a acurácia global obteve o resultado mais baixo comparado a outras acurácias; resultado semelhante ao da métrica VSI e às outras métricas tradicionais. A única métrica que não apresentou resultado semelhante foi a DISTs, devido às suas limitações, já mencionadas. No entanto, a classificação conseguiu distinguir claramente os grupos e apresentar acurácia global satisfatória.

Figura 29 – Resultado da classificação não-supervisionada pelo k-médias da imagem orbital I de SR. (a) – (c) imagens restauradas; (d) - (f) imagens classificadas.




Tabela 25 – Acurácia da imagem I classificada pelo classificador K-médias.

Imagens	Figura 29	Acurácia Global (%)	Técnica de <i>inpainting</i>
I	(d)	98,05	Azevedo (2019)
	(e)	97,57	
	(f)	98,25	

A acurácia do usuário possui relevância limitada para a classificação não supervisionada. Isso se deve ao foco na avaliação dos resultados das métricas aplicadas em imagens fotográficas convencionais, dentro do contexto do SR, após o processo de restauração, e não na avaliação do desempenho do algoritmo de classificação.

5. CONCLUSÃO

As técnicas de *inpainting* apresentadas por Azevedo (2019) e Baixo (2022) possuem características distintas em termos de aplicabilidade. Enquanto a técnica de *inpainting* de Azevedo (2019) é um método automático para remover áreas sombreadas em imagens multiespectrais orbitais com alta resolução espacial, a proposta de Baixo (2022) é um método semiautomático para a extração de feições cartográficas, com base em morfologia matemática e/ou outras técnicas de PDI.

Essas duas técnicas foram aplicadas em imagens de SR, tanto aérea quanto orbital. Apesar de não ser o objetivo da técnica elaborada por Azevedo (2019) a reconstrução de feições curvilíneas, como estradas, pivôs de irrigação e talhões agrícolas, ela desempenhou o processo de restauração de maneira satisfatória. Apenas em alguns casos, as feições não foram reconstruídas em suas totalidades. Com relação à técnica proposta por Baixo (2022), em grande parte das imagens restauradas pela referida técnica, as feições reconstruídas foram suavizadas, criando-se assim uma distorção/desfoque na imagem. Na maioria das análises realizadas, tanto pelas métricas quando pelos coeficientes de correlação, os resultados gerados pela técnica de Baixo (2022) não foram adequados para reconstruir feições curvilíneas. Devido a esses resultados, tal técnica não foi considerada nas análises de imagens de SR orbital.

Com relação à avaliação das métricas de qualidade realizadas nesta tese, ao analisar as métricas clássicas da literatura aplicadas em imagens de SR, tais como MSE, PSNR, SSIM e FSIM, percebeu-se que as restaurações nas imagens apresentam uma determinada qualidade visual e essas métricas acabaram por indicar resultados visuais não coerentes com os resultados numéricos das imagens. Dessa maneira, com base nos referenciais teóricos utilizados na tese e nos resultados apresentados pelas métricas tradicionais, houve a necessidade de adaptar e avaliar duas métricas adicionais no processo de restauração das imagens de SR: a métrica VSI e a métrica DISTS.

A métrica VSI avalia a preservação da saliência visual após o processamento da imagem, comparando a similaridade entre as imagens distorcidas e as originais. Essa métrica preserva as bordas e o contraste a fim de manter a qualidade visual da imagem. Além disso, a VSI baseia-se na comparação da similaridade entre os modelos de cor HSV (Matiz, Saturação, Valor) das imagens original e restaurada. Já a métrica DISTS permite calcular distorções estruturais (artefatos causados por ruído ou desfoque) com uma tolerância para a reamostragem de texturas, baseando-se em informações de intensidade

e estrutura, como o índice de similaridade estrutural. A diferença entre as duas métricas reside no objetivo e na metodologia de avaliação. No entanto, nos experimentos, ambas as métricas apresentaram resultados satisfatórios. Em algumas situações a VSI foi mais assertiva do que a DISTS, em outros casos, o inverso, seguindo a análise subjetiva.

Em relação às demais métricas, em alguns casos particulares, as métricas VSI e DISTS apresentaram resultados semelhantes ou superiores às métricas tradicionais, como PSNR e MSE. Todas as métricas foram analisadas em conjunto com a percepção visual, pois em alguns casos, as imagens apresentaram resultados visuais não satisfatórios, porém, houve divergência com relação aos resultados numéricos.

Para evitar depender exclusivamente de opiniões humanas na seleção dos resultados qualitativos ou de uma simples comparação de classificação baseada em métricas numéricas, recorreu-se aos coeficientes de correlação de *Kendall* (KRCC) e coeficientes de correlação *Spearman* (SRCC). Esses coeficientes foram empregados para verificar a correlação entre as preferências dos usuários em relação à percepção visual das restaurações e para avaliar a concordância entre os resultados das métricas, respectivamente. Referente à análise subjetiva dos usuários, ambos conseguiram identificar o melhor e o pior resultados, havendo uma pequena discordância de escolha entre o segundo e o terceiro resultados. Dessa maneira, em grande parte das análises de correlação, o KRCC apresentou concordância moderada entre o ranqueamento das imagens entre os usuários.

Já referente à correlação entre as métricas VSI e a DISTS com as outras métricas, foram altas (0,8) ou perfeitas (1,0), em quase todos os casos. As métricas SSIM, FSIM, VSI e DISTS demonstraram resultados consistentes em comparação à análise subjetiva. O SRCC foi perfeito tanto entre as métricas quanto entre a análise qualitativa (1,0). Em um caso, as métricas DISTS e FSIM apresentaram boas correlações com o resultado qualitativo. O SRCC entre VSI e DISTS foi perfeito (1,0), e entre as métricas SSIM e FSIM também obteve uma correlação perfeita de 1,0. Em comparação à análise subjetiva, VSI, DISTS, SSIM e FSIM apresentaram correlações perfeitas.

Em outro caso, houve uma correlação alta entre DISTS e VSI de 0,8. Por meio do SRCC, as métricas MSE e DISTS apresentaram uma correlação alta com a análise subjetiva de 0,8, enquanto VSI obteve uma correlação perfeita de 1,0. Em outra situação, em que as restaurações não foram totalmente reconstruídas, as métricas FSIM, VSI e DISTS indicaram resultados consistentes em comparação à análise subjetiva. Assim, o SRCC foi perfeito tanto entre as métricas quanto entre a análise qualitativa (1,0).

Evidenciando mais uma vez, que as métricas VSI e DISTs são duas métricas promissoras a serem utilizadas no contexto do SR. Com base nos resultados obtidos, constatou-se que as métricas clássicas (MSE e PSNR) geralmente não foram capazes de traduzir de forma precisa os resultados obtidos em termos numéricos para algumas das imagens amostradas. Isso ocorreu devido a não se considerar de certas características específicas das imagens digitais, como textura.

Por fim, as imagens foram classificadas pelo classificador k-médias depois de restauradas pelas técnicas de *inpainting*. Todas as imagens classificadas obtiveram acurácia global de pelo menos 90%. Isso significa que as restaurações foram satisfatórias e as feições restauradas foram classificadas adequadamente. Além disso, as métricas VSI e DISTs conseguiram refletir os resultados numéricos e subjetivos. No entanto, em alguns casos a acurácia global apresentou uma pequena diferença dos resultados; entretanto, essas diferenças foram insignificantes, de 0,01% ou 0,14%, em relação aos segundos melhores resultados. Além disso, em quase todos os casos, tanto as métricas quanto a análise subjetiva revelaram os mesmos resultados da acurácia quando se referiu aos resultados menos satisfatórios.

Em conclusão, a principal contribuição deste trabalho reside na identificação de métricas mais robustas e apropriadas a serem aplicadas na avaliação e análise da qualidade do *inpainting* para características cartográficas parcialmente detectadas. Com base na avaliação das métricas aplicadas às imagens de SR, foi possível mensurar e eleger as métricas DISTs e VSI como potenciais indicadores de qualidade a serem considerados no contexto específico de SR, incluindo aplicações construídas a partir das reconstruções, tal como a tarefa de classificação de imagens. Além disso, com essas métricas, VSI e DISTs, foi possível maximizar a precisão obtida durante a tarefa de avaliação, a fim de obter resultados mais precisos para orientar o processo de atualização de produtos cartográficos.

Para trabalhos futuros, sugere-se realizar aplicações de técnicas de *inpainting* com objetivo específico para restaurar feições curvilíneas; realizar aplicações e adaptações, se necessário, de outras métricas aplicadas em fotografias convencionais em imagens de SR visando analisar, caso-a-caso, as particularidades no processo de avaliação; propõe-se a modificação das métricas clássicas para considerar características específicas de imagens de SR; em relação à métrica DISTs, treinar as camadas convolucionais com imagens de SR e alterar os hiperparâmetros, como pesos e vieses, para ajustar as características dos dados de SR, como número de bandas e resolução

espacial; aplicar as métricas em imagens de SR com baixa resolução espacial; referente à classificação, utilizar um classificador supervisionado; e, por fim, aplicar um conjunto de imagens mais amplo de SR.

REFERÊNCIAS

- ALI ABD AL-HAMEED, K. Spearman's Correlation Coefficient in Statistical Analysis. **International Journal of Nonlinear Analysis and Applications**, v.13, n.1, p. 3249-3255, 2022.
- ARIAS, P.; FACCILOLO, G. CASELLES, V. A Variational Framework for Exemplar-Based Image Inpainting. **International journal of computer vision**, v. 93, n. 3, p. 319-347, 2011.
- ATAEI, S.; ALIREZAIE, J.; BABYN, P. Low Dose CT Denoising Using Dilated Residual Learning with Perceptual Loss and Structural Dissimilarity. In: 2020 **IEEE 5th Middle East and Africa Conference on Biomedical Engineering (MECBME)**. IEEE, 2020. p. 1-5.
- AZEVEDO, S.; SILVA, E.; COLNAGO, M.; NEGRI, R.; CASACA, W. Shadow Detection Using Object Area-Based and Morphological Filtering for Very High-Resolution Satellite Imagery of Urban Areas. **Journal of Applied Remote Sensing**, v. 13, n. 3, p. 036506-036506, 2019.
- AZEVEDO, S.; OLIVEIRA, R. F. D.; CASACA, W.; SILVA, E. Deshadowing of High Spatial Resolution Imagery Applied to Urban Area Detection. **Boletim de Ciências Geodésicas**, v.25: e2019S003, 2019.
- BAIXO, F, P. Avaliação do Modelo de Variação Total no Retoque de Feições Cartográficas. Dissertação (Mestrado em Ciências Cartográficas), Presidente Prudente, SP, 2022.
- BASSO, D.; COLNAGO, M.; AZEVEDO, S.; SILVA, E.; PINA, P.; CASACA, W. Combining Morphological Filtering, Anisotropic Diffusion and Block-Based Data Replication for Automatically Detecting and Recovering Unscanned Gaps in Remote Sensing Images. **Earth Science Informatics**, p. 1-14, 2021.
- BERTALMIO, M.; SAPIRO, G.; CASELLES, V.; BALLESTER, C. Image Inpainting. In: **Proceedings of the 27th annual conference on Computer graphics and interactive techniques**. 2000, p. 417-424.
- CASACA, W.; BOAVENTURA, M.; DE ALMEIDA, M. P.; NONATO, L. Combining Anisotropic Diffusion, Transport Equation and Texture Synthesis for Inpainting Textured Images. **Pattern Recognition Letters**, v. 36, p. 36-45, 2014.
- CASACA, W. C. de O. **Graph Laplacian for spectral clustering and seeded image segmentation**. Tese (Doutorado em Ciências de Computação e Matemática Computacional), São Carlos, SP, 2015, 127p.
- CHAUHAN, T.; MENIYA, A. Review and Analysis of Different Image Inpainting Methods. **IJSRD - International Journal for Scientific Research & Development**, v. 1, n. 12, p. 2810-2814, 2014.

- CHAUDHARY, V.; BHADOLA, P.; KAUSHIK, A.; KHALID, M.; FURUKAWA, H.; KHOSLA, A. Assessing Temporal Correlation in Environmental Risk Factors to Design Efficient Area-Specific COVID-19 Regulations: Delhi Based Case Study. **Scientific Reports**, v. 12, n. 1, p. 12949, 2022.
- CHEN, J.; YANG, M.; GONG, W.; YU, Y. Multi-Neighborhood Guided Kendall Rank Correlation Coefficient for Feature Matching. **IEEE Transactions on Multimedia**, 2022.
- CHEN, H.; SHAO, F.; CHAI, X.; GU, Y.; JIANG, Q.; MENG, X.; HO, Y. S. Quality Evaluation of Arbitrary Style Transfer: Subjective Study and Objective Metric. **IEEE Transactions on Circuits and Systems for Video Technology**, 2022.
- CHENG, Q.; SHEN, H.; ZHANG, L.; LI, P. Inpainting for Remotely Sensed Images with a Multichannel Nonlocal Total Variation Model. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 1, p. 175 - 187, 2014.
- DING, K.; MA, K.; WANG, S.; SIMONCELLI, E. P. Image Quality Assessment: Unifying Structure and Texture Similarity. **IEEE transactions on pattern analysis and machine intelligence**, v. 44, n.5, p. 2567-2581, 2022.
- DU, J., LI, W., PENG, Y., ZONG, Q. Image Fusion by Multiple Features in the Propagated Filtering Domain. **Social Science Research Network**. 2022.
- EGIAZARIAN, K.; PONOMARENKO, M.; LUKIN, V.; IEREMEIEV, O. Statistical Evaluation of Visual Quality Metrics for Image Denoising. **In 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**, IEEE, p.6752-6756, 2018.
- ELHARROUSS, O.; ALMAADEED, N.; AL-MAADEED, S.; AKBARI, Y. Image Inpainting: A Review. **Neural Processing Letters**, v. 51, n. 2, p. 2007–2028, 2019.
- FIGUEIRA, A. L. C.; DA SILVA, E. A.; ARAÚJO, M.; DIAS, B. S. M. D. C.; CARDIM, G. P. Use of two inpainting Techniques to Restore Partially Detected Cartographic Features. **International Journal of Advanced Engineering Research and Science (IJAERS)**, v. 7, n. 4, p. 299-304, 2020.
- FIGUEIRA, A. L. C.; CRUZ, B. S. M.; SILVA, E. A.; CARDIM, G. P.; WALLACE, C. O. C. Metodologia para Reconstrução de Feições Curvilíneas Parcialmente Detectadas após Processo de Extração de Feições Cartográficas em Imagens Digitais. **XVIII Simpósio Internacional de La Sociedad Latinoamericana Depercepción Remota y Sistemas de Información Espacial**, La habana, Cuba, 2018.
- GAO, R.; BISCHOF, W. F. Detection of Linear Structures in Remote-Sensed Images. In: **International Conference Image Analysis and Recognition**. Springer, Berlin, Heidelberg, 2009. p. 896-905.
- GILBOA, G.; OSHER, S. Nonlocal Operators with Applications to Image Processing. **Multiscale Modeling & Simulation**, v. 7, n. 3, p. 1005-1028, 2009.

GRIGAS, O.; MASKELIŪNAS, R.; DAMAŠEVIČIUS, R. Improving Structural MRI Preprocessing with Hybrid Transformer GANs. **Life**, v.13, n.9, p.1893, 2023.

GUO, W.; QIAO, L-H. Inpainting Based on Total Variation. International Conference on Wavelet Analysis and Pattern Recognition. **IEEE**, 2007.

HOUSSEIN, E. H.; ABDELKAREEM, D. A.; EMAM, M. M.; HAMEED, M. A.; YOUNAN, M. An Efficient Image Segmentation Method for Skin Cancer Imaging Using Improved Golden Jackal Optimization Algorithm. **Computers in Biology and Medicine**, v.149, p.106075, 2022.

HU, W.; YE, Y.; ZENG, F.; MENG, J. A New Method of Thangka Image Inpainting Quality Assessment. **Journal of Visual Communication and Image Representation**, v. 59, p. 292-299, 2019.

HUANG, Z. X.; JING, C. W. Super-Resolution Reconstruction Method of Remote Sensing Image Based on Multi-Feature Fusion. **IEEE Access**, v.8, p.18764-18771, 2020.

HUANG, H.; ZENG, H.; HOU, J.; CHEN, J.; ZHU, J.; MA, K. K. A Spatial and Geometry Feature-Based Quality Assessment Model for the Light Field Images. **IEEE Transactions on Image Processing**, v.31, 2022.

IEREMEIEV, O.; LUKIN, V.; OKARMA, K.; EGIAZARIAN, K. Full-Reference Quality Metric Based on Neural Network to Assess the Visual Quality Of Remote Sensing Images. **Remote Sensing**, v. 12, n. 15, p. 2349, 2020.

IKOTUN, A. M.; EZUGWU, A. E.; ABUALIGAH, L.; ABUHAIJA, B.; HEMING, J. K-Means Clustering Algorithms: A Comprehensive Review, Variants Analysis, and Advances in the Era of Big Data. **Information Sciences**, v. 622, p. 178-210, 2023.

INCE, T. Hyperspectral Image Denoising Using Group Low-Rank and Spatial-Spectral Total Variation. **IEEE Access**, v. 7, p. 52095–52109, 2019.

JAGALINGAM, P.; HEGDE, Arkal Vittal. A Review of Quality Metrics for Fused Image. **Aquatic Procedia**, v. 4, p. 133-142, 2015.

JI, T. Y.; YOKOYA, N.; ZHU, X. X.; HUANG, T. Z. Nonlocal Tensor Completion for Multitemporal Remotely Sensed Images' Inpainting. **IEEE Transactions on Geoscience and Remote Sensing**, v. 56, n. 6, p. 3047-3061, 2018.

JIANG, B.; CHEN, G.; WANG, J.; MA, H.; WANG, L.; WANG, Y.; CHEN, X. Deep Dehazing Network for Remote Sensing Image with Non-Uniform Haze. **Remote Sensing**, v. 13, n.21, p. 4443, 2021.

KADIAN, GARIMA; KHADANGA, GANESH. Review of Inpainting Techniques for UAV Images. In: **International Conference on Unmanned Aerial System in Geomatics**. Springer, Cham, 2019. p. 175-189.

KAY, Steven M. Fundamentals of Statistical Signal Processing: Estimation Theory. **Prentice-Hall, Inc.**, 1993.

- KAZAKEVICIUTE-JANUSKEVICIENE, G.; JANUSONIS, E.; BAUSYS, R.; LIMBA, T.; KISKIS, M. Assessment of the Segmentation of RGB Remote Sensing Images: A Subjective Approach. **Remote Sensing**, v. 12, n. 24, p. 4152, 2020.
- KENDALL, M. G. A New Measure of Rank Correlation. **Biometrika**, v. 30, n. 1/2, p. 81-93, 1938.
- KUMAR, R.; BHANDARI, A. K.; KUMAR, M. Haze Elimination Model-Based Color Saturation Adjustment with Contrast Correction. **IEEE Transactions on Instrumentation and Measurement**, v. 71, p. 1-10, 2022.
- LAKSHMANAN, V.; GOMATHI, R. A Survey on Image Completion Techniques in Remote Sensing Images. In: **2017 Fourth International Conference on Signal Processing, Communication and Networking (ICSCN)**. IEEE, 2017. p. 1-6.
- LATE, R. B.; DHARASHIVE, N. G. Remotely Sensed Image Inpainting with MNLTV Model. **International Journal on Recent and Innovation Trends in Computing and Communication**, v.5, n. 6, 2017, p. 392- 398.
- LEMAITRE, C.; PERDOCH, M.; RAHMOUNE, A.; MATAS, J.; MITÉLAN, J. Detection and Matching of Curvilinear Structures. **Pattern recognition**, v. 44, n. 7, p. 1514-1527, 2011.
- LI, M.; WEN, Y. A New Image Inpainting Method Based on TV Model. **Physics Procedia**, v. 33, p. 712-717, 2012.
- LI, A.; QI, J.; ZHANG, R.; MA, X.; RAMAMOCHANARAO, K. Generative Image Inpainting with Submanifold Alignment. **arXiv preprint arXiv:1908.00211**. 2019.
- LIN, C. H.; LAI, K. H.; CHEN, Z. B.; CHEN, J. Y. Patch-Based Information Reconstruction of Cloud-Contaminated Multitemporal Images. **IEEE Transactions on Geoscience and Remote Sensing**, v.52, n.1, p. 163-174, 2014.
- LIU, Y.; YEOH, J. K. Automated Crack Pattern Recognition from Images for Condition Assessment Of Concrete Structures. **Automation in Construction**, v.128, p.1-14, 2021.
- LU, Y.; GAO, Y.; GUO, Y.; XU, W.; HU, X. Low-Light Image Enhancement Via Gradient Prior-Aided Network. **IEEE Access**, v. 10, p. 92583-92596, 2022.
- MA, H.; QIN, Q; SHEN, X. Shadow Segmentation and Compensation In High Resolution Satellite Images. Proceedings... **IEEE IGARSS**, v. 2, p. 1036–1039, 2008.
- MAALOUF, A.; CARRÉ, P.; AUGEREAU, B.; FERNANDEZ-MALOIGNE. A Bandelet-Based Inpainting Technique for Clouds Removal From Remotely Sensed Images. **IEEE transactions on geoscience and remote sensing**, v. 47, n. 7, p. 2363-2371, 2009.
- MALOVIĆ, M.; VUKANIĆ, V.; JEVREMOVIĆ, D.; BRAJOVIĆ, L. Mixed Spearman's Correlation Suitability for Sine-Shaped Independent Variables in Natural Sciences. **In:**

2023 10th International Conference on Electrical, Electronic and Computing Engineering (IcETRAN). IEEE, p. 1-5, 2023.

MENA, J. B. State of The Art on Automatic Road Extraction for GIS Update: A Novel Classification. **Pattern recognition letters**, v. 24, n. 16, p. 3037-3058, 2003.

MENA, J. B.; MALPICA, J. A. An Automatic Method for Road Extraction in Rural And Semi-Urban Areas Starting from High Resolution Satellite Imagery. **Pattern recognition letters**, v. 26, n. 9, p. 1201-1220, 2005.

MERVEILLE, O.; TALBOT, H.; NAJMAN, L.; PASSAT, N. Curvilinear Structure Analysis by Ranking the Orientation Responses of Path Operators. **IEEE transactions on pattern analysis and machine intelligence**, v. 40, n. 2, p. 304-317, 2017.

NDAJAH, P.; KIKUCHI, H.; YUKAWA, M.; WATANABE, H.; MURAMATSU, S. SSIM Image Quality Metric for Denoised Images. In: **Proc. 3rd WSEAS Int. Conf. on Visualization, Imaging and Simulation**. 2010. p. 53-58.

QUEIROZ, G. R.; FERREIRA, K. R. Tutorial Sobre Bancos de Dados Geográficos. **Instituto Nacional de Pesquisas Espaciais (INPE)**: São José dos Campos, 2006, p. 104.

QURESHI, M. A.; DERICHE, M. D.; BEGHDADI, A.; AMIN, A. A Critical Survey of State-Of-The-Art Image Inpainting Quality Assessment Metrics. **Journal of Visual Communication and Image Representation**, v. 49, p. 177-191, 2017.

RABBANI, M.; JONES, P. W. Digital Image Compression Techniques. **SPIE press**, 1991.

SARA, U.; AKTER, M.; UDDIN, M. S. Image Quality Assessment Through FSIM, SSIM, MSE And PSNR - A Comparative Study. **Journal of Computer and Communications**, v. 7, n. 3, p. 8-18, 2019.

SCHONLIEB, C. B. Partial Differential Equation Methods for Image Inpainting. **Cambridge University Press**, 2015, 250p.

SHEN, H.; LIU, Y.; AI, T. WANG, Y. WU, B. Universal Reconstruction Method for Radiometric Quality Improvement of Remote Sensing Images. **International Journal of Applied Earth Observation and Geoinformation**, v. 12, n. 4, p. 278-286, 2010.

SHEN, H. F.; AI, T. H.; LI, P. X. Destriping and Inpainting of Remote Sensing Images Using Maximum A-Posteriori Method. In: ISPRS 2008: Proceedings of the XXI Congress: Silk Road for Information from Imagery: **The International Society for Photogrammetry and Remote Sensing**. 2008. p. 63-70.

SHEN, J., & CHAN, T. F. Mathematical Models for Local Nontexture Inpaintings. **SIAM Journal on Applied Mathematics**, v. 62, n. 3, p. 1019-1043, 2002.

SIEGEL, S. **Nonparametric Statistics for the Behavioral Sciences**. Pennsylvania, USA: McGraw-Hill Companies, 1956.

SIM, K.; YANG, J.; LU, W.; GAO, X. MaD-DLS: Mean and Deviation Of Deep and Local Similarity for Image Quality Assessment. **IEEE Transactions on Multimedia**, v.23, p.4037-4048, 2020.

SINGH, M.; KAUR, H.; A Survey on Image Inpainting for Remotely Sensed Images. **IRACST - International Journal of Computer Science and Information Technology & Security**, v. 6, n.1, p. 487 – 490, 2016.

SILVA, A. L. O. Modelos Matemáticos Para o Retoque Digital De Imagens. 2005. 115f. Dissertação (Mestrado em Matemática Aplicada) - Universidade Estadual Paulista, Instituto de Biociências, Letras e Ciências Exatas, 2005.

SONG, Q.; WANG, Y.; YAN, X.; GU, H. Remote Sensing Images Stripe Noise Removal by Double Sparse Regulation and Region Separation. **Remote Sensing**, v. 10, n. 7, p. 998, 2018.

SØGAARD, J.; KRASULA, L.; SHAHID, M.; TEMEL, D.; BRUNNSTRÖM, K.; RAZAAK, M. Applicability of Existing Objective Metrics of Perceptual Quality for Adaptive Video Streaming. **Electronic Imaging**, v. 2016, n. 13, p. 1-7, 2016.

SONG, X.; WU, L. Hyperspectral Image Inpainting Based on Robust Spectral Dictionary Learning. **Applied Sciences**, v. 9, n. 15, p. 3062, 2019.

SOPHIA, D. L.; LALITHA, K.; CHANDAR, J. P. Reconstruction of Cloud Contaminated Remote Sensing Images Using Inpainting Strategy. **International Journal of Electronics Communication and Computer Technology**, v. 3, n. 3, p. 407-411, 2013.

SU, H.; ZHAO, D.; ELMANNAI, H.; HEIDARI, A. A.; BOUROUIS, S.; WU, Z.; CHEN, M. Multilevel Threshold Image Segmentation for COVID-19 Chest Radiography: A Framework Using Horizontal and Vertical Multiverse Optimization. **Computers in Biology and Medicine**, v. 146, p. 105618, 2022.

TIEFENBACHER, P.; BOGISCHEF, V.; MERGET, D.; RIGOLL, G. Subjective and Objective Evaluation of Image Inpainting Quality. **In: 2015 IEEE International Conference on Image Processing (ICIP)**. IEEE, 2015. p. 447-451.

TRUNG, A. D. T; BEGHDADI, B. A.; LARABI, C. C. Perceptual Quality Assessment for Color Image Inpainting. **In: 2013 IEEE International Conference on Image Processing**. IEEE, 2013, p. 398-402.

TSAI, V. J. D. Automated Shadow Compensation in Color Aerial Images. **Annual Conference of American Society for Photogrammetry and Remote Sensing**. Reno, Nevada, 2006.

XIONG, W.; YU, J.; LIN, Z.; YANG, J.; LU, X.; BARNES, C.; LUO, J. Foreground-aware image inpainting. **In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**, 2019, p. 5840-5848.

WAFY, M; EBAID, R. Quality Assessment of Visual Cryptography Images. **Australian Journal of Basic and Applied Sciences**, v. 10, n.15, p. 215-222, 2016.

WANG, J.; QIAN, J.; MA, R. Urban Road Information Extraction from High Resolution Remotely Sensed Image Based on Semantic Model. In: **2013 21st International Conference on Geoinformatics**. IEEE, 2013, p. 1-5.

WANG, Z.; BOVIK, A. C.; SHEIKH, H. R.; SIMONCELLI, E. P. Image Quality Assessment: from Error Visibility to Structural Similarity. **IEEE transactions on image processing**, v. 13, n. 4, p. 600-612, 2004.

YEE, W. C.; JIAN, T. X.; AB RAHMAN, K. S.; HOE, T. L.; MIN, L. J.; HANG, Q. Y.; LING, T. C. Performance Analysis of Color Normalization Methods in Histopathology Images. In: **2022 IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS)**. IEEE, p. 147-151, 2022.

ZHANG, L.; ZHANG, L.; MOU, X.; ZHANG, D. FSIM: A Feature Similarity Index for Image Quality Assessment. **IEEE transactions on Image Processing**, v. 20, n. 8, p. 2378-2386, 2011.

ZHANG, L.; SHEN, Y.; LI, H. VSI: A Visual Saliency-Induced Index for Perceptual Image Quality Assessment. **IEEE Transactions on Image processing**, v. 23, n.10, p.4270-4281, 2014.

ZHANG, Z.; LIU, Q.; WANG, Y. Road Extraction by Deep Residual U-Net. **IEEE Geoscience and Remote Sensing Letters**, v. 15, n. 5, p. 749-753, 2018.

ZHENG, Y.; CHEN, W.; LIN, R.; ZHAO, T.; LE CALLET, P. UIF: An Objective Quality Assessment for Underwater Image Enhancement. **IEEE Transactions on Image Processing**, v. 31, p.5456-5468, 2022a.

ZHENG, R.; JIANG, X.; MA, Y.; WANG, L. A Comparison of Quality Assessment Metrics on Image Resolution Enhancement Artifacts. In **2022 International Conference on Culture-Oriented Science and Technology (CoST)**, IEEE. p.200-204. 2022b.

ZHU, C., XU, J., FENG, D., XIE, R., SONG, L. Edge-Based Video Compression Texture Synthesis Using Generative Adversarial Network. **IEEE Transactions on Circuits and Systems for Video Technology**, v.32, n.10, p.7061-7076, 2022.