

UNIVERSIDADE FEDERAL DE GOIÁS
INSTITUTO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO

EMÍLIA ALVES NOGUEIRA

**Técnicas de Reamostragem e
Super-Resolução em Imagens de
Culturas Agrícolas**

Goiânia
2025



UNIVERSIDADE FEDERAL DE GOIÁS
INSTITUTO DE INFORMÁTICA

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do material bibliográfico

Dissertação Tese Outro*: _____

*No caso de mestrado/doutorado profissional, indique o formato do Trabalho de Conclusão de Curso, permitido no documento de área, correspondente ao programa de pós-graduação, orientado pela legislação vigente da CAPES.

Exemplos: Estudo de caso ou Revisão sistemática ou outros formatos.

2. Nome completo do autor

Emilia Alves Nogueira

3. Título do trabalho

Técnicas de Reamostragem e Super-Resolução em Imagens de Culturas Agrícolas

4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento SIM NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

- a) consulta ao(à) autor(a) e ao(à) orientador(a);
 - b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação.
- O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Fabrizio Alphonsus Alves De Melo Nunes Soares**, Professor do Magistério Superior, em 08/04/2025, às 13:50, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Emilia Alves Nogueira, Discente**, em 08/04/2025, às 14:55, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5280890** e o código CRC **774F6C25**.

EMÍLIA ALVES NOGUEIRA

Técnicas de Reamostragem e Super-Resolução em Imagens de Culturas Agrícolas

Tese apresentada ao Programa de Pós-Graduação em Ciência da Computação, do Instituto de Informática da Universidade Federal de Goiás, como requisito parcial para obtenção do título de Doutora em Ciência da Computação.

Área de concentração: Ciência da Computação.

Linha de pesquisa: Sistemas Inteligentes e Aplicações.

Orientador: Prof. Dr. Fabrízio Alphonsus Alves de Melo Nunes Soares

Goiânia
2025

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Nogueira, Emília Alves

Técnicas de Reamostragem e Super-Resolução em Imagens de Culturas Agrícolas [manuscrito] / Emília Alves Nogueira. - 2025.

CX, 110 f.: il.

Orientador: Prof. Fabrizzio Alphonsus Alves de Melo Nunes Soares

Tese (Doutorado) - Universidade Federal de Goiás, Instituto de Informática (INF), Programa de Pós-Graduação em Ciência da Computação, Goiânia, 2025.

Bibliografia. Anexos.

Inclui siglas, fotografias, abreviaturas, tabelas, lista de figuras, lista de tabelas.

1. Reamostragem. 2. Super Resolução. 3. Aprendizado Profundo. 4. Satélite. 5. UAVs. I. Alphonsus Alves de Melo Nunes Soares , Fabrizzio, orient. II. Título.

CDU 5



UNIVERSIDADE FEDERAL DE GOIÁS

INSTITUTO DE INFORMÁTICA

ATA DE DEFESA DE TESE

Ata nº **03/2025** da sessão de Defesa de Tese de **Emilia Alves Nogueira**, que confere o título de Doutora em Ciência da Computação, na área de concentração em Ciência da Computação.

Aos vinte e oito dias do mês de fevereiro de dois mil e vinte e cinco, a partir das nove horas, na sala 257 do Instituto de Informática, realizou-se a sessão pública de Defesa de Tese intitulada “**Uso de Técnicas de Aprendizado Profundo para Melhorar a Resolução de Imagens Agrícolas de Plantíos de Cana-de-açúcar e Milho**”. Os trabalhos foram instalados pelo Orientador, Professor Doutor Fabrizio Alphonsus Alves de Melo Nunes Soares (INF/UFG) com a participação dos demais membros da Banca Examinadora: Professor Doutor Helio Pedrini (IC/UNICAMP), membro titular externo; Professor Doutor Christian Dias Cabacinha (ICA/UFG), membro titular externo; Professor Doutor Ronaldo Martins da Costa (INF/UFG), membro titular interno; e Profa. Dra. Deborah Silva Alves Fernandes (INF/UFG), membra titular interna. A participação dos professores Helio Pedrini e Christian Dias Cabacinha ocorreu por meio de videoconferência. Durante a arguição os membros da banca fizeram sugestão de alteração do título do trabalho. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Tese, tendo sido a candidata aprovada pelos seus membros. Proclamados os resultados pelo Professor Doutor Fabrizio Alphonsus Alves de Melo Nunes Soares, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos vinte e oito dias do mês de fevereiro de dois mil e vinte e cinco.

TÍTULO SUGERIDO PELA BANCA

Técnicas de Reamostragem e Super-Resolução em Imagens de Culturas Agrícolas



Documento assinado eletronicamente por **Helio Pedrini, Usuário Externo**, em 08/04/2025, às 23:16, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Christian Dias Cabacinha, Usuário Externo**, em 09/04/2025, às 08:14, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ronaldo Martins Da Costa, Professor do Magistério Superior**, em 09/04/2025, às 09:47, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Deborah Silva Alves Fernandes, Professora do Magistério Superior**, em 09/04/2025, às 10:18, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Fabrizio Alphonsus Alves De Melo Nunes Soares, Professor do Magistério Superior**, em 09/04/2025, às 13:35, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Emilia Alves Nogueira, Discente**, em 09/04/2025, às 14:44, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5299350** e o código CRC **744B8D40**.

Referência: Processo nº 23070.003824/2025-70

SEI nº 5299350

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador(a).

Emília Alves Nogueira

Possui graduação em Ciência da Computação pela Universidade Federal de Goiás (2013) e mestrado em Ciência da Computação pela Universidade Federal de Uberlândia (2015). Durante o mestrado, na UFU, foi bolsista da CAPES e desenvolveu um trabalho de sistema de recomendação. Foi professora do curso de Ciência da Computação na Universidade Federal de Goiás - Regional Jataí, em que coordenou um projeto de extensão voltado para a redução das taxas de evasão do curso e o ensino de desenvolvimento web para alunos do ensino médio. Atualmente é aluna de doutorado e bolsista da FAPEG, onde vem desenvolvendo um projeto para auxiliar na extração de características da cultura de cana-de-açúcar. Tem experiência na área de Ciência da Computação, com ênfase em Processamento Digital de Imagens, Visão Computacional, Reconhecimento de Padrões, Realidade Aumentada, Realidade Virtual e Deep Learning aplicado ao processamento de imagens.

Dedico este trabalho à minha família, que é minha maior fonte de motivação e força. A cada um de vocês, que me ensinam a valorizar a vida, a crescer com amor e sabedoria, e a enfrentar os desafios com coragem. Esta conquista é dedicada a todos vocês.

Agradecimentos

Agradeço, primeiramente, a Deus, por ser meu amparo, meu sustento e por todas as bênçãos que proporciona na minha vida e na da minha família. Aos meus pais, minha eterna gratidão. Vocês torcem por mim em cada passo, vibram com minhas vitórias e me acolhem com amor quando as coisas não saem como esperado. Seu apoio incondicional é minha base, meu porto seguro. Agradeço ao meu irmão Müller e à minha cunhada, Morgana, juntamente com as minhas sobrinhas Isadora, Maria Clara e o caçulinha José Neto, que enchem minha vida de alegria. Cada encontro com vocês renova minha energia e me inspira a seguir firme nessa jornada em busca do conhecimento.

Agradeço também ao meu sogro, sogra e cunhados por estarem sempre presentes em minha vida. Agradeço também às amigas Sarah, Lana e Neide, pela ajuda nos momentos críticos em que o tempo parecia insuficiente para entregar os artigos. E aos amigos Camila, Fernanda, Edmundo e Reny, muito obrigada pela presença constante em minha vida. Aos colegas acadêmicos Afonso, Gabriel, Thamer, Wellington, Silvio, Cláudio Gabriel e Allan, obrigada por todas as dicas e troca de ideias. Estar ao lado de vocês foi essencial para alcançar os melhores resultados possíveis.

Meus agradecimentos à FAPEG – Fundação de Amparo à Pesquisa do Estado de Goiás por meio da Chamada N. 18/2020 (Processo 202110267000772), e à CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior Código de Financiamento 001 na chamada em pareceria com a FAPEG, pelo apoio e pelos recursos concedidos, sem os quais não teria sido possível alcançar o objetivo almejado.

Meu profundo e sincero agradecimento vai ao professor Fabrizzio, meu orientador e amigo. Sua postura acolhedora e inspiradora diante dos desafios da vida (seja ela acadêmica ou não) fez toda a diferença. Com a orientação do senhor, produzir, publicar e superar os obstáculos tornou-se um processo natural. Que o meio acadêmico possa contar com mais profissionais com sua dedicação, sabedoria e humildade.

E, por fim, mas não menos importante, agradeço ao meu esposo, parceiro e amigo Bruno. Você me apoia de todas as formas possíveis, e juntos construímos nossa linda família. Obrigada pelos nossos presentes mais preciosos: Lara, Lucas e Luan. Eles são minha alegria, meu refúgio e minha maior motivação. Vocês me distraem do trabalho quando preciso, mas, acima de tudo, enchem minha vida de amor e alegria.

"Se eu vi mais longe, foi por estar sobre os ombros de gigantes."

Isaac Newton,

.

Resumo

Nogueira, Emília Alves. **Técnicas de Reamostragem e Super-Resolução em Imagens de Culturas Agrícolas**. Goiânia, 2025. 110p. Tese de Doutorado. Programa de Pós-Graduação em Ciência da Computação, Instituto de Informática, Universidade Federal de Goiás.

A crescente demanda por alimentos, associada às mudanças climáticas, tem impulsionado o desenvolvimento de tecnologias de monitoramento agrícola para aumentar a eficiência e a sustentabilidade da produção de culturas como cana-de-açúcar e milho. No entanto, a baixa resolução das imagens capturadas por Veículo Aéreo Não Tripulado (VANT) e satélites limita a análise detalhada de características agrônômicas essenciais. Esta tese investiga métodos para melhorar a resolução de imagens agrícolas, comparando as Técnicas Tradicionais de Reamostragem (TTR) com algoritmos de Super-Resolução com Redes Profundas (SRRP), como *Real Enhanced Super-Resolution Generative Adversarial Network* (Real-ESRGAN), *Multi-Level upscaling Transform* (MuLUT) e *Learning Resampling Function* (LeRF). O objetivo deste estudo é investigar a aplicação de técnicas de aprendizado profundo para melhorar a resolução de imagens agrícolas. Para isso, foram revisados os métodos existentes e preparado o conjunto de dados agrícola. A pesquisa adotou uma abordagem experimental, avaliando os métodos quantitativamente usando métricas como o *Peak Signal-to-Noise Ratio* (PSNR) e *Structural Similarity Index* (SSIM), e qualitativamente por análise visual. Os experimentos demonstram melhorias significativas na resolução das imagens usando os algoritmos de SRRP em comparação aos TTR, com ganhos de 484,34% nas imagens de cana-de-açúcar, 234,4% no milho e 58,57% nas imagens de satélite. Embora as técnicas de SRRP tenham sido desenvolvidas para outros propósitos, como melhorar a resolução de imagens de pessoas e animes, seu desempenho pode ser observado em imagens agrícolas. Os resultados obtidos são significativos para a agricultura de precisão, pois o aumento da resolução das imagens pode auxiliar no monitoramento do crescimento e da saúde das plantas, proporcionando intervenções mais rápidas e efetivas. Em investigações futuras, esperamos ampliar as comparações com outros algoritmos de SRRP.

Palavras-chave

Reamostragem, Super Resolução, Aprendizado Profundo, UAVs, Satélite, Cana-de-Açúcar, Milho.

Abstract

Nogueira, Emília Alves. **Comparison of Traditional and Deep Learning Methods in Agricultural Image Enhancement**. Goiânia, 2025. 110p. PhD. Thesis. Programa de Pós-Graduação em Ciência da Computação, Instituto de Informática, Universidade Federal de Goiás.

The increasing demand for food, coupled with climate change, has driven the development of agricultural monitoring technologies to increase the efficiency and sustainability of crop production such as sugarcane and corn. However, the low resolution of images captured by Unmanned Aerial Vehicle (UAV) and satellites limits the detailed analysis of essential agronomic features. This thesis investigates methods to improve the resolution of agricultural images, comparing Traditional Resampling Techniques (TRT) with Super-Resolution with Deep Networks (SRDN) algorithms, such as Real Enhanced Super-Resolution Generative Adversarial Network (Real-ESRGAN), Multi-Level upscaling Transform (MuLUT) and Learning Resampling Function (LeRF). The aim of this study is to investigate the application of deep learning techniques to improve the resolution of agricultural images. For this purpose, existing methods were reviewed and an agricultural dataset was prepared. The research adopted an experimental approach, evaluating the methods quantitatively using metrics such as Peak Signal-to-Noise Ratio (PSNR) and Structural Similarity Index (SSIM), and qualitatively by visual analysis. The experiments demonstrate significant improvements in image resolution using the SRDN algorithms compared to TRT, with gains of 484.34% in sugarcane images, 234.4% in corn, and 58.57% in satellite images. Although the SRDN techniques were developed for other purposes, such as improving the resolution of images of people and anime, their performance can be observed in agricultural images. The results obtained are significant for precision agriculture, since the increase in image resolution can aid in monitoring plant growth and health, providing faster and more effective interventions. In future investigations, we hope to expand the comparisons with other SRDN algorithms.

Keywords

Resampling, Super Resolution, Deep Learning, UAVs, Satellite, Sugarcane, Corn.

Lista de Siglas

AR Alta Resolução

BAM Biomassa Aérea de Milho

BR Baixa Resolução

CNN *Convolutional Neural Networks*

ESRGAN *Enhanced Super-Resolution Generative Adversarial Network*

FAR Fenotipagem de Alto Rendimento

GAN *Generative Adversarial Network*

GEE *Google Earth Engine*

JPEG *Joint Photographic Experts Group*

KML *Keyhole Markup Language*

LeRF *Learning Resampling Function*

LUT *Look-Up Table*

LPIPS *Learned Perceptual Image Patch Similarity*

MSE *Mean Squared Error*

MuLUT *Multi-Level upscaling Transform*

PNG *Portable Network Graphics*

PSNR *Peak Signal-to-Noise Ratio*

RPA *Remotely Piloted Aircraft*

Real-ESRGAN *Real Enhanced Super-Resolution Generative Adversarial Network*

RF *Receptive Field*

RSL Revisão Sistemática da Literatura

SRRP Super-Resolução com Redes Profundas

SRDN Super-Resolution with Deep Networks

SSIM *Structural Similarity Index*

TIFF *Tagged Image File Format*

TTR Técnicas Tradicionais de Reamostragem

TRT Traditional Resampling Techniques

UAV Unmanned Aerial Vehicle

VANT Veículo Aéreo Não Tripulado

VT *Vegetative Tasseling*

Sumário

Lista de Figuras	19
Lista de Tabelas	21
1 Introdução	22
1.1 Contextualização	22
1.2 Definição do Problema	23
1.3 Objetivos	24
1.4 Justificativa	25
1.5 Hipótese e Contribuição da Pesquisa	25
1.6 Estrutura da Tese	26
2 Fundamentação Teórica	27
2.1 Tipos de Resolução em Imagens Agrícolas	27
2.2 Uso de Imagens RGB no Monitoramento Agrícola	28
2.2.1 Satélites na Análise Agrícola	29
2.2.2 Veículos Aéreos Não Tripulados na Análise Agrícola Remotely Piloted Aircraft	30 30
2.2.3 Ciclo de Vida da Cana-de-Açúcar e Monitoramento Agrícola	31
2.2.4 Estágios Vegetativos do Milho e Monitoramento Agrícola	34
2.3 Melhoria de Resolução das Imagens Agrícolas	36
2.3.1 Técnicas Tradicionais de Reamostragem – TTR Reamostragem com a Técnica Vizinho mais próximo Reamostragem com a Técnica Bilinear Reamostragem com a Técnica Bicúbica	36 37 37 38
2.3.2 Super-Resolução com Redes Profundas Super-Resolução com a Técnica Real-ESRGAN Super-Resolução com a Técnica MuLUT Super-Resolução com a Técnica LeRF	40 41 43 45
3 Revisão da Literatura	47
3.1 Revisão Sistemática da Literatura	47
3.2 Trabalhos Relacionados	48
3.2.1 Comparação dos Trabalhos Relacionados	51
4 Abordagens de Melhoria de Imagens a Partir de Técnicas Tradicionais de Reamostragem e de Redes de Aprendizado Profundo	54
4.1 Fluxograma do Processo de Coleta, Melhoria e Análise de Imagens Agrícolas	54
4.2 Coleta e Preparação do Conjunto de Dados	55

4.2.1	Conjuntos Experimentais de Dados de Imagens Agrícolas Capturadas com VANT	55
	Conjunto de Imagens da Cultura de Cana-de-açúcar	55
	Conjunto de Imagens da Cultura do Milho	57
4.2.2	Imagens de Cana-de-açúcar Capturadas por Satélite	58
	Identificação com MapBiomias	58
	Exportação no GEE	59
	Aquisição das Imagens de Satélite	59
	Pré-processamento	60
4.3	Aplicação das Técnicas Tradicionais de Reamostragem	61
4.4	Aplicação das Técnicas de Super-Resolução com Redes Profundas	61
4.4.1	Ajustes e Treinamento das Técnicas de SRRP	62
4.4.2	Processo de Aumento de Resolução Espacial	63
4.5	Comparação do Impacto das TTR e das SRRP na Qualidade das Imagens Geradas	64
4.5.1	Peak Signal-to-Noise Ratio	64
4.5.2	Structural Similarity Index	64
4.5.3	Jaccard	65
4.5.4	Learned Perceptual Image Patch Similarity	65
5	Experimentos e Discussão dos Resultados	67
5.1	Experimento I - Cana-de-açúcar 40 imagens	67
5.1.1	Análise Quantitativa	68
5.1.2	Análise Qualitativa	69
5.2	Experimento II - Cana-de-açúcar: Comparação entre 40 e 500 Imagens	71
5.2.1	Análise Quantitativa	72
5.2.2	Análise Qualitativa	73
5.3	Experimento III - Milho	76
5.3.1	Treinamento realizado com 200 imagens	77
	Análise Quantitativa	77
	Análise Qualitativa	78
5.3.2	Treinamento realizado com 1.000 imagens	79
	Análise Quantitativa	79
	Análise Qualitativa	80
5.4	Experimento IV - Imagens de Satélite	81
5.4.1	Análise Quantitativa	82
5.4.2	Análise Qualitativa	82
5.4.3	<i>Ground Truth</i> com as Imagens de VANT	83
	Análise Quantitativa	84
	Análise Qualitativa	86
5.5	Investigação do Impacto das Imagens de Alta Resolução no Monitoramento Agrícola	88
6	Conclusões, Contribuições e Trabalhos Futuros	90
6.1	Conclusões	90
6.2	Contribuições	91
6.2.1	Contribuições Acadêmicas	91
6.2.2	Contribuições Práticas	91
6.3	Trabalhos Futuros	93

7	Publicações Científicas	94
	Referências Bibliográficas	96
8	Termos de Direitos de Cópia de Publicações Utilizadas Nesta Tese	103
8.1	Artigo: A Systematic Review of the Literature on Machine Learning Methods Applied to High Throughput Phenotyping in Agricultural Production	103
8.2	Artigo: Upsampling of Unmanned Aerial Vehicle Images of Sugarcane Crop Lines with a REAL-ESRGAN	104
8.3	Artigo: Deep Learning for Super Resolution of Sugarcane Crop Line Imagery from Unmanned Aerial Vehicles	105
8.4	Artigo: Enhancing Corn Image Resolution Captured by Unmanned Aerial Vehicles With the Aid of Deep Learning	109

Lista de Figuras

2.1	Exemplo de Veículos Aéreos Não Tripulados. a) DJI Phantom 4 RTK. b) Matrice 300 RTK. Figura adaptada de Czyża et al. (2023)	30
2.2	Exemplo de Aeronaves Remotamente Pilotadas - <i>Remotely Piloted Aircraft</i> (RPA). Figura adaptada de Zhang and Kovacs (2012)	31
2.3	Fases do ciclo de vida da cana-de-açúcar. Figura adaptada de Sobrinho et al. (2019)	33
2.4	Fases do ciclo de vida do milho. Figura adaptada de Sobrinho et al. (2019)	35
2.5	Imagem original de tamanho 3×3 à esquerda, representada na tabela, e a imagem gerada à direita, conforme a tabela de valores de <i>pixel</i> .	37
2.6	Resultado de reamostragem aplicando a técnica de Vizinhos Mais Próximos, ilustrado pela tabela à esquerda (com valores originais de <i>pixel</i>) e pela imagem à direita (após a aplicação da técnica).	38
2.7	Resultado de reamostragem aplicando a técnica Bilinear, ilustrado pela tabela à esquerda (com valores originais de <i>pixel</i>) e pela imagem à direita (após a aplicação da técnica).	39
2.8	Resultado de reamostragem aplicando a técnica bicúbica, ilustrado pela tabela à esquerda (com valores originais de <i>pixel</i>) e pela imagem à direita (após a aplicação da técnica).	39
2.9	Arquitetura do Real-ESRGAN. Figura adaptada de Wang et al. (2021).	42
2.10	O SR-LUT é obtido armazenando os valores de saída de uma rede profunda de SR treinada. Figura adaptada de Li et al. (2022)	44
2.11	Indexação complementar. Com os dois novos padrões de indexação propostos por Li et al. (2022). Os <i>pixel</i> vizinhos que são perceptíveis estão marcados com caixas tracejadas. Figura adaptada de Li et al. (2022)	44
2.12	Diferentes reamostragens do LeRF. Figura adaptada de Li et al. (2023)	46
4.1	Fluxograma do processo metodológico.	55
4.2	Ortomosaicos de plantios de cana-de-açúcar. Figura adaptada de Rocha et al. (2022).	56
4.3	Exemplo das imagens contidas no conjunto de dados de Zermas et al. (2021)	57
4.4	Fluxo das etapas realizadas para a construção dessa base de dados.	58
4.5	Exemplo de imagens contidas no conjunto de dados de satélite.	60
5.1	Amostra de comparação de algoritmo na mesma região (em vermelho): (a) Imagem alta resolução espacial capturada pelo VANT; (b) Imagem resultante após a aplicação da técnica Real-ESRGAN. (Amplie para melhor visualização.)	69

5.2	Imagem de Baixa Resolução (BR) com aplicação dos métodos para melhor resolução espacial: Vizinhos mais próximos, Bilinear, Bicubico e Real-ESRGAN.	70
5.3	Filtro Laplaciano na imagem para reduzir o efeito serrilhado. (a) Algoritmo tradicional do vizinho mais próximo. (b) Vizinho mais próximo com filtro de suavização. (c) Real-ESRGAN aplicado à mesma região sem filtro de suavização. (Amplie para uma melhor visualização)	70
5.4	Comparação dos resultados obtidos com diferentes escalas e seus respectivos algoritmos.	71
5.5	Amostra de comparação de algoritmo na mesma região (em vermelho): (a) Imagem de alta resolução espacial capturada pelo VANT; (b) Imagem resultante após técnica Real-ESRGAN; (c) Imagem resultante após técnica MuLUT. (Amplie para melhor visualização.)	73
5.6	Resultados obtidos treinando as redes com 40 imagens. a) Imagem do reduzida para fins de teste. b) Resultados após aplicar as TTRs e de SRRP na imagem de baixa resolução espacial.	74
5.7	Resultados obtidos pelas TTRs e SRRP, com treinando usando 500 imagens.	74
5.8	Resultados obtidos ao aplicar as técnicas de SRRP em duas imagens da base de testes que continham árvores.	75
5.9	Comparação visual do impacto da variação de escala no resultado do método Real-ESRGAN.	77
5.10	Avaliação das TTRs em comparação com as técnicas de SRRP para 200 imagens.	79
5.11	Avaliação das TTRs em comparação com as técnicas de SRRP para 1.000 imagens. (Ampliar para melhor visualização)	80
5.12	Comparação entre as diferentes técnicas utilizadas para gerar as imagens artificiais. A região analisada da imagem original de satélite está destacada de vermelho, as regiões analisadas das imagens geradas artificialmente estão destacadas de azul.	83
5.13	Comparação entre as técnicas aplicadas as imagens de satélite e VANT ambas com a mesma resolução espacial. (Ampliar para melhor visualização)	86
5.14	Comparação entre as imagens criadas artificialmente via Real-ESRGAN (aumentando em 3× e 4×) com a imagem de VANT em sua resolução espacial original.(Ampliar para melhor visualização)	88
5.15	Comparação das imagens geradas artificialmente aplicando as TTRs e as técnicas SRRP em uma região de mancha na planta. (Ampliar para melhor visualização)	89

Lista de Tabelas

3.1	Comparativo entre os trabalhos relacionados.	53
5.1	Avaliação das TTRs em comparação com Real-ESRGAN treinado com 40 imagens de cana-de-açúcar.	68
5.2	TTR vs SRRP (40 imagens).	72
5.3	TTR vs SRRP (500 imagens).	73
5.4	Avaliação das TTRs em comparação com MuLUT, LeRF e Real-ESRGAN para 200 imagens.	78
5.5	Avaliação das TTRs em comparação com as técnicas de SRRP para 1.000 imagens.	80
5.6	Avaliação das TTRs em comparação com Real-ESRGAN para as imagens de satélite.	82
5.7	Avaliação das TTRs e Real-ESRGAN para gerar imagens artificiais a partir das imagens de VANT na mesma resolução espacial do que as imagens de satélite.	85
5.8	Avaliação das TTRs em comparação com Real-ESRGAN para imagens de satélite das regiões de cana-de-açúcar de (Rocha et al., 2022).	85

Introdução

Este capítulo apresenta a introdução ao tema da pesquisa, abordando o contexto e a relevância do estudo no cenário atual da agricultura, particularmente no que se refere ao uso de imagens de VANT e satélite para o monitoramento agrícola. Inicialmente, são discutidos os desafios impostos pelas mudanças climáticas e pelo crescimento populacional, que exigem uma maior eficiência na produção de alimentos. Em seguida, é apresentada a definição do problema, que se concentra na otimização do uso de VANT e satélites para coleta de dados agrícolas.

O capítulo também descreve os objetivos da pesquisa, os quais envolvem a aplicação e comparação de diferentes técnicas para melhorar a resolução espacial de imagens agrícolas. A justificativa e a hipótese da pesquisa são expostas, destacando a importância do estudo para o aprimoramento do monitoramento agrícola. Por fim, é apresentada a contribuição desta pesquisa, que visa preencher lacunas existentes na literatura ao comparar abordagens tradicionais e modernas para o melhoramento da resolução espacial das imagens.

1.1 Contextualização

O impacto das mudanças climáticas no setor agrícola e no meio ambiente está se intensificando a uma taxa significativa. Com a crescente demanda por alimentos, impulsionada pelo aumento contínuo da população global, isso representa um desafio significativo para o setor agrícola (FAOSTAT, 2023). De acordo com dados das Nações Unidas, a população mundial deve atingir 9,7 bilhões em 2050 e continuar crescendo até um pico de aproximadamente 10,4 bilhões na década de 2080 (UN, 2021), destacando a necessidade de um aumento proporcional na produção de alimentos para atender a essa projeção populacional crescente.

Em resposta a esses desafios mencionados anteriormente, o monitoramento eficiente da agricultura desempenha um papel fundamental no desenvolvimento de práticas mais sustentáveis, como a redução do consumo de água, fertilizantes e pesticidas. O uso de imagens de satélite e de VANT tem se mostrado uma ferramenta essencial para a

captura de dados agrícolas, oferecendo informações valiosas para o manejo das culturas de grande importância econômica, como a cana-de-açúcar e o milho (Dang et al., 2023; Som-ard et al., 2024). Essas imagens desempenham um papel crucial na agricultura de precisão, proporcionando dados detalhados sobre as culturas e permitindo a análise de aspectos importantes como monitorar o crescimento e a saúde das plantas, a presença de ervas daninhas e eficiência no uso de recursos (Niu et al., 2024; Castro-Valdecantos et al., 2022).

Esse monitoramento, quando realizado de forma preventiva, pode reduzir os custos de forma significativa. Por exemplo, um manejo insuficiente de ervas daninhas pode resultar em perdas de rendimento superiores a 50%, ou até 90%, se as ervas daninhas não forem controladas a tempo (Manalil et al., 2017). Portanto, as abordagens computacionais não apenas contribuem para aumentar a produtividade, mas também para reduzir os custos de produção (Hassan et al., 2021; Jonak et al., 2024).

Para um monitoramento eficiente das culturas, a coleta de dados é fundamental. No entanto, áreas agrícolas extensas tornam esse processo demorado e caro com dispositivos terrestres, como veículos ou robôs. O uso de VANT e satélites torna a captura de dados mais eficiente, reduzindo tempo e recursos (Ong et al., 2023). Porém, ao aplicar essas tecnologias em grandes áreas, surgem desafios, especialmente na maximização da cobertura com custos e tempo reduzidos. A resolução espacial das imagens também desempenha um papel crucial, pois imagens de alta resolução espacial permitem uma análise detalhada das variações nas culturas, oferecendo informações mais precisas.

Contudo, a obtenção de imagens de alta resolução espacial em grandes áreas agrícolas é um desafio, uma vez que essas imagens necessitam de um maior tempo de captura devido à necessidade de voos mais longos ou passagens repetidas para cobrir grandes extensões. Além disso, o equipamento necessário para capturar essas imagens de alta resolução espacial geralmente deve ser mais sofisticado e necessitar de maior manutenção, o que pode aumentar os custos operacionais. Portanto, apesar de sua importância, a obtenção de imagens de alta resolução espacial se torna um obstáculo significativo quando se busca monitorar grandes áreas de cultivo (Som-ard et al., 2024).

1.2 Definição do Problema

Para otimizar a aplicação prática de VANT em atividades agrícolas, é fundamental reduzir o tempo de voo e maximizar a eficiência na coleta de dados. Uma abordagem eficaz para alcançar esse objetivo é aumentar a altitude de voo. Voar a uma altura maior, por exemplo, entre 90 e 100 metros acima do solo, pode reduzir significativamente o tempo total de aquisição de dados, quando comparadas com alturas menores de voo, além de permitir a cobertura de uma área mais extensa em uma única imagem. No entanto,

imagens capturadas por **VANT** em altitudes elevadas apresentam desafios consideráveis, como desfoque, baixa resolução espacial e diminuição do tamanho dos alvos, o que pode comprometer a precisão dos algoritmos de detecção de objetos (Chang et al., 2023). Embora ajustar a altitude do voo possa melhorar a resolução espacial das imagens, novas limitações surgem devido ao movimento das culturas causado pelas hélices do **VANT**, o que resulta em sobreposição de imagens e pode impactar a qualidade da captura e análise.

Embora as imagens de satélite gratuitas, ofereçam uma visão ampla para grandes áreas, frequentemente apresentam uma resolução espacial limitada, o que pode dificultar a análise detalhada das culturas agrícolas em larga escala. Para superar essas limitações, é necessário explorar novas abordagens para melhorar a qualidade das imagens capturadas, tanto por **VANT** quanto por satélites.

1.3 Objetivos

O objetivo geral deste estudo é investigar a aplicação de técnicas de aprendizado profundo para melhorar a resolução espacial de imagens agrícolas, avaliando os resultados dessas abordagens em comparação com métodos tradicionais de reamostragem, com o intuito de identificar as técnicas mais eficazes para auxiliar no monitoramento das culturas agrícolas. Para atingir este objetivo geral, os seguintes objetivos específicos se fazem necessários:

- Revisar as principais técnicas utilizadas para melhorar a resolução espacial de imagens agrícolas.
- Coletar e preparar os conjuntos de dados de imagens agrícolas capturadas por **VANT** e satélites.
- Aplicar as Técnicas Tradicionais de Reamostragem (**TTR**), como Vizinhos mais Próximos, interpolação Bilinear e Bicúbico, em imagens agrícolas, avaliando os impactos na resolução espacial.
- Modificar e treinar as técnicas de Super-Resolução com Redes Profundas (**SRRP**), como *Real Enhanced Super-Resolution Generative Adversarial Network* (**Real-ESRGAN**) e *Multi-Level upscaling Transform* (**MuLUT**), em imagens agrícolas para melhorar sua resolução espacial.
- Comparar o impacto das **TTRs** e das técnicas de **SRRP** na qualidade das imagens geradas, utilizando métricas como *Peak Signal-to-Noise Ratio* (**PSNR**) e *Structural Similarity Index* (**SSIM**), juntamente com uma análise qualitativa.
- Investigar o impacto das imagens de alta resolução espacial no monitoramento agrícola.

1.4 Justificativa

Apesar das limitações associadas ao uso de **VANT** e satélites, a crescente demanda por monitoramento agrícola de alta precisão, especialmente em culturas de grande relevância econômica, como cana-de-açúcar e milho, exige imagens de alta resolução espacial para identificar padrões de desenvolvimento, saúde e produtividade das plantas (Som-ard et al., 2024; Niu et al., 2024). Além disso, essas imagens são cruciais para otimizar processos agrícolas, como irrigação e controle de pragas (Castro-Valdecantos et al., 2022).

Embora as **TTRs**, como Vizinhos Mais Próximos (Rosenfeld, 1976), Bilinear (Rosenfeld, 1969) e Bicúbico (Keys, 1981), possam ser usadas para melhorar a resolução espacial, elas falham em capturar detalhes finos e nuances importantes para uma análise agrícola precisa (Zhang et al., 2021). Por outro lado, as técnicas de **SRRP**, como **Real-ESRGAN** (Wang et al., 2021), **MuLUT** (Li et al., 2022) e *Learning Resampling Function* (**LeRF**) (Li et al., 2023), são desenvolvidas com o propósito de gerar imagens de Alta Resolução (**AR**) a partir de imagens de entrada de **BR** (Jonak et al., 2024). Ao aumentar a resolução espacial das imagens de entrada, os algoritmos oferecem melhorias significativas na qualidade visual e reduzem substancialmente os níveis de degradação, comumente observados ao simplesmente aumentar a escala de imagens usando as **TTRs** (Ledig et al., 2017; Wang et al., 2021). As técnicas de **SRRP** podem ser vistas como uma grande promessa para melhorar a resolução espacial de imagens agrícolas. Por isso, é fundamental explorar e comparar o desempenho dessas abordagens para determinar a mais eficaz em melhorar a resolução espacial das imagens essenciais para o monitoramento agrícola.

1.5 Hipótese e Contribuição da Pesquisa

Nesta pesquisa, tem-se como hipótese de pesquisa que a aplicação de técnicas de super-resolução com redes neurais profundas para melhorar a resolução espacial de imagens agrícolas venha a proporcionar melhores resultados do que as técnicas tradicionais de reamostragem.

Neste sentido, a principal contribuição desta pesquisa está na investigação e comparação do impacto das diferentes técnicas de melhoramento de resolução espacial em imagens agrícolas, com foco em um cenário que envolve múltiplas culturas (como cana-de-açúcar e milho) e diferentes plataformas de captura de imagens, como **VANT** e satélites.

Embora existam diversos estudos que abordam o uso de **VANT** ou satélites para monitoramento agrícola (Naidoo et al., 2021; Velumani et al., 2021; Som-ard et al.,

2024; Niu et al., 2024), não conseguimos encontrar até o momento nenhum trabalho que explorasse a comparação das diferentes técnicas de melhoramento de resolução espacial em imagens agrícolas. Este trabalho preenche essa lacuna, ao oferecer uma análise dos resultados dos algoritmos modernos de **SRRP**, como **Real-ESRGAN**, **MuLUT** e **LeRF**, em contraste com as **TTRs**, como **Vizinhos Mais Próximos**, **Bilinear** e **Bicúbico**. Possibilitando assim auxiliar na escolha dos métodos mais adequados para as diferentes situações práticas, como o uso de imagens de satélite ou **VANT** em grandes áreas agrícolas de cana-de-açúcar e milho.

Este estudo também contribui para o aprimoramento das técnicas de processamento de imagens no contexto agrícola, expandindo o uso de algoritmos de aprendizado profundo, que originalmente foram desenvolvidos para lidar com imagens de rostos, animes e outros tipos de imagens. Até o momento, não foram encontrados estudos que aplicassem as técnicas de **SRRP** especificamente no contexto agrícola.

Para a realização dos testes em imagens de satélite, construímos uma base de dados com imagens das 10 maiores regiões produtoras de cana-de-açúcar do estado de Goiás. As imagens foram obtidas por meio da plataforma Planet¹, que disponibiliza imagens com resolução espacial de até 3 metros por *pixel*, de forma gratuita.

Além disso, foi criada uma base de dados contendo imagens com a resolução espacial melhorada, das culturas de cana-de-açúcar e milho, capturadas por **VANT** ou satélite. Essas imagens de melhor resolução espacial podem auxiliar no monitoramento e manejo das culturas, no planejamento de insumos, no controle de pragas, doenças e na gestão de irrigação, visando otimizar a produtividade e reduzir os custos operacionais.

1.6 Estrutura da Tese

Este estudo está organizado da seguinte maneira: o Capítulo 2 apresenta os principais conceitos utilizados nesta pesquisa. O Capítulo 3 oferece uma visão geral dos trabalhos relacionados a este estudo. No Capítulo 4, são descritos os métodos e materiais empregados na realização deste trabalho. O Capítulo 5 aborda as configurações experimentais, bem como as descobertas e discussões geradas a partir dos resultados. O Capítulo 6 apresenta a conclusão deste estudo e aponta possíveis direções para futuras investigações. Por fim, o Capítulo 7 apresenta as publicações resultantes deste trabalho.

¹<https://www.planet.com>

Fundamentação Teórica

Este capítulo apresenta os conceitos fundamentais relacionados às ferramentas e tecnologias empregadas nesta tese. Inicialmente, serão abordadas os tipos de resolução em imagens e as tecnologias de captura de imagens, como [VANT](#) e satélites, destacando suas vantagens e limitações no contexto da agricultura. Serão descritas também as culturas agrícolas (cana-de-açúcar e milho) utilizadas nos experimentos, com ênfase nas características específicas de cada uma. Em seguida, exploraremos as [TTRs](#) e as técnicas de [SRRP](#), essenciais para o melhoramento da resolução espacial das imagens capturadas.

2.1 Tipos de Resolução em Imagens Agrícolas

Existem diferentes tipos de resolução que são usados para descrever a qualidade e a capacidade de detecção em sistemas de monitoramento, como imagens de satélite ou [VANT](#). Aqui estão os principais tipos de resolução:

- **Resolução Espectral:** Refere-se à capacidade de um sensor de capturar diferentes faixas de comprimento de onda (cores ou bandas espectrais) do espectro eletromagnético. Sensores com alta resolução espectral podem distinguir mais detalhes em diferentes faixas, como luz visível, infravermelho ou micro-ondas, o que permite uma análise mais detalhada das características das superfícies (por exemplo, distinguir diferentes tipos de vegetação) ([Campbell and Wynne, 2011](#)).
- **Resolução Temporal:** Relacionada à frequência com que um sensor captura imagens de uma determinada área. Sensores com alta resolução temporal são capazes de coletar dados frequentemente, o que é crucial para monitorar mudanças rápidas, como variações no crescimento de culturas ou desastres ambientais. Isso é expresso como o intervalo de tempo entre duas imagens consecutivas (por exemplo, diariamente, semanalmente, etc.) ([Schott, 2007](#)).
- **Resolução Radiométrica:** Refere-se à capacidade do sensor de medir a intensidade de radiação eletromagnética com precisão. A resolução radiométrica é geralmente expressa pelo número de bits usados para quantificar a intensidade de luz, como 8

bits, 16 bits, etc. Quanto maior a resolução radiométrica, mais níveis de intensidade podem ser capturados, o que resulta em imagens mais detalhadas em termos de brilho e contraste (Wang and Myint, 2015).

- **Resolução Espacial:** Refere-se à capacidade de um sensor em distinguir detalhes no espaço. Ela é expressa em termos de distância entre dois pontos na superfície terrestre que podem ser capturados como objetos distintos em uma imagem. Em outras palavras, quanto menor o valor da resolução espacial, mais detalhada a imagem será. Por exemplo, uma resolução espacial de 10 metros significa que o sensor pode distinguir objetos que estão a 10 metros de distância um do outro (Jensen, 2009).

Neste trabalho, nosso foco foi melhorar a resolução espacial das imagens. Na próxima seção, exploraremos como as imagens RGB podem ser aplicadas no monitoramento das plantações.

2.2 Uso de Imagens RGB no Monitoramento Agrícola

O uso de imagens no contexto agrícola está tendo um crescimento significativo nos últimos anos. E um fator para isso é a demanda por tecnologias que otimizem o monitoramento e a gestão das culturas. Por meio de sensores remotos, como satélites, VANT e câmeras especializadas, é possível obter informações detalhadas sobre o estado das plantações.

Essas imagens podem ser obtidas em diferentes escalas e resoluções, dependendo do equipamento utilizado e da finalidade da análise. Um tipo de imagem amplamente empregado em estudos agrícolas é o RGB.

As imagens RGB são aquelas compostas por três canais de cores: vermelho (Red), verde (Green) e azul (Blue). Esses três canais correspondem às cores primárias que formam a percepção visual das imagens capturadas por câmeras digitais e sensores de imagem. Diferente das imagens multispectrais ou hiperespectrais, que capturam informações em várias faixas espectrais, as imagens RGB fornecem uma representação visual da cena que é intuitivamente compreensível para o olho humano. Elas são amplamente usadas em plataformas de sensoriamento remoto devido à sua simplicidade e ao fato de que refletem a luz visível, ou seja, a radiação que pode ser captada pelos sensores dessas plataformas (Fisher et al., 2018).

Embora as imagens RGB sejam úteis para representar a paisagem de maneira visual, elas possuem algumas limitações. A resolução espacial (definida como o tamanho do *pixel* na imagem) pode variar conforme a plataforma que captura as imagens. No caso dos satélites, a resolução espacial é muito mais baixa, devido à maior altitude de

captura, enquanto os **VANTs**, que voam em menores altitudes, podem fornecer imagens com resolução espacial significativamente mais alta (Colomina and Molina, 2014).

A obtenção de imagens RGB pode ser realizada por diferentes plataformas, como **satélites** e **VANT**, cada uma com suas vantagens e limitações em termos de resolução espacial, temporal, cobertura geográfica e custos operacionais.

2.2.1 Satélites na Análise Agrícola

Os satélites são ferramentas de captura essenciais para o sensoriamento remoto, oferecendo uma cobertura global e contínua. Equipados com sensores ópticos, multiespectrais e hiperespectrais, eles fornecem informações detalhadas sobre a superfície terrestre, possibilitando análises como monitoramento das culturas, detecção de mudanças ambientais e planejamento agrícola. Alguns exemplos de satélites com câmeras RGB de alta resolução espacial incluem os satélites da WorldView (DigitalGlobe), que oferecem imagens com resolução espacial de até 31 cm, e os satélites da GeoIQ, contudo, possuem um custo muito elevado para o *download* das imagens, já os gratuitos como Landsat são 30 metros por *pixel*, Sentinel-2 até 10 metros por *pixel* e o Planet de até 3 metros por *pixel* (Technologies, 2024; Sentinel Hub, 2024).

Na agricultura, os satélites são amplamente utilizados para monitorar a saúde das plantas, realizar estimativas de produtividade, auxiliar na detecção de estresses hídricos e pragas em larga escala. Essas aplicações são fundamentais para culturas extensivas, como cana-de-açúcar e milho, em que as imagens com ampla cobertura ajudam a reduzir custos e a aumentar a eficiência operacional (Hassan et al., 2021; Sishodia et al., 2020; Segarra et al., 2020).

No entanto, os satélites apresentam algumas limitações, como a resolução espacial baixa, que pode dificultar análises mais detalhadas. Além disso, esse tipo de imagem pode enfrentar problemas de cobertura devido à presença de nuvens e, finalmente, os intervalos de revisita¹ podem ser insuficientes para monitoramento em tempo real, como na análise do avanço de pragas ou dos impactos de eventos climáticos (Merchant, 2000).

Além dos satélites, outra maneira de realizar a captura de imagens agrícolas são os **VANTs** descritos a seguir.

¹Intervalos de revisita: refere-se ao tempo que um satélite leva para passar novamente sobre a mesma área da superfície terrestre. Esse intervalo varia dependendo do tipo de órbita do satélite e de sua posição. Por exemplo, no Sentinel-2, esse tempo é de 5 dias, no Landsat é de 16 dias, enquanto no Planet é de um dia ou menos, dependendo da posição do satélite.

2.2.2 Veículos Aéreos Não Tripulados na Análise Agrícola

Os **VANTs** são aeronaves que operam sem a presença de um piloto a bordo, podendo ser controladas remotamente ou, em alguns casos, operar de forma autônoma. Os **VANTs** oferecem uma resolução espacial superior em comparação com satélites, pois operam a altitudes muito mais baixas (geralmente entre 100 e 200 metros). Câmeras RGB de **VANT**, como as instaladas nos modelos DJI Phantom 4 RTK ou Matrice 300 RTK (exemplo desses modelos pode ser observado na Figura 2.1), podem alcançar resoluções de até 2 a 5 cm por *pixel*, proporcionando um nível de detalhamento muito maior do que as imagens de satélites, que geralmente possuem resoluções de 10 metros ou mais. Essa capacidade torna os **VANTs** altamente eficazes para monitorar pequenos detalhes, como a saúde das culturas e a variabilidade do solo (Manfreda et al., 2018).



Figura 2.1: Exemplo de Veículos Aéreos Não Tripulados. a) DJI Phantom 4 RTK. b) Matrice 300 RTK. Figura adaptada de Czyża et al. (2023)

Os **VANTs** incluem ainda uma categoria específica, conhecida como **RPA**, controladas por operadores em solo, o que pode melhorar o planejamento dos voos e a coleta de dados.

Remotely Piloted Aircraft

Os **RPAs**, ou Aeronaves Remotamente Pilotadas, são um subtipo de **VANT** que se distingue pela necessidade de um controle constante por parte de um piloto humano. Um exemplo de **RPA** pode ser observado na Figura 2.2. A principal diferença entre **VANT** e **RPA** está no grau de autonomia: enquanto um **VANT** pode ser programado para operar de forma autônoma, um **RPA** requer que o piloto o controle remotamente durante toda a missão. Ou seja, enquanto todos os **RPAs** são **VANTs**, nem todos os **VANTs** são **RPAs** (Giordan et al., 2018). Por esse motivo, em nosso trabalho adotaremos apenas o termo **VANT** que também já contempla **RPA**.

A flexibilidade de voo dos **VANTs** permite o monitoramento detalhado de pequenas e médias áreas, sendo úteis para identificar estresses hídricos, pragas e deficiências



Figura 2.2: *Exemplo de Aeronaves Remotamente Pilotadas - RPA.*
Figura adaptada de Zhang and Kovacs (2012)

nutricionais. Eles também podem auxiliar na criação de mapas de produtividade e detecção de padrões de desenvolvimento ao longo do ciclo de cultivo (Guebsi et al., 2024). No entanto, essa melhor resolução espacial vem com algumas limitações, como a dependência de bateria e um maior custo por área coberta, especialmente quando comparados aos satélites gratuitos. Além disso, os VANTs capturam áreas menores por voo, o que exige um planejamento das missões para cobrir grandes áreas de forma eficiente. Como o alcance de voo dos VANTs é restrito pela capacidade da bateria e pela duração do voo, seu uso é mais indicado para monitoramento em escala local. Para áreas maiores, é necessário realizar múltiplos voos ou utilizar estratégias de cobertura sistemática, a fim de evitar lacunas nas imagens e garantir a continuidade dos dados capturados.

Embora os VANTs apresentem uma resolução espacial superior em comparação às imagens de satélite, ainda existem desafios ao usar esses sistemas para a captura de imagens agrícolas, especialmente nas culturas analisadas no trabalho, como cana-de-açúcar e milho. Para um melhor entendimento sobre as características dessas culturas, elas serão melhor descritas a seguir.

2.2.3 Ciclo de Vida da Cana-de-Açúcar e Monitoramento Agrícola

A cana-de-açúcar é uma planta perene da família Poaceae, amplamente cultivada em regiões tropicais e subtropicais, sendo uma das principais fontes de produção de açúcar, etanol e biocombustíveis. O cultivo de cana-de-açúcar no Brasil é de grande relevância econômica, representando uma das maiores produções agrícolas do país, especialmente no contexto das usinas de açúcar e etanol.

Segundo Verma et al. (2024) as fases do ciclo de vida da cana-de-açúcar podem ser divididas da seguinte forma:

- **Fase E-0: Pré-Germinação:** A fase E-0 corresponde a pré-germinação. Nesse estágio, as mudas de cana são plantados no solo, e o processo de desenvolvimento do broto começa internamente. O broto ainda não emerge acima do solo, e a planta começa a utilizar as reservas armazenadas para iniciar seu crescimento.
- **Fase E-1: Germinação e Emergência:** O broto da cana começa a emergir do solo, marcando a fase de emergência. As primeiras folhas começam a se formar, e a planta dá início ao seu crescimento visível.
- **Fase E-2: Emergência e Formação Foliar:** Esta fase é caracterizada pelo início da formação foliar. A planta continua a se desenvolver com o surgimento das primeiras folhas, e a cana começa a adquirir mais estrutura vegetativa. A planta ganha altura e as raízes continuam a se expandir.
- **Fase E-3: Formação de Brotos Secundários Acima do Solo:** A fase E-3 é marcada pela formação de brotos secundários que começam a crescer acima do solo. Durante esta fase, a planta já está estabelecida no solo, e mais caule(s) começam a se formar. A planta cresce em altura e começa a formar uma estrutura mais complexa, com mais colmos secundários surgindo.
- **Fase E-4: Elongação do Caule:** A fase E-4 é marcada pelo alongamento dos colmos (caule) e a expansão vegetativa. A planta cresce significativamente em altura e o aumento da biomassa é evidente. A cana está agora mais estabelecida e com uma estrutura robusta.
- **Fase E-5: Pré-Maturação:** A fase E-5 é o período de pré-maturação, em que os colmos começam a acumular açúcares e a planta começa a entrar no processo de maturação. O crescimento vegetativo desacelera, e a planta foca mais na formação de sacarose nos colmos.
- **Fase E-6: Cana Madura:** A fase E-6 é a maturação final da cana-de-açúcar. Os colmos atingem o máximo teor de açúcar (sacarose) e estão prontos para a colheita. Este é o ponto ideal para a colheita, pois a cana apresenta o melhor rendimento de sacarose.

Essas fases do ciclo de vida da cana-de-açúcar podem ser melhor visualizadas na Figura 2.3.

No Brasil, a prática de corte da cana-de-açúcar de ano a ano envolve a utilização do sistema de socagem, em que a cana é replantada ou não replantada após a colheita, mantendo parte da planta (o tolete ou soca) no solo. Esse sistema permite que a mesma planta seja colhida anualmente, com uma nova geração de colmos surgindo a partir das socas. Após o primeiro ciclo de crescimento, a cana é colhida quando atinge a maturação (geralmente de 12 a 18 meses após o plantio).

No primeiro ciclo, a planta é cortada até o solo, removendo os colmos maduros. O que permanece no campo são os toletes (socas), que são partes do caule que ficam




Figura 2.3: Fases do ciclo de vida da cana-de-açúcar. Figura adaptada de *Sobrinho et al. (2019)*

enterradas no solo após a colheita. Depois da colheita, novas brotações surgem a partir das socas. Essas brotações crescem mais rapidamente do que a plantação inicial, o que permite um ciclo de colheita mais rápido. Esse ciclo de crescimento das socas pode ocorrer anualmente, e cada ciclo subsequente pode durar de 10 a 14 meses, dependendo das condições ambientais e das práticas de manejo. A cana de soca (nova brotação a partir das socas) é menos vigorosa e tem um rendimento menor comparado à cana de primeiro corte, mas ainda assim pode gerar uma boa produção de açúcar ou etanol. A rotação de socas é uma prática muito comum em usinas de açúcar e etanol no Brasil ([Grandis et al., 2024](#)).

Após cada ciclo de colheita da soca, o processo é repetido, e as socas continuam a brotar novas canas. Com o tempo, no entanto, a qualidade e a produtividade das socas tendem a diminuir, o que pode exigir a replantação total (substituição por novos toletes) após alguns ciclos. Após vários ciclos de socagem (geralmente de 3 a 5 ciclos), a produtividade das socas começa a cair significativamente. Nesse momento, a rotação de socas é interrompida, e um novo plantio é realizado, reiniciando o ciclo da cana. O novo plantio exige o uso de mudas ou gomos de colmo para formar a base de uma nova geração de cana ([Grandis et al., 2024](#)).

Devido ao ciclo de vida da cana-de-açúcar ser longo, com várias fases vegetativas e de maturação, é extremamente interessante um monitoramento contínuo, principalmente durante as fases de crescimento e colheita. O uso de tecnologias de monitoramento, como [VANT](#), pode otimizar a detecção precoce de problemas, de modo a minimizar as perdas e maximizar os lucros.

A cana-de-açúcar apresenta uma estrutura única, com caules (ou colmos) altos e segmentados, podendo atingir até 6 metros de altura, dependendo das condições ambien-

tais. Sua folhagem é espessa e longa, o que pode dificultar a visualização clara das plantas em imagens aéreas devido ao seu dossel denso.

Além da cana-de-açúcar, outras culturas são extremamente importantes para a segurança alimentar, como o milho, que será melhor explorado a seguir.

2.2.4 Estágios Vegetativos do Milho e Monitoramento Agrícola

Os estágios vegetativos do milho (*Zea mays*) são fundamentais para entender seu ciclo de crescimento e determinar os melhores momentos para adubação, irrigação, controle de pragas e colheita. A escala de estágios vegetativos do milho, conhecida como **escala de V**, descreve as fases principais do desenvolvimento da planta desde a germinação até a maturação (V-1 a V-18), mas para simplificar, vamos focar nos estágios mais comuns e suas características principais (Muchow and Carberry, 1989; Guo et al., 2022). A seguir, apresentamos as principais fases dessa escala:

- **V-0: Germinação** A germinação é o primeiro estágio, em que o grão de milho começa a se desenvolver após ser plantado no solo.
- **V-1: Primeira folha verdadeira** O milho atinge o estágio V-1 quando desenvolve a primeira folha verdadeira, a primeira folha funcional capaz de realizar a fotossíntese de forma eficiente.
- **V-2: Segunda folha verdadeira** O milho atinge o estágio V-2 quando a segunda folha verdadeira emerge.
- **V-3: Terceira folha verdadeira** A planta de milho atinge o estágio V-3 quando a terceira folha verdadeira começa a aparecer.
- **V-4: Quarta folha verdadeira** Quando a quarta folha verdadeira aparece, o milho atinge o estágio V-4.
- **V-5 a V-7: Formação de folhas adicionais** De V-5 a V-7, o milho continua a formar novas folhas.
- **V-8: Início da formação de gemas (botões da inflorescência)** O estágio V-8 marca o início da formação das gemas de inflorescência, ou seja, o milho começa a se preparar para a formação das espigas e das flores.
- **V-10 a V-12: Estágio vegetativo final** Entre os estágios V-10 e V-12, a planta de milho já está bem estabelecida e começa a se preparar para a fase reprodutiva.
- **V-13 a V-15: Preparação para a inflorescência** Os estágios V-13 a V-15 são indicativos que a planta está totalmente desenvolvida vegetativamente e começa a preparar-se para a fase reprodutiva.

Após o estágio V-15, a planta de milho entra no estágio *Vegetative Tasseling* (VT), que marca o início da transição para a fase reprodutiva. Nesse estágio, a planta

começa a formar a panícula (ou “tassel”), estrutura reprodutiva masculina responsável pela liberação do pólen. Este é um estágio vegetativo que prepara a planta para a polinização, que ocorrerá posteriormente. Após o estágio **VT**, a planta entra efetivamente no estágio reprodutivo, que é marcado pela polinização e pela formação da espiga. Após a polinização, o milho entra nas fases de enchimento de grãos e maturação, que são fases de desenvolvimento reprodutivo, focadas no crescimento e na formação dos grãos, não mais no desenvolvimento vegetativo. Essas fases do ciclo de vida do milho podem ser melhor visualizadas na Figura 2.4.




Figura 2.4: Fases do ciclo de vida do milho. Figura adaptada de Sobrinho et al. (2019)

Entender e monitorar os diferentes estágios de desenvolvimento da planta são fundamentais para o manejo eficaz da cultura do milho. Isso permite a otimização dos recursos e a minimização dos riscos, além de determinar o momento ideal para a colheita. O desenvolvimento adequado nas fases vegetativas tem um impacto direto na produtividade final da cultura (Guo et al., 2022).

Como o milho é altamente sensível ao clima, o monitoramento de sua saúde por meio de imagens aéreas pode ser crucial para otimizar a produtividade, especialmente durante as fases de floração e maturação, permitindo assim, um gerenciamento mais eficiente das lavouras. Nesse contexto, as imagens RGB têm se mostrado ferramentas valiosas no monitoramento das culturas agrícolas. Embora essas imagens não capturem informações fora do espectro visível, elas podem oferecer dados essenciais para avaliar aspectos como vigor vegetativo, identificação de padrões anômalos no solo ou na vegetação, e até

mesmo detecção inicial de estresses em plantas [Somard et al. \(2024\)](#); [Castro-Valdecantos et al. \(2022\)](#).

Contudo, quando o intuito é extrair características das plantas, como altura, diâmetro, número de plantas e outras informações essenciais para estimativas de produtividade, a resolução espacial das imagens ainda precisa ser significativamente aprimorada, e esse será o assunto da próxima seção.

2.3 Melhoria de Resolução das Imagens Agrícolas

Para melhorar a qualidade das imagens capturadas via satélites e [VANT](#), realizamos experimentos utilizando as [TTRs](#) e as [SRRP](#), que visam revelar detalhes ocultos em imagens de baixa resolução e tornar esses dados mais acessíveis para análises posteriores.

2.3.1 Técnicas Tradicionais de Reamostragem – TTR

A reamostragem em imagens é o processo de alterar o tamanho ou a resolução de uma imagem, ajustando o número de *pixel* ou mudando sua disposição espacial. Isso é feito por meio da interpolação ou manipulação matemática dos valores dos *pixel* para produzir uma nova representação da imagem com a dimensão ou escala desejada. Em termos de **mudança de resolução**, acontece quando uma imagem precisa ser ampliada (*upsampling*) ou reduzida (*downsampling*), seja para melhor visualização, processamento ou integração em análises de diferentes resoluções. Já com as **transformações geométricas**, acontece quando a imagem é rotacionada, transladada ou projetada para um novo sistema de coordenadas (por exemplo, re-projeção geográfica). Em nosso trabalho, focamos na mudança de resolução ([Pan et al., 2023](#)).

A reamostragem é uma técnica rápida e amplamente utilizada em aplicações em tempo real, mas tem limitações, como a incapacidade de recriar detalhes mais finos ou de preservar bordas de maneira eficiente. Entre os vários métodos empregados em reamostragem três técnicas são amplamente utilizadas, a saber: Vizinheiro mais Próximo ([Rosenfeld, 1976](#)), Bilinear ([Rosenfeld, 1969](#)) e Bicúbica ([Keys, 1981](#)).

Cada uma dessas técnicas será detalhadamente descrita a seguir. Para facilitar a visualização das diferenças entre as técnicas de reamostragem criamos um cenário em que seja necessário aumentar a resolução de uma imagem de 3×3 (Figura 2.5) para 5×5 *pixel*, ou seja, iremos adicionar *pixel* entre os já existentes. As técnicas de reamostragem tradicionais vão gerar uma versão ampliada dessa imagem de maneiras diferentes, de acordo com cada técnica.

<i>pixel</i>	1	2	3
1	10	20	30
2	40	50	60
3	70	80	90




Figura 2.5: *Imagem original de tamanho 3×3 à esquerda, representada na tabela, e a imagem gerada à direita, conforme a tabela de valores de pixel.*

Reamostragem com a Técnica Vizinho mais próximo

A técnica de vizinhos mais próximos é uma das abordagens mais simples e rápida para reamostragem. Neste método, a estimativa do valor de um ponto em uma nova grade é feita selecionando o valor do ponto mais próximo da grade original. Em outras palavras, o valor atribuído ao novo ponto é o mesmo do ponto original, que está mais próximo em termos de distância (Rosenfeld, 1976).

Ao aplicar a técnica de vizinhos mais próximos para aumentar a imagem de 3×3 para 5×5 , os valores dos *pixel* seriam duplicados sem suavização, como se estivessem sendo copiados diretamente para os novos pontos. O resultado seria uma imagem 5×5 como na Figura 2.6. Algumas vantagens dessa técnica são: simplicidade e rapidez no cálculo, baixo custo computacional, o que torna essa técnica útil em cenários com grandes volumes de dados ou quando a velocidade é uma prioridade. Contudo, algumas desvantagens são que a reamostragem pode resultar em bordas serrilhadas nas imagens, pois não há suavização entre os pontos. Além de poder gerar imagens com perda de detalhes, especialmente em mudanças abruptas de valores.

Reamostragem com a Técnica Bilinear

A interpolação bilinear é uma técnica de reamostragem linear que leva em consideração os quatro pontos vizinhos mais próximos para estimar o valor de um ponto em uma nova grade. Essa técnica utiliza interpolação linear em duas direções (horizontal e vertical), sendo um dos métodos mais populares e amplamente utilizados para aumentar ou reduzir a resolução de imagens (Rosenfeld, 1969).

Para cada ponto na nova grade, a interpolação bilinear realiza primeiro uma interpolação linear entre os dois pontos horizontais mais próximos e, em seguida, realiza

<i>pixel</i>	1	2	3	4	5
1	10	10	20	20	30
2	10	10	20	20	30
3	40	40	50	50	60
4	40	40	50	50	60
5	70	70	80	80	90




Figura 2.6: Resultado de reamostragem aplicando a técnica de Vizinhos Mais Próximos, ilustrado pela tabela à esquerda (com valores originais de *pixel*) e pela imagem à direita (após a aplicação da técnica).

outra interpolação linear entre os dois pontos verticais mais próximos. O valor final do ponto é uma média ponderada desses dois resultados. Com a interpolação bilinear, os novos *pixel* são calculados com base em valores intermediários, criando uma transição mais suave entre os valores originais. A Figura 2.7 ilustra o resultado via interpolação bilinear com valores aproximados.

É possível notar que, com a técnica Bilinear, o resultado gerado tem uma melhor qualidade do que os vizinhos mais próximos, proporcionando transições mais suaves entre os pontos. Pode ser considerado simples e mais rápido do que métodos mais avançados (como a reamostragem bicúbica), mas, ainda assim, oferece resultados razoáveis em muitas situações.

Reamostragem com a Técnica Bicúbica

A reamostragem bicúbica é uma técnica mais avançada e precisa, baseada no uso de polinômios de grau 3 para estimar os valores entre os pontos. Em vez de usar apenas os pontos vizinhos imediatos, como na interpolação bilinear, a bicúbica considera uma área maior, geralmente os 16 pontos vizinhos mais próximos (4x4), para calcular o valor de um novo ponto. Isso permite um ajuste mais suave e detalhado dos valores, resultando em transições mais naturais e menos distorcidas (Keys, 1981).

Para tal, essa técnica usa uma fórmula cúbica para cada direção (horizontal e vertical). Cada uma das 16 posições ao redor do ponto a ser interpolado contribui com um peso determinado pela fórmula cúbica, o que garante uma transição mais suave entre os pontos, a Figura 2.8 exibe o resultado da aplicação desta técnica. É possível notar que essa técnica possui uma suavidade maior do que as anteriores, com transições mais naturais

<i>pixel</i>	1	2	3	4	5
1	10	15	20	25	30
2	20	25	30	35	40
3	40	45	50	55	60
4	50	55	60	65	70
5	70	75	80	85	90




Figura 2.7: Resultado de reamostragem aplicando a técnica Bilinear, ilustrado pela tabela à esquerda (com valores originais de *pixel*) e pela imagem à direita (após a aplicação da técnica).

entre os valores. Contudo, possui um maior custo computacional em comparação com os métodos bilinear e vizinhos mais próximos.

<i>pixel</i>	1	2	3	4	5
1	10	15	20	25	30
2	20	30	35	40	45
3	40	45	50	55	60
4	55	60	65	70	75
5	70	75	80	85	90




Figura 2.8: Resultado de reamostragem aplicando a técnica bicúbica, ilustrado pela tabela à esquerda (com valores originais de *pixel*) e pela imagem à direita (após a aplicação da técnica).

Embora as **TTRs** sejam eficazes para aumentar o tamanho de uma imagem (por exemplo, ampliando uma imagem de 3×3 para 5×5), elas frequentemente resultam em imagens borradas e com falta de detalhes finos. Isso ocorre porque essas técnicas apenas interpolam valores entre os *pixel* existentes, sem a capacidade de recuperar informações adicionais ou melhorar a qualidade da imagem. Para superar essas limitações, exploramos técnicas mais avançadas, conhecidas como **SRRP**, que visam não apenas aumentar a resolução das imagens, mas também restaurar detalhes sutis, proporcionando resultados mais nítidos e realistas. Essas técnicas serão descritas a seguir.

2.3.2 Super-Resolução com Redes Profundas

As técnicas de **SRRP** surgem como uma alternativa mais sofisticada. Pois elas utilizam modelos de aprendizado profundo², para melhorar a resolução das imagens de forma mais inteligente, criando novos detalhes que não estavam presentes na imagem original. Com isso, não só é possível aumentar a resolução das imagens, mas também melhorar a textura e os detalhes, gerando imagens mais nítidas e realistas.

No contexto de processamento de imagens, vários modelos de aprendizado profundo são amplamente utilizados, cada um adaptado para tarefas específicas, como classificação de imagens, segmentação, detecção de objetos, super-resolução, entre outras. Abaixo, são resumidos os principais modelos de aprendizado profundo, mais comuns e eficazes para trabalhar com imagens:

- **Redes Neurais Convolucionais (*Convolutional Neural Networks (CNN)*):** As **CNNs** são, até o momento, as redes mais utilizadas para tarefas relacionadas a imagens, devido à sua capacidade de aprender automaticamente características espaciais dos dados. Elas são especialmente eficazes em tarefas como classificação de imagens, detecção de objetos, segmentação de imagens, rastreamento de objetos, dentre outros ([Tan and Le, 2021](#)).
- **Redes Neurais de Segmentação (U-Net):** A U-Net é uma arquitetura de rede neural altamente eficaz para tarefa de segmentação de imagens. A principal característica do U-Net é sua estrutura de codificador-decodificador simétrica, o que permite capturar detalhes espaciais de diferentes resoluções. Muito utilizada em segmentação de imagens médicas, imagens de satélite, além de segmentação semântica como estrada, edifícios, pessoas e etc ([Çiçek et al., 2016](#)).
- **Redes Neurais de Detecção de Objetos (YOLO - You Only Look Once):** As redes YOLO são uma das arquiteturas mais populares para detecção em tempo real de objetos em imagens e vídeos. A principal vantagem do YOLO é que ele realiza a detecção de objetos em uma única passagem pela rede. Pode ser utilizada em detecção de objetos em tempo real, autonomia de veículos, vigilância, entre outros ([Bochkovskiy et al., 2020](#)).
- **Redes Neurais de Estilo e Transferência de Estilo:** As redes de transferência de estilo são usadas para transferir o estilo de uma imagem para outra. Essas redes são baseadas em **CNNs** e podem criar resultados visuais impressionantes, como transformar fotos em pinturas de artistas famosos ([Gatys et al., 2015](#)).

²Um modelo de aprendizado profundo (ou Deep Learning) é um tipo de modelo de aprendizado de máquina que utiliza redes neurais artificiais com múltiplas camadas (daí o termo profundo, ou deep). Essas redes são projetadas para aprender representações hierárquicas de dados complexos, realizando tarefas como classificação, previsão, tradução de idiomas, reconhecimento de imagem, etc. ([LeCun et al., 2015](#))

- **Rede Adversária Generativa (*Generative Adversarial Network (GAN)*):** As **GANs** são usadas principalmente para gerar novas imagens a partir de entradas aleatórias ou para modificar/imitar estilos de imagens. Elas consistem em duas redes: um gerador, que cria imagens sintéticas, e um discriminador, que tenta distinguir as imagens reais das geradas artificialmente. Dentre as principais aplicações desta rede estão a geração de imagens realistas, transferência de estilo, criação de imagens artificiais e super-resolução de imagens (Rombach et al., 2022).
- **Transformers:** Os Transformers são uma arquitetura de rede neural originalmente desenvolvida para processamento de linguagem natural, mas que também têm sido aplicada com sucesso em tarefas de processamento de imagens. A principal inovação dos Transformers é a utilização do mecanismo de atenção, que permite que o modelo se concentre em diferentes partes da entrada de forma flexível e eficiente. No contexto de imagens, os Transformers têm sido usados em tarefas como classificação de imagens, segmentação e detecção de objetos, oferecendo vantagens em relação às redes convolucionais tradicionais, especialmente em cenários que envolvem grandes quantidades de dados e requisitos de alta precisão (Dubey and Singh, 2024).

As técnicas de **SRRP** visam melhorar a qualidade de uma imagem de baixa resolução, aumentando sua resolução e preservando detalhes finos, textura e nitidez. Neste trabalho, foram realizados experimentos envolvendo três redes neurais profundas de super-resolução: **Real-ESRGAN** (Wang et al., 2021), **MuLUT** (Li et al., 2022) e **LeRF** (Li et al., 2023), todas detalhadas a seguir.

Super-Resolução com a Técnica Real-ESRGAN

O **Real-ESRGAN** é uma técnica de super-resolução de imagens baseada em redes neurais generativas adversárias **GAN**. Essa abordagem foi projetada para melhorar a resolução de imagens de forma realista, reconstruindo detalhes e texturas com base em aprendizado profundo. Muito utilizada para imagens de rostos, paisagens e animes. O **Real-ESRGAN** é uma versão aprimorada do modelo proposto por Wang (Wang et al., 2018) denominado *Enhanced Super-Resolution Generative Adversarial Network (ESRGAN)*.

A ideia central do **Real-ESRGAN** é usar as **GANs** para criar detalhes realistas que seriam difíceis de recriar apenas com as **TTRs** (Wang et al., 2021).

A arquitetura do **Real-ESRGAN** é baseada em uma combinação de técnicas de **CNNs** e **GANs** e pode ser observada na Figura 2.9. O modelo é projetado para gerar imagens de alta resolução de forma realista. O **Real-ESRGAN** usa um gerador com múltiplas camadas convolucionais e uma rede discriminadora para classificar as imagens

como reais ou geradas artificialmente, além de incluir diversos ruídos para simular as degradações que as imagens costumam sofrer no mundo real (Wang et al., 2021).

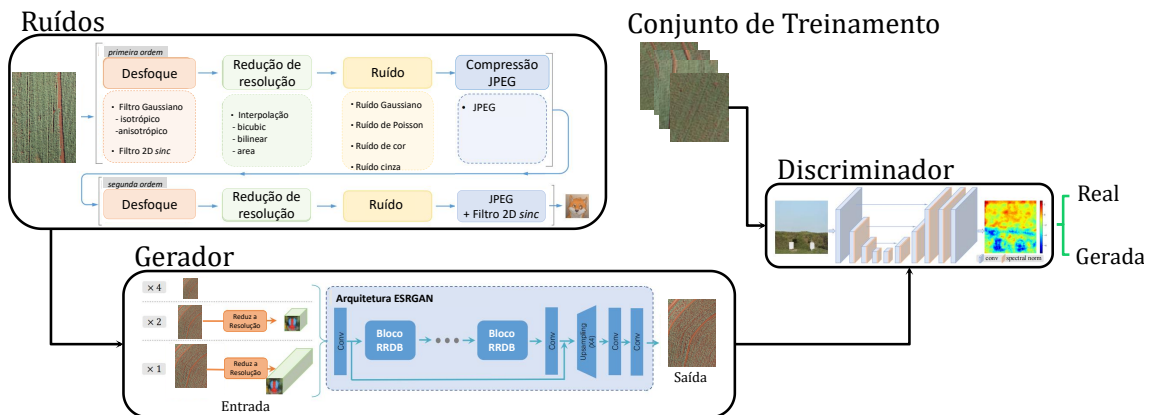


Figura 2.9: Arquitetura do Real-ESRGAN. Figura adaptada de Wang et al. (2021).

- Gerador:** O Gerador é responsável por aumentar a resolução da imagem de entrada. Ele utiliza uma arquitetura de rede neural convolucional profunda, que consiste em várias camadas convolucionais que aplicam filtros de forma hierárquica, extraindo características em diferentes escalas. O modelo segue o seguinte esquema:
 - Camadas convolucionais: Extraem características locais e globais da imagem de baixa resolução.
 - *Residual Learning*: O modelo usa técnicas de aprendizado residual, onde as características de alta resolução são somadas com as características de baixa resolução para melhorar a reconstrução de detalhes.
 - *Upscaling* (Aumento de resolução): Durante a propagação da rede, o gerador aumenta progressivamente a resolução da imagem, reconstruindo detalhes e texturas mais finas.
- Discriminador:** O Discriminador é uma rede neural que avalia se a imagem gerada pelo Gerador é realista o suficiente para ser classificada como uma imagem de alta resolução. Sua função principal é tentar distinguir entre imagens reais (de alta resolução) e imagens geradas. O discriminador ajuda a melhorar a qualidade das imagens geradas pelo gerador ao fornecer um *feedback* adversário durante o treinamento.
 - Classificação: O discriminador recebe tanto imagens reais (de alta resolução) quanto imagens geradas (de baixa resolução melhoradas pelo gerador) e tenta classificar corretamente quais são reais e quais são geradas.
 - *Feedback* Adversário: O discriminador fornece um sinal de erro ao gerador, forçando-o a melhorar a qualidade das imagens geradas a cada iteração.

Super-Resolução com a Técnica MuLUT

O termo *Look-Up Table* (**LUT**) se refere a uma tabela de consulta, ou seja, é uma estrutura de dados que mapeia entradas para saídas predefinidas. Em termos de processamento de imagem, uma **LUT** pode ser usada para realizar transformações rápidas de *pixel*. Ela permite que, dado um valor de entrada (um valor de *pixel* ou uma característica da imagem), você acesse uma saída correspondente de forma eficiente, sem ter que recalcular todo o processo. A vantagem das **LUTs** é que elas armazenam as operações em uma tabela e, em vez de realizar cálculos a cada operação, basta acessar a tabela para obter os resultados desejados.

Um **LUT** é composto por pares de **índices e valores**, que funcionam como entradas de índice para consulta e candidatos para interpolação durante a inferência, respectivamente. Esses pares de entradas de índice e valores podem ser armazenados na memória do dispositivo, resultando em alta eficiência de execução. Recentemente, [Jo and Kim \(2021\)](#) propuseram o SR-LUT, adotando o **LUT** para a tarefa de super-resolução. Como ilustrado na Figura 2.10. Durante a inferência, os valores de saída de **AR** previamente calculados são recuperados do **LUT** para os *pixel* de entrada **BR** consultados. As entradas de indexação e os valores correspondentes de **AR** de um **LUT** 4D para uma super-resolução de $2\times$ são marcados em azul e verde, respectivamente. A área receptiva real, utilizando a técnica de *rotation ensemble*, é representada com linhas tracejadas. Os valores de saída da rede SR treinada são armazenados em um **LUT**, percorrendo todos os possíveis valores de entrada. Já as previsões de **AR** são obtidas localizando os *pixel* da entrada de **BR** e interpolando os valores de **AR** armazenados. Devido ao crescimento exponencial do tamanho do **LUT** à medida que a dimensão da entrada de índice aumenta, os autores impõem uma restrição à capacidade de indexação do **LUT**, o que resulta em um campo de recepção limitado para a rede SR ser armazenada.

Para contornar essa limitação, [Li et al. \(2022\)](#) propuseram uma abordagem que aumenta a capacidade de indexação por meio da cooperação de múltiplos **LUTs**, resultando no **MuLUT**. Um dos aspectos cruciais para isso é o aumento do campo receptivo (ou *Receptive Field* (**RF**)), que determina a quantidade de informação dos *pixel* vizinhos que cada *pixel* de saída “percebe”. Ao utilizar múltiplos **LUTs** organizados em arranjos paralelos e cascadeados, o **MuLUT** amplia o **RF**, permitindo que a rede capture um contexto mais amplo da imagem e, assim, melhore significativamente a resolução final.

Cada camada do **MuLUT** realiza uma modificação progressiva da imagem. A super-resolução, portanto, ocorre por meio da combinação de múltiplos ajustes nos valores dos *pixel*. A seguir, está resumido o fluxo básico deste método:

1. **Entrada:** Uma imagem de baixa resolução (com menos detalhes, geralmente

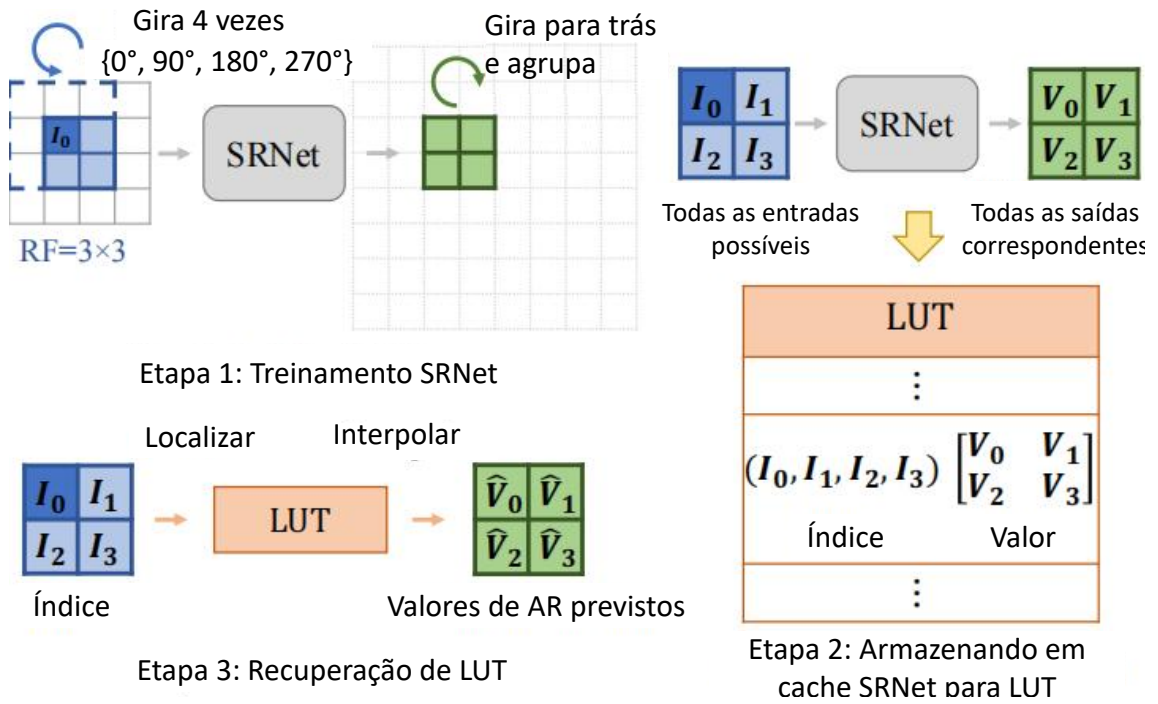


Figura 2.10: O SR-LUT é obtido armazenando os valores de saída de uma rede profunda de SR treinada. Figura adaptada de Li et al. (2022)

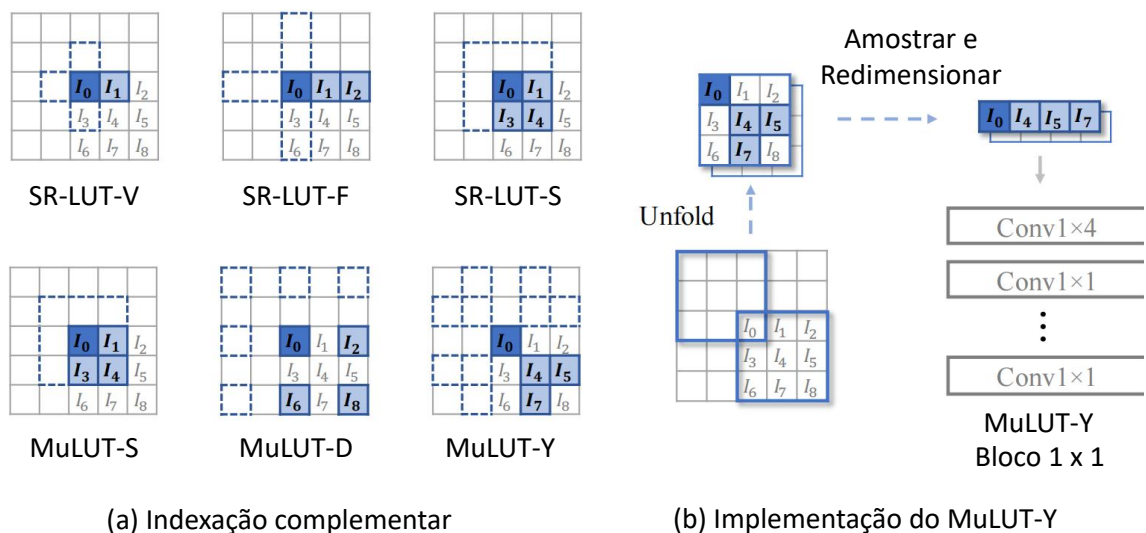


Figura 2.11: Indexação complementar. Com os dois novos padrões de indexação propostos por Li et al. (2022). Os pixel vizinhos que são perceptíveis estão marcados com caixas tracejadas. Figura adaptada de Li et al. (2022)

devido à redução de tamanho ou limitações no processo de captura).

2. **Primeira camada:** A primeira camada da **MuLUT** aplica um mapeamento inicial para aumentar a resolução, preenchendo os espaços faltantes da imagem. Isso no seu modelo tradicional é feito via técnica de reamostragem (como bilinear ou bicúbica).
3. **Camadas subsequentes:** Cada camada adicional ajusta a imagem, refinando os detalhes, melhorando as texturas e aumentando a qualidade das bordas e dos contornos. As camadas podem ser aplicadas com diferentes propósitos, como **CNNs** para refinar texturas e detalhes, além do *pixel shuffle* para aumentar a resolução com mais precisão.
4. **Saída:** A saída final é uma imagem de alta resolução com maior nitidez e mais detalhes do que a imagem original.

O conceito de camadas múltiplas é o que diferencia a **MuLUT** de uma **LUT** tradicional, que apenas realiza uma transformação direta de entrada para saída.

A técnica **MuLUT** possui uma alta eficiência computacional, pois as **LUTs** (Look-Up Tables) são capazes de realizar transformações de maneira rápida, por já terem armazenado todos os mapeamentos necessários, o que torna o cálculo da super-resolução ágil em comparação com outras técnicas que demandam operações iterativas ou convoluções pesadas. Contudo, embora a **MuLUT** ofereça vantagens interessantes, existem algumas limitações que devem ser consideradas como: a qualidade limitada em imagens extremamente degradadas, pois se a imagem original for extremamente de baixa qualidade ou perder muitos detalhes importantes, a técnica **MuLUT** pode ter dificuldades para restaurar a imagem com alta fidelidade. Outro ponto é a dependência de mapeamentos de entrada, pois a eficácia da técnica depende muito da qualidade das tabelas de consulta e dos mapeamentos utilizados. Se essas **LUTs** não forem bem treinadas ou ajustadas, a super-resolução pode resultar em artefatos ou falhas na imagem. A necessidade de adaptação aos dados é grande, para imagens muito específicas (por exemplo, imagens médicas ou científicas), é necessário ajustar as camadas de **LUT** de forma personalizada para alcançar os melhores resultados. Por isso, pode ser interessante combinar a **MuLUT** com outras técnicas avançadas de super-resolução, como redes neurais convolucionais ou modelos baseados em **GANs**, para alcançar melhores resultados.

Assim como o **MuLUT**, outra técnica também utiliza as **LUTs** para acelerar a aplicação em tempo real, o **LeRF**, proposto por [Li et al. \(2023\)](#) e é melhor descrito na seção seguinte.

Super-Resolução com a Técnica LeRF

O algoritmo **LeRF** ([Li et al., 2023](#)), apresentado em 2023, combina a eficiência dos métodos de interpolação clássicos com a capacidade de aprendizado dos modelos de

redes neurais profundas para realizar reamostragem de imagens. Seu objetivo é minimizar as limitações dos métodos tradicionais, como o desfoque causado pela invariância espacial das funções de interpolação, mas tentando manter a eficiência computacional.

Diferentemente das **TTRs**, que utilizam funções fixas para calcular novos valores dos *pixel*, o **LeRF** ajusta suas funções de reamostragem para cada região da imagem, dependendo de suas características locais. Para isso, ele usa funções como a Gaussiana anisotrópica, que pode assumir diferentes formas e orientações para se adaptar a estruturas específicas, como bordas ou texturas. Ou seja, o algoritmo analisa a imagem e aplica uma abordagem personalizada para cada *pixel* ou um conjunto de *pixel* (região), como ilustrado na Figura 2.12.

Para realizar a reamostragem adaptativa, o algoritmo precisa calcular parâmetros como a direção e a intensidade das mudanças em cada região. Esses parâmetros são aprendidos automaticamente por uma rede neural profunda. A rede analisa os padrões na imagem de entrada (como bordas ou gradientes) e ajusta os parâmetros da função de reamostragem para produzir uma saída mais natural e detalhada.

Apesar de ser mais flexível que métodos tradicionais de reamostragem, o **LeRF** não se torna mais lento, pois, assim como o **MuLUT**, o **LeRF** também utiliza as **LUTs**, que armazenam os resultados pré-computados para funções de reamostragem comuns. No entanto, vale ressaltar que esse método não foi disponibilizado pelos autores para realizarmos o treinamento a partir do nosso conjunto de dados, só foi possível aplicar o modelo pré-treinado disponibilizado previamente.

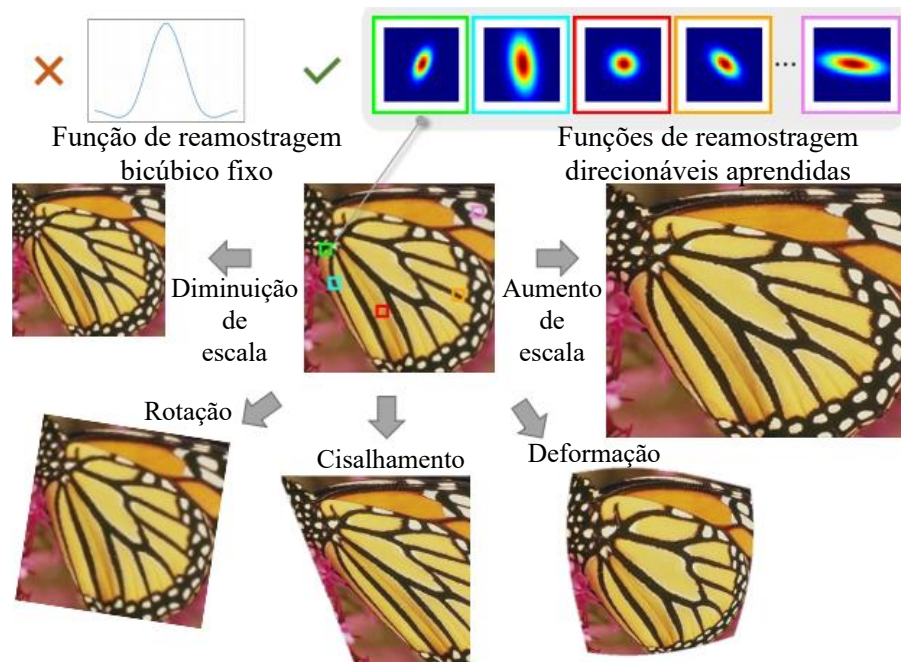


Figura 2.12: Diferentes reamostragens do **LeRF**. Figura adaptada de *Li et al. (2023)*

Revisão da Literatura

Este capítulo apresenta uma revisão dos trabalhos relacionados ao tema, abordamos inicialmente uma Revisão Sistemática da Literatura Revisão Sistemática da Literatura (RSL) que realizamos com o intuito de verificar as técnicas existentes para extração de características agronômicas a partir de imagens de VANT e satélites. Por meio dessa RSL, identificamos limitações significativas nas imagens disponíveis, como baixa resolução espacial, desfoque e oclusões, que dificultavam a análise direta.

Diante desses desafios, adotamos uma nova estratégia focada no melhoramento da resolução espacial e qualidade das imagens, utilizando as TTRs e as técnicas de SRRP. Essa abordagem busca minimizar as limitações identificadas, criando uma base de dados para análises mais precisas. No decorrer deste capítulo, serão discutidas as técnicas analisadas, suas limitações e as motivações que levaram ao desenvolvimento desta pesquisa.

3.1 Revisão Sistemática da Literatura

Antes de direcionarmos o foco desta pesquisa para o melhoramento da resolução espacial de imagens, buscamos identificar os métodos e técnicas existentes de processamento digital de imagens e aprendizado de máquina aplicados à Fenotipagem de Alto Rendimento (FAR)¹. O objetivo inicial era avaliar como as imagens que tínhamos disponíveis poderiam ser usadas para extrair características agronômicas relevantes da cultura da cana-de-açúcar, como quantidade de colmos, diâmetro e altura dos colmos², fundamentais para determinar a produtividade de uma plantação de cana-de-açúcar.

Para termos uma melhor dimensão do que existia na literatura, foi optado por realizar uma RSL que pode ser encontrada em Nogueira et al. (2023a). Analisando os

¹Fenotipagem de plantas é definida como a avaliação de caracteres agronômicos. Contudo, devido ao elevado número de dados a serem analisados para um estudo eficaz de fenótipos, foi necessária a ampliação da área de pesquisa para FAR(Araus and Cairns, 2014).

²Colmo é um tipo de caule encontrado nas gramíneas como: cana-de-açúcar e bambu. É um tipo de caule em que nós e entrenós são bem visíveis, e podem ser ocós (bambu) ou cheios (cana-de-açúcar).

métodos e técnicas encontrados na [RSL](#), em conjunto com as imagens que tínhamos disponíveis, foi possível observar que os recursos existentes para captura e processamento de imagens ainda estavam distantes de se conseguir extrair esses caracteres agronômicos no contexto da [FAR](#).

Como as imagens que nosso grupo de pesquisa possuía eram imagens capturadas a 200 metros de altura, alguns testes em altitudes menores foram realizados para ver se dessa forma esses caracteres agronômicos ficariam mais visíveis. Os testes realizados em altitudes mais baixas, embora tenham apresentado uma resolução espacial superior, evidenciaram novos desafios práticos para a extração de características agronômicas. Entre eles, destacou-se o movimento das folhas causado pelo vento gerado pelas hélices do [VANT](#), o que resultava em imagens borradas, e as oclusões provocadas por diferentes partes das plantas, como folhas sobre os colmos. Essas limitações reforçaram que, mesmo com a captura em condições ideais, a extração precisa de informações era um objetivo difícil de ser alcançado sem avanços no processamento das imagens.

Diante desse contexto, observamos que a baixa qualidade das imagens era o principal fator limitante para a aplicação das técnicas de [FAR](#) na cultura da cana-de-açúcar. Assim, o melhoramento da resolução espacial das imagens se tornou a prioridade deste trabalho. Esta pesquisa explorou técnicas modernas, como algoritmos de [SRRP](#), e comparou os resultados obtidos com [TTR](#). Essa abordagem busca viabilizar, no futuro, a extração confiável de características agronômicas diretamente das imagens de alta resolução espacial. Os trabalhos relacionados a essa estratégia estão resumidos a seguir.

3.2 Trabalhos Relacionados

As técnicas de melhoramento de resolução espacial têm ganhado destaque, pois permitem aprimorar a qualidade das imagens obtidas, ampliando sua utilidade em aplicações práticas. O melhoramento da resolução espacial de imagens é fundamental em diversas áreas, especialmente em aplicações que demandam dados visuais de alta qualidade para análise e tomada de decisão. Contudo, a obtenção dessas imagens por meio de sensores físicos pode ser limitada devido aos altos custos dos equipamentos, especialmente para operações em larga escala ([Sishodia et al., 2020](#)).

Diante desse cenário, os métodos computacionais para melhorar a resolução espacial de imagens têm ganhado destaque. Esses métodos incluem desde [TTR](#) até abordagens avançadas de [SRRP](#), que têm se mostrado promissoras em aplicações complexas ([Bilecen and Ayazoglu, 2023](#)). Por exemplo, em [Zhou et al. \(2022\)](#), os autores aplicaram [TTR](#) para a detecção de linhas de energia usando [VANT](#). No domínio médico, [Bishas \(2023\)](#), empregaram essas técnicas em ressonância magnética e em imagens de tomogra-

fia computadorizada do coração (Al-Jarrah et al., 2023). Métodos semelhantes também têm sido explorados na área de veterinária, como apresentado por Kim et al. (2023).

Com o avanço das tecnologias de sensoriamento remoto, especialmente com o uso de VANT e satélites, as demandas por técnicas de melhoramento de imagens têm-se intensificado em áreas como a agricultura, principalmente em culturas como milho e cana-de-açúcar, devido ao seu impacto na alimentação global.

Nesse contexto, a fim de identificar as abordagens mais recentes e as lacunas existentes nas pesquisas, foi realizada uma análise da literatura científica. Essa revisão abrangeu quatro bases de dados relevantes: Scopus³, IEEE Xplore⁴, ACM Library⁵ e Engineering Village⁶. O objetivo desse levantamento foi identificar pesquisas voltadas para o melhoramento da resolução espacial de imagens capturadas por VANT e satélites, nas culturas de cana-de-açúcar e milho.

Para essa pesquisa, foi utilizada uma estratégia de busca que combinou as seguintes palavras-chave: “sugarcane” e “corn” com termos relacionados a “UAV”, “VANT” ou “satellite”, além de “upsampling”, “upscaling”, “resampling”, “super resolution” ou “super-resolution”. A pesquisa foi conduzida ao longo do desenvolvimento deste trabalho, com a última atualização realizada em 25 de novembro de 2024.

Ao todo, foram encontrados 87 trabalhos (dentre eles: artigos científicos, livros e conferências), sendo mais de 70% publicados nos últimos dois anos. Esse dado evidencia o aumento significativo de interesse sobre o assunto. Apesar disso, nem todos os estudos identificados puderam ser incluídos como trabalhos relacionados, uma vez que alguns não abordavam diretamente as culturas de cana-de-açúcar e milho ou não aplicavam estratégias de melhoria da resolução espacial.

Com o intuito de melhorar a resolução espacial das imagens, a pesquisa de Liang et al. (2021) utilizou a arquitetura *Swin Transformer*. Uma arquitetura originalmente desenvolvida para o processamento de linguagem natural, que eles aplicaram no contexto de visão computacional, especificamente para melhorar tarefas de restauração de imagens. O SwinIR combina as vantagens dos *Transformers* em modelar dependências globais com a capacidade de manter a estrutura local das imagens, resultando em melhorias na qualidade das imagens restauradas.

O estudo realizado por Velumani et al. (2021), teve como objetivo realizar a detecção automática das plantas de milho com o modelo Faster-RCNN. Para isso, foi aplicada a SRRP, utilizando a rede profunda Cycle-ESRGAN (Zhu et al., 2017), uma abordagem que aumenta a resolução espacial das imagens e melhora a precisão da

³Scopus – <https://www.scopus.com/>

⁴IEEE Xplore – <https://ieeexplore.ieee.org/Xplore/home.jsp>

⁵ACM Library – <https://dl.acm.org/>

⁶Engineering Village – <https://www.engineeringvillage.com>

contagem das plantas, especialmente em imagens adquiridas a altitudes mais altas. O estudo utilizou imagens adquiridas por VANT com câmeras de alta resolução espacial, como a Sony Alpha 6000 e a DJI X7. As imagens de alta resolução espacial apresentaram uma resolução de 0,27 a 0,35 cm/pixel, enquanto as de baixa resolução, adquiridas a altitudes mais elevadas, tinham uma resolução de 0,63 a 0,66 cm/pixel.

No trabalho desenvolvido por Naidoo et al. (2021), foi realizada uma integração de dados de VANT e satélites para estimar a Biomassa Aérea de Milho (BAM). A principal finalidade foi escalar modelos de estimativa de BAM, combinando dados locais de VANT com dados regionais obtidos pelos satélites Sentinel-1 e Sentinel-2, o que, segundo os autores, ajudou a melhorar a precisão das estimativas de biomassa ao cobrir grandes áreas com diferentes resoluções espaciais. As imagens de satélite Sentinel-1 (SAR) e Sentinel-2 (multiespectral) tinham resolução espacial de 10 m/pixel. As imagens de VANT foram capturadas com o sensor óptico MicaSense RedEdge-M, com resolução de 0,3 m/pixel.

Recentemente, Bilecen and Ayazoglu (2023) introduziu uma versão melhorada da interpolação bicúbica chamada Bicubic++. O objetivo era melhorar a resolução da imagem usando o método bicúbico tradicional. O Bicubic++ emergiu como o vencedor na competição NTIRE 2023 RTSR Track 2 × 3 SR e é o mais rápido entre todos os métodos concorrentes, quase igualando à velocidade do método bicúbico tradicional. Contudo, apesar do foco de todos esses trabalhos estar no melhoramento da resolução das imagens, eles não foram utilizados para o melhoramento de imagens agrícolas e nem trabalharam com imagens de VANT ou satélite.

Já no método criado por Som-ard et al. (2024), o propósito foi gerar mapas de rendimento de cana-de-açúcar mais precisos e detalhados, combinando os dados de alta resolução espacial obtidos por drone VANT com os dados de satélite do Sentinel-2. Essa integração ajudou a complementar os dados limitados de campo, que são difíceis de coletar. Segundo os autores, isso melhora a estimativa do rendimento da cana-de-açúcar, especialmente quando os dados de campo eram insuficientes. O estudo utilizou imagens de satélite Sentinel-2 com uma resolução espacial de 10 m/pixel para as bandas refletivas, além de imagens de VANT adquiridas com um Phantom 3 Professional, com uma resolução espacial de 2,1 cm/pixel. A combinação dessas duas fontes de dados, segundo os autores, resultou em uma estimativa mais precisa do rendimento.

Na pesquisa de Niu et al. (2024), foi investigado a influência da resolução espacial na estimativa da altura das plantas de milho, utilizando a reamostragem Bilinear para aumentar a resolução espacial das imagens adquiridas por VANT. A técnica ajustou o tamanho do pixel das imagens capturadas, modificando a resolução espacial original de 1,5 cm/pixel para valores maiores, como 2 cm, 3 cm, 6 cm e 12 cm/pixel, com o intuito de analisar como as diferentes resoluções impactam as medições das plantas. O

estudo utilizou imagens de [VANT](#) capturadas com o DJI Phantom 4 Pro, que tinha uma resolução espacial original de 1,5 cm a 2 cm/*pixel*. As imagens foram ajustadas para diferentes resoluções por meio da reamostragem Bilinear.

Na seção seguinte, os trabalhos relacionados são comparados com a nossa proposta, com o intuito de deixar claras as contribuições de nossa pesquisa.

3.2.1 Comparação dos Trabalhos Relacionados

Nesta seção, apresentamos uma análise comparativa dos trabalhos relacionados à nossa pesquisa, visando identificar suas similaridades e diferenças em relação à proposta deste estudo. A análise foca em estudos que comparam o melhoramento de resolução espacial de imagens para aplicações agrícolas, especialmente no contexto do uso de [VANT](#) e satélites.

Apesar desses trabalhos — Swinir ([Liang et al., 2021](#)), Bicubic++ ([Bilecen and Ayazoglu, 2023](#)), — focarem no melhoramento da resolução de imagens, nenhum deles foi direcionado para o contexto agrícola, especialmente em imagens capturadas por [VANT](#) ou satélites. Esses métodos, embora eficazes em outros domínios, não foram projetados para trabalhar com imagens de sensoriamento remoto, que frequentemente apresentam desafios como variações na iluminação e diferentes resoluções espaciais. Portanto, a aplicação dessas técnicas em imagens agrícolas, particularmente em culturas monitoradas por [VANT](#) e satélites, representa uma lacuna importante.

Já os trabalhos de [Naidoo et al. \(2021\)](#) e [Som-ard et al. \(2024\)](#), realizam a integração de dados de diferentes fontes ([VANT](#) e satélite) no contexto agrícola para tentar melhorar a resolução espacial das imagens. Contudo, o foco estava na geração de mapas de rendimento ou biomassa, e não no melhoramento das imagens em si.

Em [Velumani et al. \(2021\)](#), os autores utilizam o Cycle-ESRGAN ([Zhu et al., 2017](#)), que é uma adaptação do [ESRGAN](#) focada em garantir a consistência do ciclo de resolução, enquanto o [Real-ESRGAN](#) ([Wang et al., 2021](#)) (utilizado neste trabalho para melhorar a resolução das imagens) foca em superar limitações relacionadas à qualidade das imagens geradas pelo [ESRGAN](#). O [Real-ESRGAN](#) foi considerado uma abordagem mais robusta e prática para uso em ambientes do mundo real, em que as imagens de entrada podem ter distorções além da baixa resolução. Os autores não analisaram o impacto de diferentes técnicas de melhoria de resolução; eles empregaram o Cycle-ESRGAN para com o intuito de melhorar a resolução das imagens.

Por fim, [Niu et al. \(2024\)](#) procuram obter imagens de melhor resolução aplicando a técnica Bilinear tradicional. Contudo, os autores não investigaram diferentes técnicas de melhoria de resolução, eles empregaram apenas o Bilinear tradicional com o intuito de melhorar a resolução das imagens.

Muitos dos trabalhos mencionados visam melhorar a resolução de imagens e realizam comparações entre diversas técnicas com o mesmo propósito. No entanto, esses estudos não são direcionados para o contexto agrícola. Por outro lado, os trabalhos voltados especificamente para o cenário agrícola não abordam o impacto que diferentes técnicas de melhoramento de resolução espacial podem ter em imagens agrícolas. Essa lacuna destaca a necessidade de se investigar como as diferentes técnicas impactam no melhoramento da resolução espacial de imagens agrícolas, sejam elas de VANT ou satélites.

Desta forma, foram escolhidos os trabalhos de Liang et al. (2021), Bilecen and Ayazoglu (2023), Naidoo et al. (2021), Som-ard et al. (2024), Velumani et al. (2021) e Niu et al. (2024) que mais são semelhantes com esta proposta. Para este fim, serão apresentadas as características similares e diferentes de cada trabalho, com o objetivo de realçar a contribuição desta pesquisa.

As características elencadas para comparar os trabalhos com esta proposta são: (1) o trabalho é direcionado para plantação de cana-de-açúcar; (2) o trabalho é direcionado para plantação de milho; (3) realiza um comparativo entre as técnicas de melhoramento de resolução espacial de imagens; (4) utiliza imagens de VANT ou RPA; (5) utiliza imagens de satélites.

As características escolhidas para comparar os trabalhos relacionados com esta proposta visam avaliar diferentes aspectos importantes para o melhoramento das imagens agrícolas. Primeiramente, verificamos se os trabalhos focam na plantação de cana-de-açúcar, milho ou ambos, a fim de analisar como as técnicas se comportam em diferentes contextos. Outro ponto importante é a comparação entre as técnicas de melhoria de resolução espacial das imagens, o que permite identificar quais métodos são mais eficazes para melhorar a qualidade das imagens agrícolas. O uso de imagens de VANT é relevante, pois essas tecnologias têm um custo baixo, permitem mapear grandes áreas sem danificar a plantação e são fáceis de operar. As imagens de satélite, por sua vez, são fundamentais para o monitoramento de áreas mais extensas, complementando as imagens de maior detalhamento capturadas por VANT. Além disso, a capacidade de mapear as plantações em diferentes estágios de crescimento, desde as plantas recém-plantadas até as mais desenvolvidas, proporciona uma visão abrangente do campo. Isso possibilita aos produtores a identificação e correção de falhas no cultivo, como a aplicação inadequada de fertilizantes ou o controle de pragas.

A Tabela 3.1 apresenta o resumo das características presentes nos trabalhos relacionados e a proposta desenvolvida neste trabalho. Analisando a Tabela 3.1, observe que a proposta deste trabalho é a única que pretende contemplar todas as características. Observe que os trabalhos que analisam o impacto do melhoramento das imagens não são para o contexto agrícola e os que são para o contexto agrícola não investigam o impacto

do melhoramento das imagens.

Tabela 3.1: *Comparativo entre os trabalhos relacionados.*

Trabalhos	Características				
	(1)	(2)	(3)	(4)	(5)
(Liang et al., 2021)			✓		
(Velumani et al., 2021)		✓		✓	
(Naidoo et al., 2021)		✓		✓	✓
(Bilecen and Ayazoglu, 2023)			✓		
(Som-ard et al., 2024)	✓			✓	✓
(Niu et al., 2024)		✓		✓	
Nossa Proposta	✓	✓	✓	✓	✓

O símbolo ✓ indica que o trabalho possui a característica.

A ausência do símbolo significa que a característica não está presente.

Características:

- (1) Trabalho é direcionado para plantação de cana-de-açúcar;
- (2) Trabalho é direcionado para plantação de milho;
- (3) Realiza um comparativo entre as técnicas de melhoramento de resolução espacial de imagens;
- (4) Utiliza imagens de VANT ou RPA;
- (5) Utiliza imagens de satélites.

A literatura apontou a falta de estudos que abordem o impacto das diferentes técnicas de melhoramento de resolução espacial das imagens agrícolas, particularmente em contextos que envolvem a combinação de dados de diferentes plataformas, como VANT e satélites, e múltiplas culturas agrícolas. Este cenário abre espaço para uma pesquisa mais aprofundada sobre o impacto de métodos avançados de SRRP na qualidade das imagens agrícolas. Embora alguns estudos tenham integrado dados de VANT e satélites, focando em aplicações como estimativas de biomassa ou rendimento das culturas, nenhum deles investigou a aplicação conjunta de diferentes técnicas de SRRP e o impacto dessas metodologias no melhoramento das imagens agrícolas de forma comparativa.

Diante dessa lacuna, a metodologia proposta neste trabalho visa explorar o uso de TTR e de SRRP para melhorar a resolução espacial de imagens de VANT e satélites aplicadas a culturas de cana-de-açúcar e milho. A partir da revisão dos métodos apresentados.

No capítulo seguinte, detalharemos a metodologia adotada no trabalho proposto, incluindo a aplicação de técnicas para melhorar a resolução espacial das imagens, além das etapas de coleta e pré-processamento dos dados, bem como as métricas utilizadas para a análise dos resultados, com foco nas avaliações quantitativas e qualitativas das imagens geradas.

Abordagens de Melhoramento de Imagens a Partir de Técnicas Tradicionais de Reamostragem e de Redes de Aprendizado Profundo

Este capítulo detalha os métodos e materiais utilizados nesta pesquisa, descrevendo o fluxo metodológico desde a coleta e preparação dos dados até a aplicação das técnicas para melhorar a resolução espacial das imagens. Neste capítulo, são apresentados os conjuntos de dados utilizados, incluindo imagens de cana-de-açúcar e milho capturadas por [VANT](#) e satélites, e os processos de pré-processamento e treinamento dos algoritmos empregados.

A metodologia foi projetada para avaliar comparativamente as [TTRs](#) e as técnicas de [SRRP](#), utilizando métricas quantitativas e qualitativas para analisar a qualidade das imagens geradas.

4.1 Fluxograma do Processo de Coleta, Melhoramento e Análise de Imagens Agrícolas

Para ilustrar essas etapas, foi elaborado um fluxograma (Figura 4.1) que apresenta de forma sequencial o processo metodológico desenvolvido neste trabalho. Ele organiza as fases envolvidas, desde a coleta de dados, a aplicação das diferentes técnicas para melhorar a resolução espacial das imagens, bem como a avaliação e comparação dos resultados e proporciona uma visão clara das ações executadas. Cada uma dessas fases será detalhada no decorrer deste capítulo.

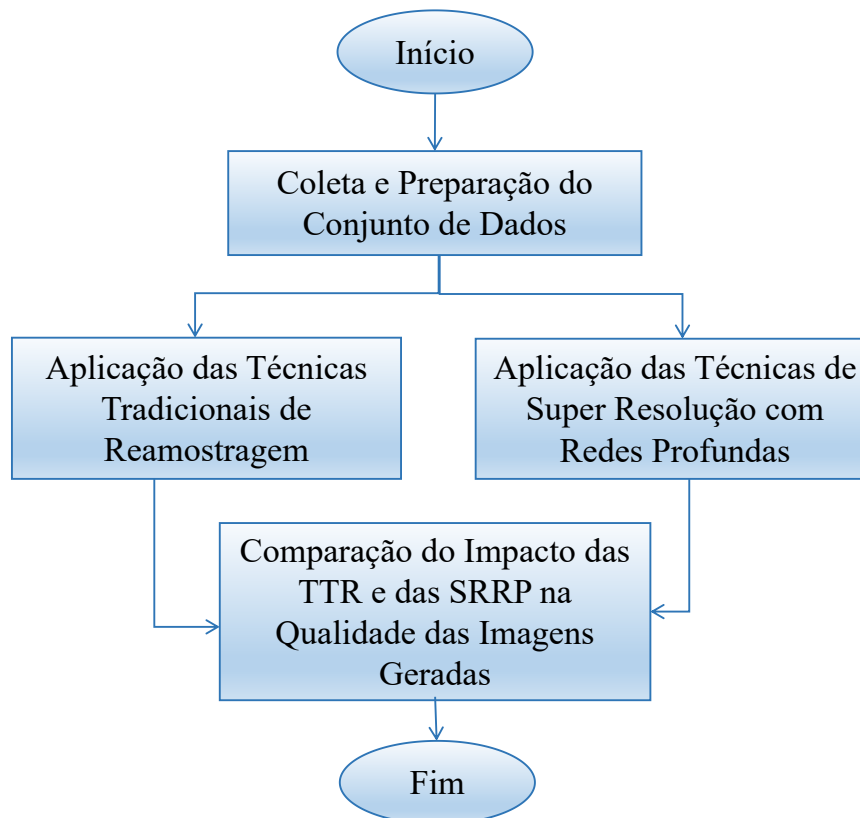


Figura 4.1: Fluxograma do processo metodológico.

4.2 Coleta e Preparação do Conjunto de Dados

A primeira fase foi marcada pela coleta das imagens agrícolas, realizadas tanto por VANT quanto por satélites, e o pré-processamento dessas imagens obtidas de ambas as plataformas.

4.2.1 Conjuntos Experimentais de Dados de Imagens Agrícolas Capturadas com VANT

Nesta subseção, apresentamos os conjuntos experimentais de dados de imagens agrícolas capturadas por VANTs. Dois conjuntos de dados distintos foram utilizados: um referente à cultura de cana-de-açúcar e outro à cultura do milho. Ambos os conjuntos foram coletados em áreas específicas do Brasil e dos Estados Unidos, utilizando diferentes VANTs. A seguir, detalharemos as características e o processo de coleta de cada conjunto de dados, destacando suas particularidades.

Conjunto de Imagens da Cultura de Cana-de-açúcar

As imagens de cana-de-açúcar utilizadas neste estudo foram coletadas pelo nosso grupo de pesquisa (Rocha et al., 2022) no estado de Goiás, Brasil, especificamente nas

coordenadas de latitude $18^{\circ}36'16.15''S$ e longitude $50^{\circ}27'27.99''W$. Para capturar as imagens, foi usado um modelo de RPA. Denominado BATMAP¹ I foi empregado. O VANT foi operado a uma altitude de 200 metros durante o processo de mapeamento. Ele foi equipado com uma câmera Sony Alpha 6000 RGB com resolução espacial de 24,3 megapixel.

Com as imagens capturadas, o software Agisoft PhotoScan² foi utilizado, na versão 1.3.5, para realizar a junção de várias imagens (ortofoto) em uma única imagem (ortomosaico). O formato das imagens geradas no ortomosaico é o geoTIFF, o qual permitiu incluir informações de georreferenciamento em um arquivo *Tagged Image File Format (TIFF)*. O *pixel* da imagem corresponde a aproximadamente 5,63 cm/*pixel*, ou seja, cada *pixel* cobre uma área de cerca de 31,7 cm² (5,63 cm \times 5,63 cm). Sete ortomosaicos foram criados usando diferentes áreas de plantio de cana-de-açúcar da fazenda, localizadas perto da cidade de Quirinópolis. Os ortomosaicos são mostrados na Figura 4.2.

As imagens originais foram padronizadas em *patches* de 300×300 *pixel*. Foi optado por selecionar proporcionalmente as imagens de cada um dos ortomosaicos disponíveis. Para que cada ortomosaico tivesse a mesma representação no conjunto de dados. A quantidade de imagens variou conforme o experimento realizado.




Figura 4.2: *Ortomosaicos de plantios de cana-de-açúcar. Figura adaptada de Rocha et al. (2022).*

¹Informações detalhadas sobre o modelo BATMAP I podem ser encontradas na seguinte URL: <http://nuvemuav.com/batmap>.

²<http://www.agisoft.com/downloads/installer/>.

Conjunto de Imagens da Cultura do Milho

Na cultura do milho, o conjunto de dados de [Zermas et al. \(2021\)](#) foi utilizado, a coleta de imagens ocorreu ao longo de dois períodos de cultivo (2017–2019), capturando uma combinação de estágios de crescimento variando de V5 a VT, conforme descrito na Subseção 2.2.4. Neste contexto, “V” indica o estágio vegetativo, enquanto o número associado representa o número de folhas presentes na planta. É importante notar que, embora as imagens tenham sido coletadas em épocas ótimas, algumas plantas têm um pouco mais ou um pouco menos de folhas. Contudo, apenas os dados de V8 a VT foram usados nos experimentos dos autores e nos nossos experimentos, pois a deficiência de nitrogênio não era evidente nas folhas de todos os campos nos estágios iniciais devido aos tipos de solo utilizados. Os dados correspondem a dois campos de milho situados nas cidades de Becker e Waseca, do estado de Minnesota, nos EUA.

Para demonstrar a independência da ferramenta de captura, os dados foram coletados por duas plataformas de VANT distintas: um MikroKopter Okto XL equipado com um sensor NIKON D7200 RGB e um DJI Matrice 100 com câmeras Zenmuse X3 e Zenmuse Z3 RGB. A resolução espacial das imagens variou entre 0,2 e 0,47 cm/pixel. As imagens, armazenadas no formato *Joint Photographic Experts Group (JPEG)*, não estão georreferenciadas, o que impossibilitou a criação de um ortomosaico. Na Figura 4.3 fizemos a combinação de algumas imagens existentes na base de dados, para ilustrar a base de dados utilizada.



Figura 4.3: Exemplo das imagens contidas no conjunto de dados de [Zermas et al. \(2021\)](#)

As imagens originais foram padronizadas em *patches* de 250×250 pixel e foram mantidas dessa forma. Como todas as características da plantação estão bem distribuídas no banco de dados na totalidade, optamos por selecionar as imagens sequencialmente para facilitar a replicabilidade dos experimentos.

Além das imagens capturadas via VANT, também foi construída uma base de imagens de satélites, com o intuito de testar os algoritmos de melhoria de resolução

espacial com imagens em diferentes cenários e resoluções. A seguir, a construção dessa base de dados é detalhada.

4.2.2 Imagens de Cana-de-açúcar Capturadas por Satélite

Nesta seção, serão descritos os procedimentos realizados para a criação da base de dados das imagens de satélite. O fluxo desses processos pode ser visualizado na Figura 4.4, e será detalhado nesta seção.



Figura 4.4: Fluxo das etapas realizadas para a construção dessa base de dados.

A base de dados foi criada a partir da combinação de imagens de satélite da plataforma Planet³, que fornece imagens multiespectrais gratuitas, e do uso do MapBiomias⁴ e *Google Earth Engine (GEE)*⁵ para identificar e delimitar as áreas de cultivo de cana-de-açúcar no estado de Goiás. O processo de criação da base de dados envolveu várias etapas, como a identificação das regiões de interesse, a extração das áreas de cultivo, o pré-processamento das imagens e o armazenamento dos dados resultantes.

Identificação com MapBiomias

Primeiramente, foi utilizado o MapBiomias, uma plataforma brasileira que oferece informações detalhadas sobre o uso e cobertura do solo no Brasil. O MapBiomias

³<https://www.planet.com>

⁴<https://brasil.mapbiomas.org>

⁵<https://earthengine.google.com>

fornece dados sobre as diferentes classes de uso do solo, incluindo a cana-de-açúcar, em uma base temporal que abrange vários anos. Com esses dados, foi possível identificar as áreas de cultivo de cana-de-açúcar em Goiás. Essas áreas foram extraídas a partir de um mapa de classificação que indica, por exemplo, onde a cana-de-açúcar foi cultivada, conforme a cobertura do solo no período analisado.

Exportação no GEE

O [GEE](#) é uma plataforma para análise e processamento de dados geoespaciais. Após identificar as áreas de interesse no MapBiomass, utilizamos o [GEE](#) para processar e extrair esses dados. Dentro do [GEE](#), importamos o mapa de uso do solo do MapBiomass que continha as regiões correspondentes às áreas de cana-de-açúcar de todo o Brasil.

No [GEE](#) foi inserida manualmente a geometria poligonal da área de Goiás, de forma que a análise só fosse realizada para a área do estado, descartando regiões fora dele. Posteriormente, os dados raster (*pixel*) foram convertidos em objetos vetoriais (polígonos). Depois, os polígonos foram ordenados por tamanho de área, de forma decrescente, permitindo identificar as áreas de cana-de-açúcar com maior extensão.

Por fim, utilizamos apenas as 10 maiores áreas e exportamos essas áreas como arquivos *Keyhole Markup Language* ([KML](#)), esses arquivos contêm as coordenadas geográficas e as delimitações das regiões em que a cana-de-açúcar estava presente. Com os [KMLs](#) exportados via [GEE](#), foi possível ter uma representação precisa das regiões com cana-de-açúcar em Goiás, em um formato que pode ser compartilhado e visualizado em diversas ferramentas de mapeamento, como: *Quantum GIS* (QGIS), Google Earth, dentre outros.

Aquisição das Imagens de Satélite

Com as áreas de cana-de-açúcar delimitadas no formato [KML](#), o próximo passo foi obter imagens de satélite para as regiões selecionadas. Para isso, foi utilizada a plataforma Planet, que oferece imagens de satélite gratuitas em intervalos diários a partir de uma constelação de satélites (PlanetScope com resolução espacial de 3 m/*pixel*, em oito bandas espectrais) e imagens de maior resolução espacial com o satélite SkySat (chegando a 0,5 m/*pixel* em imagens pancromáticas, mas não é gratuito e a disponibilidade de novas imagens é menor do que a do PlanetScope).

Para fazer o *download* das imagens, foi necessário realizar o cadastro na plataforma Planet, o qual levou 16 dias para ser aprovado por se tratar de uma conta institucional, pois, só assim seria possível os *downloads* de forma gratuita. Depois da conta aprovada, o arquivo [KML](#) na plataforma foi importado para ser utilizado como referência para navegar/encontrar a área de interesse dos dados. Definimos o intervalo de datas,

faixa de cobertura das nuvens e as bandas espectrais de interesse. Por fim, foi criada uma solicitação de imagem com base nos parâmetros fornecidos. Após aprovada, a imagem fica disponível para *download*, em formato georreferenciado (geralmente em formato GeoTIFF).

Pré-processamento

As 10 regiões de interesse resultaram em 10 imagens de diferentes tamanhos. Essas imagens passaram por diversos pré-processamentos, incluindo a extração da banda RGB, já que as imagens originais possuem 8 bandas espectrais (duas das 10 imagens podem ser visualizadas na Figura 4.5⁶).



Figura 4.5: Exemplo de imagens contidas no conjunto de dados de satélite.

⁶Para proporcionar uma visualização mais agradável das imagens de satélite desta tese, foi realizado um ajuste no brilho das imagens.

Após a conversão para o formato RGB, foram realizados recortes nessas imagens, gerando blocos de 256×256 *pixels*, o que resultou em 1.096 imagens. No entanto, nem todas as 1.096 puderam ser utilizadas, pois as que estavam localizadas nas bordas apresentaram um número reduzido de *pixel*, enquanto outras continham construções que poderiam confundir as redes neurais durante o treinamento. Como resultado, essas imagens foram descartadas, e ao final restaram 700 imagens utilizáveis.

Com o banco de dados para VANT e satélite prontos, foram iniciados os testes de melhoramento de resolução espacial, inicialmente com as técnicas tradicionais.

4.3 Aplicação das Técnicas Tradicionais de Reamostragem

Nesta etapa, foram aplicadas as TTRs para melhorar a resolução espacial das imagens agrícolas descritas na Seção 4.2. As técnicas escolhidas foram bem detalhadas no Capítulo 2.3.1 a saber: Vizinhos Mais Próximos, Bilinear e Bicúbica.

Todo o processo de reamostragem foi realizado utilizando ferramentas como Python com a biblioteca Pillow, que oferecem implementações das técnicas utilizadas, resultando em uma maior velocidade durante a implementação. A seguir, descrevemos o passo a passo da aplicação das técnicas de reamostragem:

1. Carregamento das Imagens: As imagens agrícolas de BR foram carregadas como sendo a entrada para as TTRs.
2. Seleção do Fator de Aumento: Para cada imagem de entrada, foram aplicados três fatores de aumento de resolução espacial ($2\times$, $3\times$ e $4\times$), ou seja, as imagens serão ampliadas para o dobro, triplo e quadruplicado de sua resolução espacial original.
3. Aplicação da Reamostragem: As TTRs foram aplicadas para melhorar a resolução espacial das imagens. Para cada fator de aumento, as imagens foram processadas separadamente com as três técnicas.
4. Armazenamento das Imagens Reamostradas: As imagens reamostradas foram armazenadas no formato *Portable Network Graphics* (PNG).

4.4 Aplicação das Técnicas de Super-Resolução com Redes Profundas

A SSRP foi a outra estratégia que testamos para melhorar a resolução espacial das imagens descritas na Seção 4.2. As técnicas escolhidas foram bem detalhadas no

Capítulo 2.3.2 a saber: [Real-ESRGAN](#), [MuLUT](#) e [LeRF](#), ambas foram modificadas e treinadas, visando atingir o objetivo proposto.

4.4.1 Ajustes e Treinamento das Técnicas de SRRP

Antes de ser iniciado o treinamento das redes, é essencial configurar o ambiente no qual elas irão ser executadas. Para o treinamento, foi utilizado o Google Colab Pro⁷, que oferece alguns recursos avançados. Como o acesso a GPU, que pode variar entre a NVIDIA Tesla P100 ou NVIDIA Tesla T4 dependendo da disponibilidade. A memória RAM padrão é de 25 GB, mas, se disponível, é possível acessar até 50 GB de RAM. O plano também oferece 100 GB de armazenamento temporário, utilizado durante a execução das tarefas. Se for necessário armazenamento permanente, o mesmo pode ser feito via Google Drive. O tempo máximo de execução contínua das sessões no Colab Pro é de 24 horas, com desconexões automáticas após 12 horas de inatividade.

Para garantir a execução adequada dos métodos no Google Colab, foi necessário realizar uma série de passos para configurar cada ambiente de desenvolvimento, instalar as dependências e garantir a compatibilidade com os códigos originais. O primeiro deles foi a instalação das bibliotecas necessárias para a execução de cada modelo, como PyTorch, NumPy, OpenCV, Torchvision e outras dependências específicas. Inicialmente, foi feito um downgrade de algumas bibliotecas para versões específicas, a fim de garantir a compatibilidade com os códigos originais, que dependiam de versões anteriores de certas bibliotecas. Esses processos foram fundamentais para assegurar que as técnicas funcionassem corretamente no ambiente do Google Colab.

Com os três ambientes configurados, instalamos as redes a partir de seus repositórios oficiais no GitHub, [Real-ESRGAN](#)⁸, [MuLUT](#)⁹ e [LeRF](#)¹⁰. Para isso, utilizamos o comando `git clone` para baixar o código-fonte dos repositórios diretamente para o ambiente do Google Colab. Com os repositórios clonados, foram realizados ajustes nos parâmetros dos modelos para adequá-los à tarefa de super-resolução de imagens agrícolas conforme o *hardware* que tínhamos disponível para tal.

Além dos ajustes e treinamentos dos modelos, outra etapa crucial para melhorar os resultados foi a aplicação de *data augmentation* (aumento de dados). Através dessa técnica, geramos variações das imagens de entrada, simulando diferentes condições de rotação e variações de escala, o que ajudou a melhorar a robustez e a generalização dos modelos treinados. Configuramos o *data augmentation* para criar versões das imagens

⁷<https://colab.research.google.com>

⁸<https://github.com/xinntao/Real-ESRGAN>

⁹<https://github.com/ddlee-cn/MuLUT>

¹⁰<https://github.com/ddlee-cn/LeRF-MindSpore>

com rotações de 45°, 90°, 120° e 180° e resoluções reduzidas em 2×, 3× e 4×, aumentando assim a diversidade dos dados de treinamento e proporcionando um modelo mais adaptável a diferentes cenários.

Concluídos todos esses passos, as redes foram treinadas utilizando imagens agrícolas com resolução espacial reduzida (obtidas ao diminuir a qualidade das imagens originais). Ou seja, as imagens de **BR** são fornecidas como entradas para as redes e as respectivas imagens originais são o *ground truth*. Com isso, as redes podem aprender a reconstruir as imagens de forma nítida e precisa. No caso do **Real-ESRGAN**, essa reconstrução passa por um discriminador, que avalia a qualidade da imagem gerada e ajusta a rede para melhorar a qualidade, caso necessário. À medida que o treinamento vai sendo realizado, os modelos passam a se concentrar em detalhes característicos das imagens agrícolas, como na textura do solo, as formas das plantações e a vegetação.

4.4.2 Processo de Aumento de Resolução Espacial

Após o treinamento das redes, a etapa de inferência/Aumento de Resolução Espacial é responsável por aplicar a super-resolução a novas imagens de **BR**, ou seja, nas imagens que não foram usadas durante o treinamento. Durante esse processo, os modelos treinados geram imagens de **AR** com base nos padrões e detalhes aprendidos. Cada imagem de entrada é alimentada no modelo, em que passa por diversas camadas da rede que realizam operações de convolução. Utilizando os pesos aprendidos, a rede gera uma previsão, recriando uma versão de **AR** da imagem original, com o intuito de recuperar detalhes perdidos e melhorar a qualidade visual.

A rede realiza uma série de operações de *upscaling*, expandindo a imagem de **BR** ao adicionar mais *pixel* para alcançar a resolução espacial desejada. Durante esse processo, o modelo tenta reconstruir detalhes presentes na versão original de **AR**. Após o Aumento de Resolução Espacial, as imagens de **AR** geradas são salvas em formatos como **TIFF** ou **PNG**, garantindo a melhor qualidade possível para a aplicação desejada.

Esse processo de Aumento de Resolução Espacial pode ser realizado em lotes de imagens, ou seja, os modelos treinados podem processar várias imagens ao mesmo tempo, em vez de uma de cada vez. Esse processo é mais eficiente em termos de tempo de execução, pois as previsões são realizadas simultaneamente para todas as imagens.

Após o processo de Aumento de Resolução Espacial, é importante avaliar a qualidade da imagem gerada. Isso pode ser feito utilizando métricas quantitativas como o **PSNR** ou o **SSIM**, que medem a similaridade entre a imagem de **AR** gerada e a imagem de referência (*ground truth*).

4.5 Comparação do Impacto das TTR e das SRRP na Qualidade das Imagens Geradas

Nesta seção serão descritas algumas métricas utilizadas para avaliar a qualidade das imagens geradas artificialmente. A avaliação foi conduzida considerando cinco métricas diferentes para avaliar a qualidade das imagens criadas artificialmente em comparação com as imagens originais, sendo elas: **PSNR**, **SSIM**, Jaccard e *Learned Perceptual Image Patch Similarity* (**LPIPS**), todas serão descritas a seguir.

4.5.1 Peak Signal-to-Noise Ratio

Calcula a razão entre a energia do sinal e a energia do ruído introduzida pelo processo de restauração. Quanto maior o valor de **PSNR**, menor a diferença entre as imagens e, teoricamente, melhor a qualidade da imagem restaurada (Korhonen and You, 2012). A fórmula matemática do **PSNR** é dada na Equação 4-1,

$$PSNR = 10 \cdot \log_{10} \left(\frac{L^2}{MSE} \right), \quad (4-1)$$

em que, L é o valor máximo possível de intensidade do *pixel* na imagem (normalmente 255 para imagens de 8 bits, onde os *pixels* têm valores entre 0 e 255); *Mean Squared Error* (**MSE**) é o erro quadrático médio entre os *pixel* da imagem original e da imagem gerada artificialmente, calculado como na Equação 4-2,

$$MSE = \frac{1}{N \cdot M} \sum_{i=1}^N \sum_{j=1}^M (x_{i,j} - y_{i,j})^2, \quad (4-2)$$

onde, $x_{i,j}$ e $y_{i,j}$ são os valores dos *pixel* na posição i, j da imagem original e da imagem gerada artificialmente, respectivamente, e $N \cdot M$ é o número total de *pixel* da imagem. Geralmente, o valor do **PSNR** é expresso em decibéis (dB).

4.5.2 Structural Similarity Index

Avalia a similaridade estrutural entre imagens, considerando contraste, luminância e estrutura. O **SSIM** leva em consideração algumas características da percepção visual humana. Em vez de olhar apenas para a diferença exata nos valores dos *pixel*, como o **PSNR**. O **SSIM** é calculado como na Equação 4-3 (Wang et al., 2004).

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (4-3)$$

em que, μ_x e μ_y são as médias dos valores de intensidade de *pixel* nas imagens x e y , respectivamente; σ_x^2 e σ_y^2 são as variâncias das intensidades de *pixel* nas imagens x e y ; σ_{xy} é a covariância entre x e y , que mede a relação entre as mudanças nas intensidades de *pixel* de ambas as imagens; c_1 e c_2 são pequenas constantes usadas para evitar divisões por zero e estabilizar a fórmula. Essas constantes são geralmente definidas como na Equação 4-4.

$$c_1 = (K_1L)^2, \quad c_2 = (K_2L)^2, \quad (4-4)$$

onde, K_1 e K_2 são valores pequenos e fixos, definidos empiricamente para evitar divisões por zero e garantir que a fórmula do SSIM seja estável, principalmente quando as imagens a serem comparadas têm pouca variação nas suas intensidades, e L é o valor máximo da intensidade do *pixel* (geralmente 255 para imagens de 8 bits).

4.5.3 Jaccard

Primeiro, os conjuntos de *pixel* de cada imagem de AR e BR são formados, considerando os *pixel* como elementos dos conjuntos. Em seguida, a intersecção e a união dos conjuntos de *pixel* são calculadas. O índice de Jaccard é então definido como a razão entre o tamanho da intersecção e o tamanho da união dos conjuntos (Fedotova et al., 2020).

A fórmula do índice de Jaccard é dada pela Equação 4-5:

$$J(x,y) = \frac{|x \cap y|}{|x \cup y|}, \quad (4-5)$$

onde, x e y são os conjuntos que estamos comparando (neste caso, os conjuntos de *pixel* das imagens original e gerada artificialmente); $|x \cap y|$ é o número de elementos (ou *pixel*) idênticos nas duas imagens (a intersecção), e $|x \cup y|$ é o número total de elementos (ou *pixel*) presentes em x e y (a união).

Ou seja, o índice de Jaccard mede a sobreposição entre dois conjuntos. Ele varia de 0 a 1, em que: 1 (um) significa que os dois conjuntos são idênticos (ou seja, a intersecção é igual à união, ou não há diferença entre os conjuntos). E 0 (zero) significa que não há sobreposição entre os conjuntos (ou seja, a intersecção é vazia). No contexto de imagens, estamos usando o índice de Jaccard para medir a semelhança entre os *pixel* das duas imagens. Quanto mais *pixel* sobrepostos (idênticos) existirem entre a imagem original e a imagem gerada artificialmente, maior será o valor do índice de Jaccard.

4.5.4 Learned Perceptual Image Patch Similarity

O LPIPS é uma métrica de similaridade perceptual entre duas imagens, baseada em redes neurais profundas. O LPIPS é projetado para capturar melhor a percepção hu-

mana de semelhanças e diferenças entre imagens, em contraste com métricas tradicionais como PSNR e SSIM, que são baseadas apenas em diferenças *pixel a pixel* (Zhang et al., 2018).

O LPIPS calcula a diferença perceptual entre duas imagens utilizando redes neurais profundas treinadas para essa tarefa. As redes AlexNet e VGG são as redes usadas para esse cálculo. O valor gerado pela função LPIPS mede o quão “distantes” as imagens estão em termos da percepção humana, com um valor maior indicando uma maior diferença perceptual entre as imagens.

A fórmula exata do LPIPS é um pouco mais complexa, pois envolve o cálculo da distância entre as representações das imagens nas camadas de uma rede neural profunda. De maneira geral, podemos expressá-la como na Equação 4-6.

$$LPIPS(x,y) = \frac{1}{N} \sum_{i=1}^N \|f_i(x) - f_i(y)\|_2^2 \quad (4-6)$$

em que, $f_i(x)$ e $f_i(y)$ representam as ativações da rede neural (por exemplo, as saídas das camadas convolucionais) para as imagens x e y , respectivamente; $\|\cdot\|_2$ é a norma L2 (distância Euclidiana) entre as ativações; N é o número de camadas da rede que estão sendo comparadas.

Essa fórmula indica que o LPIPS calcula a distância entre as representações das imagens nas camadas da rede neural, e o valor final é uma média dessa diferença, proporcionando uma métrica de similaridade perceptual entre as imagens.

Além da análise quantitativa com as métricas PSNR, SSIM, Jaccard e LPIPS, iremos avaliar também a qualidade visual das imagens geradas, por meio da inspeção visual, verificando se os detalhes como a textura do solo, formas das plantações e a vegetação foram bem preservados.

No decorrer deste capítulo, foram detalhadas as bases de dados, além de como as TTRs e as técnicas SRRP foram utilizadas, e por fim, foram apresentadas as métricas de avaliação, fundamentais para comparar de maneira quantitativa uma imagem original com uma imagem gerada artificialmente. A partir dessas descrições, foi possível configurar um ambiente controlado para testar a hipótese levantada, bem como garantir a confiabilidade e a repetibilidade dos resultados.

No Capítulo a seguir, serão discutidos os experimentos realizados, as variações observadas nos resultados e como eles se relacionam com as expectativas iniciais.

Experimentos e Discussão dos Resultados

Os experimentos realizados nesta pesquisa avaliaram a eficácia de técnicas de super-resolução em imagens agrícolas de cana-de-açúcar e milho, utilizando abordagens baseadas em aprendizado profundo, como [Real-ESRGAN](#), [MuLUT](#) e [LeRF](#), em comparação com métodos tradicionais de interpolação. Inicialmente, foram conduzidos testes com um conjunto reduzido de imagens de cana-de-açúcar (40 imagens) e posteriormente ampliados para um conjunto maior (500 imagens), observando melhorias na qualidade das imagens conforme o aumento do conjunto de treinamento. Em seguida, experimentos com imagens de milho seguiram uma abordagem similar, testando conjuntos de 200 e 1.000 imagens para avaliar a influência do volume de dados nos modelos. Além disso, foram realizadas análises em imagens de satélite, buscando melhorar sua resolução espacial para se aproximar da qualidade das imagens capturadas por [VANT](#). A avaliação foi conduzida tanto por métricas quantitativas ([PSNR](#), [SSIM](#), Jaccard e [LPIPS](#)) quanto por inspeção visual, destacando os impactos das diferentes técnicas na detecção de características relevantes para o manejo das culturas.

5.1 Experimento I - Cana-de-açúcar 40 imagens

Os experimentos descritos nesta seção foram publicados na *IEEE Canadian Conference on Electrical and Computer Engineering* (CCECE) ([Nogueira et al., 2023b](#)). O objetivo desse estudo foi avaliar o desempenho de diferentes [TTRs](#) em comparação com um método de [SRRP](#) o [Real-ESRGAN](#), em imagens de cana-de-açúcar. As imagens utilizadas neste estudo são detalhadas na Seção [4.2.1](#). Nesta fase preliminar, foram selecionadas apenas 40 imagens para o treinamento da rede, e 10 imagens para realizarmos o Aumento da Resolução Espacial.

O treinamento do [Real-ESRGAN](#) seguiu as etapas descritas na Seção [4.4.1](#) e foi realizado com 1.000 iterações. Após o treinamento, a fase de **Aumento de Resolução Espacial** foi iniciada. Para isso, as 10 imagens de tamanho 300×300 *pixel* foram redimensionadas (*downscaling*) em escalas de $4\times$, $3\times$ e $2\times$, resultando em imagens de baixa resolução espacial com dimensões de 75×75 *pixel*, 100×100 *pixel* e

150 × 150 *pixel*, respectivamente. Essas imagens de baixa resolução espacial foram então processadas utilizando os métodos Vizinhos Mais Próximos, Bilinear, Bicúbico e **Real-ESRGAN**, com o intuito de aumentar a resolução espacial das imagens para as escalas de 2×, 3× e 4×.

A análise dos resultados foi dividida em duas subseções. A primeira se concentra em uma análise quantitativa baseada nas métricas de qualidade de imagem descritas por **Zhang et al. (2018)**, enquanto a segunda aborda a análise qualitativa dos resultados.

5.1.1 Análise Quantitativa

Para a análise quantitativa, foram utilizadas três métricas de qualidade de imagem descritas na Seção 4.5: (1) **PSNR** e (2) **SSIM** são comumente usadas para avaliar a qualidade das restaurações de imagem. Elas prestam mais atenção à fidelidade da imagem *pixel à pixel* do que à similaridade visual. (3) **LPIPS** tende a determinar se as imagens são semelhantes conforme a percepção visual humana. Os resultados quantitativos foram obtidos ao comparar as imagens geradas por cada método testado (**TTR** e **Real-ESRGAN**) com a imagem original. Para cada uma das 10 imagens utilizadas na etapa de Aumento de Resolução Espacial, as métricas, como **PSNR** e **SSIM**, foram calculadas entre a imagem original e a imagem gerada. Por fim, a média¹ dessas métricas foi calculada com base nos resultados de todas as 10 imagens. Os valores médios das métricas para cada método podem ser visualizados na Tabela 5.1.

Tabela 5.1: Avaliação das **TTRs** em comparação com **Real-ESRGAN** treinado com 40 imagens de cana-de-açúcar.

Métricas	Vizinhos mais Próximos	Bilinear	Bicúbico	Real-ESRGAN
PSNR ↑	19,47	21,26	21,09	18,85
SSIM ↑	0,56	0,60	0,63	0,45
LPIPS ↓	0,70	0,48	0,53	0,29

↑ Quanto maior melhor; ↓ Quanto menor melhor

Embora os métodos tradicionais como Vizinhos mais Próximos, Bilinear e Bicúbico apresentem melhores valores de **PSNR** e **SSIM**, o método **Real-ESRGAN** se destaca quando se considera a métrica **LPIPS**. A Figura 5.1 mostra uma comparação visual entre a imagem original de alta resolução espacial e a imagem gerada pelo **Real-ESRGAN**, evidenciando os artefatos gerados durante o processo de melhoramento de resolução espacial. Estes artefatos são comuns em técnicas de super-resolução, especialmente quando

¹A média (ou valor médio) dos resultados é calculada somando os valores das métricas para cada imagem gerada e dividindo o total pela quantidade de imagens utilizadas.

se utiliza um método de super-resolução para ampliação em uma escala maior (5x), e foi treinado por um pequeno conjunto de dados, como foi o caso.




Figura 5.1: Amostra de comparação de algoritmo na mesma região (em vermelho): (a) Imagem alta resolução espacial capturada pelo VANT; (b) Imagem resultante após a aplicação da técnica Real-ESRGAN. (Amplie para melhor visualização.)

Conforme os resultados apresentados na Tabela 5.1, o método Real-ESRGAN apresenta melhorias significativas em relação aos métodos tradicionais, com ganhos de 141,37% (comparado com o método Vizinhos Mais Próximos), 82,75% (Bicúbico) e 65,51% (Bilinear), quando avaliado pela métrica LPIPS. Embora o Real-ESRGAN produza artefatos visíveis nas imagens, especialmente quando ampliadas para $5\times$, o LPIPS sugere que ele ainda consegue melhorar a qualidade perceptual das imagens com base na percepção visual humana.

5.1.2 Análise Qualitativa

A análise qualitativa foi realizada por meio da avaliação visual dos resultados obtidos pelas TTRs e pelo Real-ESRGAN. A Figura 5.2 apresenta os resultados dessas técnicas aplicadas em imagens de cana-de-açúcar. Os resultados indicam que as imagens geradas pela técnica de aprendizado profundo Real-ESRGAN apresentam superior nitidez e maior riqueza de detalhes, mesmo com um número reduzido de imagens usadas no treinamento (apenas 40 imagens), evidenciando a eficácia dessas abordagens para a melhoria da qualidade da imagem.

Outra observação durante os experimentos foi que o método de Vizinhos Mais Próximos frequentemente gera imagens com serrilhados visíveis. Para minimizar esse efeito, algumas técnicas de suavização, como o filtro Laplaciano, foram utilizadas. A Figura 5.3 ilustra essa estratégia. Na imagem (a), vemos o resultado da reamostragem uti-




Figura 5.2: Imagem de *BR* com aplicação dos métodos para melhor resolução espacial: Vizinhos mais próximos, Bilinear, Bicúbica e *Real-ESRGAN*.

lizando o algoritmo Vizinhos Mais Próximos, em que o efeito de serrilhado é claramente perceptível. Em (b), o filtro Laplaciano foi aplicado à imagem gerada pelo Vizinhos Mais Próximos, com o intuito de suavizar os contornos. Embora o filtro tenha atenuado o serrilhado, a imagem resultante apresenta uma certa “borragem” que compromete a nitidez. Por outro lado, em (c), o método *Real-ESRGAN*, mesmo sem o uso de qualquer filtro de suavização, consegue produzir uma imagem mais nítida e com menos irregularidades, demonstrando sua capacidade superior de preservar os detalhes.




Figura 5.3: Filtro Laplaciano na imagem para reduzir o efeito serrilhado. (a) Algoritmo tradicional do vizinho mais próximo. (b) Vizinho mais próximo com filtro de suavização. (c) *Real-ESRGAN* aplicado à mesma região sem filtro de suavização. (Amplie para uma melhor visualização)

5.2 Experimento II - Cana-de-açúcar: Comparação entre 40 e 500 Imagens

Os experimentos descritos nesta seção foram apresentados no *International Symposium on Visual Computing (ISVC)* (Nogueira et al., 2023c). O objetivo deste experimento foi avaliar o desempenho de diferentes TTRs em comparação com as três técnicas de SRRP aplicadas a imagens de cana-de-açúcar. As imagens utilizadas neste estudo foram previamente detalhadas na Seção 4.2.1. Contudo, dois cenários distintos foram testados: um utilizando 40 imagens para treinamento e outro com um conjunto mais robusto de 500 imagens. A etapa de Aumento de Resolução Espacial contou com 10 imagens. Essas 10 imagens foram usadas tanto para testar o conjunto de 40 como o de 500 imagens. Optamos por repetir as imagens de teste justamente para analisar o comportamento das técnicas conforme o banco de dados aumenta.

Os métodos de SRRP, Real-ESRGAN e MuLUT foram treinados conforme as etapas descritas na Seção 4.4.1, com ambos passando por 10.000 iterações. Após o término do treinamento, iniciou-se a fase de **Aumento de Resolução Espacial**, em que as 10 imagens com dimensões de 300×300 *pixel* foram reduzidas (*downscaling*) para escalas de $4\times$, $3\times$ e $2\times$, resultando em imagens de baixa resolução espacial com tamanhos de 75×75 *pixel*, 100×100 *pixel* e 150×150 *pixel*, respectivamente. Essas imagens degradadas foram então submetidas às TTRs, bem como às técnicas de SRRP. O objetivo foi restaurar as imagens para suas resoluções originais em escalas de $2\times$, $3\times$ e $4\times$. Essa variação de escala aplicada às imagens durante a etapa de **Aumento de Resolução Espacial** impacta diretamente nos resultados. A influência das variações de escala nos métodos pode ser observada na Figura 5.4.

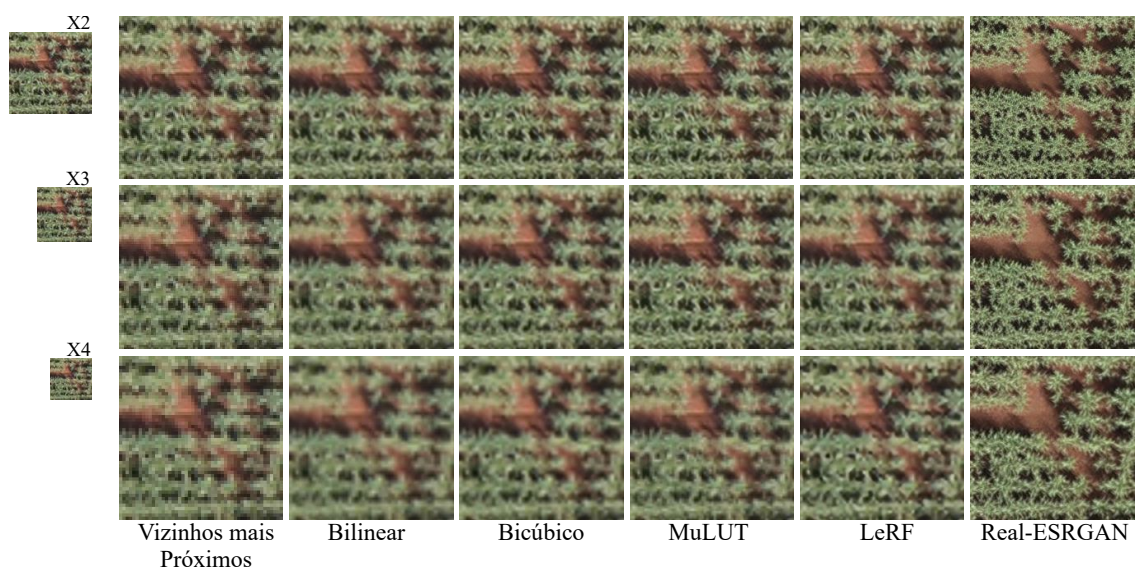


Figura 5.4: Comparação dos resultados obtidos com diferentes escalas e seus respectivos algoritmos.

Neste experimento, a análise dos resultados também foi dividida em análise quantitativa, baseada em métricas objetivas, e análise qualitativa, focada nos aspectos visuais.

5.2.1 Análise Quantitativa

Assim como na análise quantitativa anterior, a Tabela 5.2 apresenta a média dos resultados do experimento realizado, com o conjunto de 10 imagens para teste. Nesse experimento, **LeRF** se destacou, com o melhor resultado para a métrica **LPIPS** (0,123), em relação aos Vizinhos Mais Próximos (0,730). **MuLUT** obteve o melhor desempenho em **PSNR** (28,980) e **SSIM** (0,897). Já o algoritmo dos Vizinhos Mais Próximos obteve os piores resultados nas três métricas.

Nota-se que os métodos baseados em aprendizado profundo obtiveram melhorias substanciais em relação às técnicas tradicionais. Esses resultados mostram indícios de que as técnicas de aprendizado profundo podem ser úteis na tarefa de melhorar a resolução espacial de imagens de cana-de-açúcar.

Tabela 5.2: *TTR vs SRRP (40 imagens).*

Métricas	Vizinhos mais Próximos	Bilinear	Bicúbico	MuLUT	LeRF	Real-ESRGAN
PSNR ↑	25,043	26,342	27,415	28,980	28,457	26,294
SSIM ↑	0,775	0,804	0,848	0,897	0,894	0,847
LPIPS ↓	0,730	0,269	0,227	0,146	0,123	0,190

↑ Quanto maior melhor; ↓ Quanto menor melhor

No entanto, ao comparar o **Real-ESRGAN** com o **MuLUT**, é possível observar a presença de artefatos indesejados durante o processo de aumento de resolução espacial, o que pode explicar o desempenho inferior do **Real-ESRGAN** em algumas métricas. Ao analisar a imagem aumentada **AR** e compará-la com os resultados das técnicas **Real-ESRGAN** e **MuLUT** em uma ampliação de $5\times$ (Figura 5.5), torna-se evidente que o **Real-ESRGAN** gera distorções visíveis, comprometendo a qualidade visual e a fidelidade em relação à imagem de referência.

A média dos resultados dos experimentos com o conjunto de 500 imagens está apresentada na Tabela 5.3. Como observado nos experimentos anteriores, os métodos baseados em aprendizado profundo continuaram a se destacar. Um aspecto interessante desses resultados foi o desempenho do método **Real-ESRGAN**, que teve um ganho de 484,34% se comparado com o algoritmo de Vizinho Mais Próximo.

O **Real-ESRGAN** apresentou uma melhoria significativa à medida que o tamanho do banco de dados aumentou, com o **LPIPS** diminuindo de 0,190 para 0,128 ao passar



Figura 5.5: Amostra de comparação de algoritmo na mesma região (em vermelho): (a) Imagem de alta resolução espacial capturada pelo VANT; (b) Imagem resultante após técnica Real-ESRGAN; (c) Imagem resultante após técnica MuLUT. (Amplie para melhor visualização.)

de 40 para 500 imagens. Em contraste, o método **LeRF** não demonstrou um ganho semelhante, possivelmente devido ao fato de que o algoritmo não foi treinado especificamente com o nosso conjunto de imagens.

Tabela 5.3: *TTR* vs *SRRP* (500 imagens).

Métricas	Vizinhos mais Próximos	Bilinear	Bicúbico	MuLUT	LeRF	Real-ESRGAN
PSNR ↑	26,134	27,519	28,492	29,637	22,325	29,251
SSIM ↑	0,791	0,830	0,867	0,904	0,668	0,901
LPIPS ↓	0,746	0,242	0,247	0,178	0,413	0,128

↑ Quanto maior, melhor; ↓ Quanto menor, melhor.

5.2.2 Análise Qualitativa

A análise visual dos resultados reforça as conclusões quantitativas. A Figura 5.6 exibe exemplos de imagens obtidas via experimento com 40 imagens, em que já é possível perceber a superioridade dos métodos de aprendizado profundo em termos de restauração de detalhes e suavidade de bordas. Dentre as **TTRs**, a que mais se destaca em termos de resultados visuais é o Bicúbico e, embora ele seja mais eficiente do que as técnicas de

SRRP, por não exigir treinamento prévio, ele tende a apresentar suavizações que resultam em perda de detalhes finos, podendo comprometer a precisão para análise agrônômica.




Figura 5.6: Resultados obtidos treinando as redes com 40 imagens. a) Imagem do reduzida para fins de teste. b) Resultados após aplicar as **TTRs** e de **SRRP** na imagem de baixa resolução espacial.

A Figura 5.7 apresenta os resultados do experimento com 500 imagens, as imagens demonstrando uma melhoria em termos de qualidade visual conforme o tamanho do conjunto de treinamento aumenta. Os métodos de super-resolução mantiveram um desempenho superior em restaurar as imagens agrônômicas. Apesar das limitações apresentadas pelo **Real-ESRGAN**, seu potencial em criar imagens de alta resolução espacial não pode ser ignorado.




Figura 5.7: Resultados obtidos pelas **TTRs** e **SRRP**, com treinando usando 500 imagens.

Em síntese, esses experimentos demonstram a eficácia dos métodos baseados em aprendizado profundo no melhoramento de imagens agrônômicas. As diferenças observadas entre os métodos destacam a importância de combinar métricas quantitativas e avaliações visuais na análise de qualidade de imagens.

Além dos experimentos focados em imagens agrícolas, realizamos outro teste para avaliar o desempenho dos algoritmos em cenários que envolvem outros tipos de informações, como, por exemplo, imagens de árvores. O objetivo era verificar como os métodos se comportariam em situações que estão além do contexto estritamente agrícola.

Os resultados desse experimento estão ilustrados na Figura 5.8, em que destacamos duas imagens do banco de dados de **Aumento de Resolução Espacial** contendo árvores (Figura 5.8 a) e (Figura 5.8 b). Essas imagens foram reduzidas em um fator de $4\times$, simulando condições de baixa resolução espacial. Em seguida, aplicamos as técnicas de **SRRP** em cada uma delas. Para uma melhor visualização, ampliamos especificamente as áreas das copas das árvores, sendo possível assim observar a nitidez e a preservação dos detalhes nas imagens geradas.

Neste contexto, o método **Real-ESRGAN** se destacou por seu desempenho visualmente superior, gerando imagens mais nítidas e detalhadas em comparação aos outros algoritmos. Por exemplo, o método de Vizinhos Mais Próximos resulta em imagens com serrilhado visível, enquanto as abordagens Bilinear e Bicúbico produzem imagens mais embaçadas, com menos definição.




Figura 5.8: Resultados obtidos ao aplicar as técnicas de **SRRP** em duas imagens da base de testes que continham árvores.

Os resultados visuais complementam as análises quantitativas apresentadas anteriormente, reforçando o potencial das técnicas de **SRRP** para aplicações práticas na análise agrônômica.

Com base nos bons resultados obtidos com a cultura da cana-de-açúcar, decidimos expandir os testes para outras culturas, explorando dessa vez o milho, que apresenta morfologia e padrões visuais distintos comparados com a cultura da cana-de-açúcar. No experimento seguinte, direcionamos nossa análise para imagens de milho, inicialmente

utilizando um conjunto de 200 imagens e, em seguida, ampliando para 1.000 imagens, a fim de avaliar o impacto do tamanho do conjunto de treinamento na qualidade dos resultados.

5.3 Experimento III - Milho

Os experimentos descritos nesta seção foram publicados no *IEEE Access* (Nogueira et al., 2024). O objetivo deste estudo foi avaliar o desempenho de diferentes TTRs em comparação com as três técnicas de SRRP aplicadas a imagens de milho. As imagens utilizadas neste estudo foram previamente detalhadas na Seção 4.2.1. Esse banco de dados foi dividido em dois conjuntos de treinamento (Conjunto A e Conjunto B) e um conjunto de Aumento de Resolução Espacial. O conjunto de treinamento **Conjunto A** continha 200 imagens e o **Conjunto B** continha 1.000 imagens. O **Conjunto de Aumento de Resolução Espacial** consistia em 20 imagens, e as imagens deste conjunto não foram usadas no treinamento dos algoritmos de super-resolução.

Os métodos de SRRP, Real-ESRGAN e MuLUT foram treinados conforme as etapas descritas na Seção 4.4.1. No Conjunto A 1.000 iterações foram realizadas para o treinamento de ambas as redes. Este número de iterações foi escolhido para avaliar a capacidade dos modelos de aprender rapidamente a partir de um conjunto de dados menor, garantindo uma convergência rápida. Já o Conjunto B foi usado para treinamento mais extenso com 10.000 iterações. O aumento do número de iterações permitiu que os modelos ajustassem melhor os parâmetros internos, resultando em precisão aprimorada e qualidade visual superior, especialmente nesses cenários em que nossos dados aumentaram de um teste para o outro.

Antes do treinamento, inicialmente, as imagens de alta resolução espacial (Conjunto A e Conjunto B) são degradadas usando o método bicúbico para gerar imagens de baixa resolução espacial correspondentes. Em três escalas diferentes, a saber: $4\times$, $3\times$ e $2\times$, reduzindo assim a resolução espacial das imagens de 250 *pixel* para 62 *pixel*, 83 *pixel* e 125 *pixel*, respectivamente.

Na etapa de *Aumento de Resolução Espacial* de imagens aplicamos as TTRs e as técnicas de SRRP. O **Conjunto de Aumento de Resolução Espacial** usado foi o mesmo para todas as técnicas, composto por imagens com resoluções variadas de 62, 83 e 125 *pixel*. Para tal, antes foi necessário reduzir a resolução espacial com as escalas variando de $4\times$, $3\times$ e $2\times$, respectivamente.

Assim como nos experimentos realizados com as imagens de cana-de-açúcar, a escala aplicada às imagens no Treinamento e na de Aumento de Resolução Espacial tem um impacto direto nos resultados. O reflexo das variações de escala no método Real-ESRGAN pode ser visto na Figura 5.9. Primeiramente, as imagens foram reduzidas

em 2×, 3× e 4×, para simular as degradações que as imagens podem sofrer. Depois, tiveram suas resoluções ampliadas para voltar ao tamanho original. O recorte em amarelo é a região da imagem gerada que será ampliada para uma melhor comparação, conforme destacado em vermelho.




Figura 5.9: Comparação visual do impacto da variação de escala no resultado do método *Real-ESRGAN*.

A etapa de Aumento de Resolução Espacial dos métodos *Real-ESRGAN*, *MuLUT* usou os modelos treinados com as imagens de milho, descritas na Seção 4.2.1. Para melhorar a resolução espacial das imagens fornecidas como entrada, convertendo-as de versões de baixa qualidade para versões de alta resolução espacial. Os resultados dessa melhoria de resolução espacial tanto das *TTRs* quanto das técnicas de *SRRP* são apresentados e discutidos a seguir.

5.3.1 Treinamento realizado com 200 imagens

Neste cenário, apenas 200 imagens do banco de dados foram utilizadas para treinar as redes profundas. A análise dos resultados foi dividida em duas partes principais: uma análise quantitativa baseada em métricas objetivas (descritas na Seção 4.5) e uma análise qualitativa focando nos aspectos visuais.

Análise Quantitativa

Assim como nos experimentos anteriores, esses resultados quantitativos foram obtidos ao comparar as imagens geradas por cada método testado com a imagem original. Para cada uma das 20 imagens utilizadas na etapa de Aumento de Resolução Espacial, as

métricas de similaridade foram calculadas entre a imagem original e a imagem gerada. Por fim, a média dessas métricas foi calculada com base nos resultados de todas as 20 imagens, considerando o treinamento apenas com o Conjunto A de 200 imagens. Os valores médios das métricas para cada método podem ser visualizados na Tabela 5.4.

É possível observar que os métodos de aprendizado profundo analisados obtiveram desempenhos significativamente superiores em comparação aos métodos tradicionais de reamostragem, com ganhos expressivos. Por exemplo, o método **Real-ESRGAN** apresentou um ganho de 249,59% na métrica **LPIPS** em relação ao método Vizinhos Mais Próximos, destacando-se como o mais eficiente para redução do erro perceptual. Em termos de **PSNR**, o **LeRF** foi o método que obteve o melhor valor (30,330), superando o **MuLUT** (29,496) e os métodos tradicionais.

Tabela 5.4: Avaliação das *TTRs* em comparação com *MuLUT*, *LeRF* e *Real-ESRGAN* para 200 imagens.

Métricas	Vizinhos mais Próximos	Bilinear	Bicúbico	MuLUT	LeRF	Real-ESRGAN
PSNR ↑	25,569	27,532	29,205	29,496	30,330	27,179
SSIM ↑	0,724	0,725	0,788	0,795	0,825	0,746
Jaccard ↑	0,912	0,918	0,903	0,909	0,915	0,952
LPIPS ↓	0,430	0,341	0,278	0,225	0,151	0,123

↑ Quanto maior, melhor; ↓ Quanto menor, melhor.

Além disso, a análise das métricas **SSIM** e Jaccard também mostrou vantagens para os métodos baseados em aprendizado profundo, com **LeRF** e **Real-ESRGAN** apresentando valores mais elevados em comparação aos métodos tradicionais. Esses resultados indicam que os métodos de **SRRP** são eficazes no aumento da resolução espacial de imagens agrícolas, seja para cana-de-açúcar ou milho, mostrando avanços consideráveis sobre as abordagens convencionais.

A seguir, alguns resultados visuais deste experimento podem ser observados, com o intuito de complementar os resultados quantitativos apresentados.

Análise Qualitativa

A Figura 5.10 resume os experimentos conduzidos após o treinamento dos modelos **Real-ESRGAN** e **MuLUT** com 200 imagens, bem como as demais técnicas utilizadas. A área destacada em amarelo representa o corte de uma imagem de alta resolução espacial gerada artificialmente a partir de uma imagem de baixa resolução reduzida em $4\times$, usando **TTR** e **SRRP**. Para facilitar a visualização, esse corte é ampliado, conforme destacado em vermelho. Visualmente, o ganho fornecido pelas técnicas de **SRRP** é evidente, produzindo imagens mais nítidas mesmo com o treinamento limitado a apenas 200 imagens.

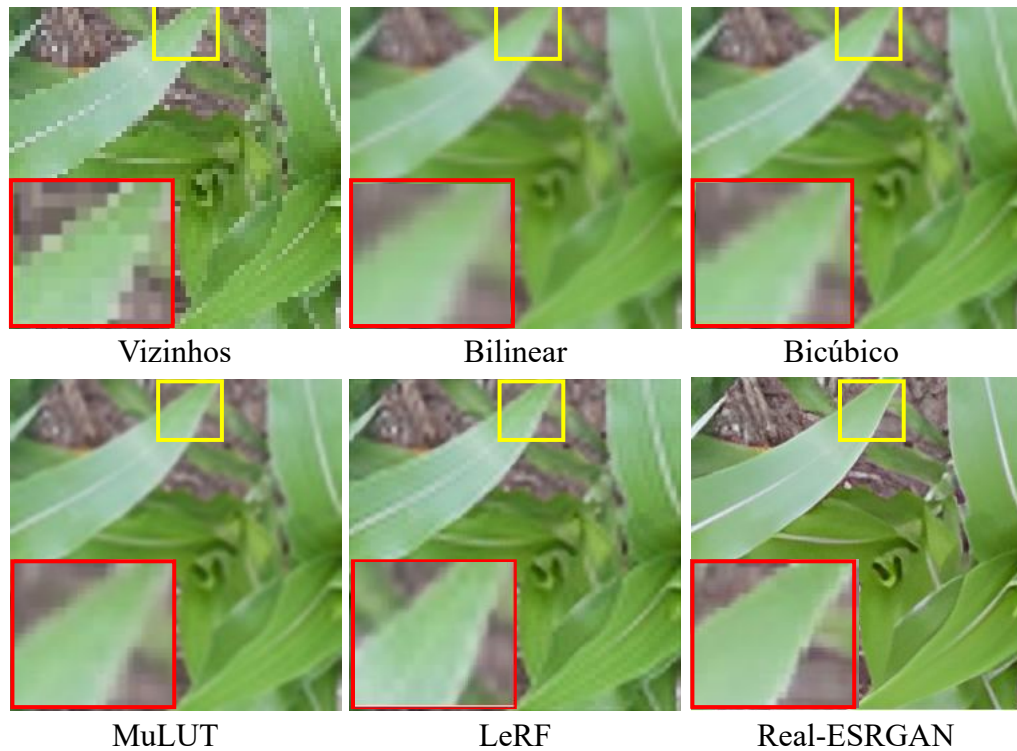


Figura 5.10: Avaliação das *TTRs* em comparação com as técnicas de *SRRP* para 200 imagens.

Na seção seguinte, o conjunto de treinamento é aplicado de 200 imagens a 1.000 imagens.

5.3.2 Treinamento realizado com 1.000 imagens

Neste experimento, aumentamos o tamanho do banco de dados utilizado no treinamento das redes, de 200 para 1.000 imagens. E analisamos o quanto o tamanho do banco de dados influencia nos resultados quantitativos e qualitativos.

Análise Quantitativa

A análise quantitativa é similar à análise para o conjunto de treinamento de 200 imagens. A média dos resultados para o **Conjunto B** (1.000 imagens), apresentados na Tabela 5.5, mostra que os métodos de aprendizado profundo, especialmente o **Real-ESRGAN**, superaram os métodos tradicionais de reamostragem em várias métricas. O **Real-ESRGAN** obteve um ganho de 234,4% na métrica **LPIPS** quando comparado aos Vizinhos mais Próximos. Em termos de **PSNR**, o **MuLUT** apresentou o melhor desempenho (34,196), seguido de perto pelo **LeRF** (33,676), enquanto os Vizinhos mais Próximos ficaram em último (27,944). O **SSIM** também destacou o **MuLUT** (0,907) como o melhor, seguido pelo **LeRF** (0,895), ambos superando os métodos tradicionais. No índice Jaccard, o **Real-ESRGAN** obteve o melhor valor (0,937), seguido pelo **LeRF** (0,886),

com ambos superando os métodos convencionais, que apresentaram valores mais baixos. Esses resultados indicam que os métodos de aprendizado profundo, como o **LeRF** e o **Real-ESRGAN**, são mais eficazes no aumento da resolução espacial de imagens agrícolas,

Tabela 5.5: Avaliação das *TTRs* em comparação com as técnicas de *SRRP* para 1.000 imagens.

Métricas	Vizinhos mais Próximos	Bilinear	Bicúbico	MuLUT	LeRF	Real-ESRGAN
PSNR ↑	27,944	32,520	32,520	34,196	33,676	27,975
SSIM ↑	0,798	0,880	0,880	0,907	0,895	0,852
Jaccard ↑	0,887	0,891	0,869	0,866	0,886	0,937
LPIPS ↓	0,427	0,225	0,225	0,155	0,192	0,128

↑ Quanto maior, melhor; ↓ Quanto menor, melhor.

Análise Qualitativa

A Figura 5.11 exemplifica os experimentos conduzidos após o treinamento dos modelos usando um conjunto de dados contendo 1.000 imagens.




Figura 5.11: Avaliação das *TTRs* em comparação com as técnicas de *SRRP* para 1.000 imagens. (Ampliar para melhor visualização)

A parte destacada de vermelho se refere a uma região da imagem original, que será usada para comparar com as imagens criadas artificialmente aplicando as **TTRs** em comparação com as técnicas de **SRRP**. Observa-se visualmente que a técnica **Real-ESRGAN** produz uma imagem mais nítida, o que pode contribuir significativamente para a extração de informações valiosas, como detecção de doenças, e auxiliar no manejo adequado desta cultura.

Durante nossos experimentos, observamos que a aplicação de técnicas de **SRRP** no contexto agrícola oferece um grande potencial para melhorar a resolução espacial das imagens. As técnicas utilizadas, como **MuLUT**, **LeRF** e **Real-ESRGAN**, têm o potencial de auxiliar na agricultura moderna ao melhorar significativamente a resolução espacial das imagens capturadas por **VANT**.

Além das bases de imagens obtidas por meio dos **VANTs**, iremos realizar alguns experimentos em imagens de satélite. Para verificar a adaptabilidade das diferentes técnicas testadas.

5.4 Experimento IV - Imagens de Satélite

Assim como nos experimentos anteriores, o objetivo deste experimento foi avaliar a eficácia das **TTRs** em comparação com as técnicas de **SRRP** na melhoria da qualidade das imagens de satélite. As imagens de satélite apresentam grandes desafios, como a presença de ruídos, baixa resolução espacial e detalhes finos que podem ser difíceis de distinguir. Para tentar minimizar essas limitações, foram utilizadas as técnicas de melhoramento de resolução espacial já discutidas, visando aumentar a resolução espacial e melhorar a definição dos detalhes presentes nas imagens.

O banco de dados utilizado neste experimento foi descrito na Seção 4.2.2. Sendo 700 imagens para treinamento e 6 imagens para teste (aumento de resolução espacial). Antes do treinamento, as 700 imagens originais de maior resolução espacial (3 *m/pixel*) são degradadas usando o método Bicúbico para gerar imagens de baixa resolução espacial correspondentes. Em três escalas diferentes, a saber: 4×, 3× e 2×, reduzindo assim a resolução espacial das imagens de 255 *pixel* para 63 *pixel*, 85 *pixel* e 127 *pixel*, respectivamente. Essas imagens degradadas e as imagens originais são utilizadas durante o treinamento da rede.

Nestes experimentos, o treinamento foi realizado apenas com o método **Real-ESRGAN**, conforme as etapas descritas na Seção 4.4.1. Para treinar a rede, foram utilizadas 10.000 iterações, conforme o equipamento disponível.

Na etapa de **Aumento de Resolução Espacial**, aplicamos as **TTRs** e o método de **SRRP** foi o **Real-ESRGAN**. O **Conjunto de Aumento de Resolução Espacial** usado foi de 6 imagens de satélite capturadas nos mesmos locais do que as imagens de cana-

de-açúcar capturadas por **VANT**, (descritas na Seção 4.2.1) composto por imagens com dimensões variadas conforme o tamanho de cada região. A resolução espacial dessas imagens foi reduzida em três escalas diferentes: $4\times$, $3\times$ e $2\times$. Essas imagens reduzidas tiveram sua resolução espacial aumentada via as **TTRs** e o **Real-ESRGAN**. Os resultados quantitativos e qualitativos são apresentados a seguir.

5.4.1 Análise Quantitativa

A média dos resultados obtidos das 6 imagens, para cada métrica, pode ser observada na Tabela 5.6. Com as imagens de satélite, é possível observar que o **Real-ESRGAN** se destacou em todas as métricas. Podendo ser uma alternativa promissora para melhorar a resolução espacial de imagens de satélite com alta similaridade perceptual em relação às imagens originais. Foi possível observar também que, entre as **TTRs**, o Bicúbico é o melhor, com resultados superiores ao Bilinear e Vizinhos mais Próximos, mas ainda fica atrás do **Real-ESRGAN**. Já os Vizinhos mais Próximos mostram o pior resultado, na maioria das métricas testadas, podendo ser um indicativo de que é uma técnica muito limitada para tarefas que exigem reconstrução de alta qualidade.

Tabela 5.6: Avaliação das **TTRs** em comparação com **Real-ESRGAN** para as imagens de satélite.

Métricas	Vizinhos mais Próximos	Bilinear	Bicúbico	Real-ESRGAN
PSNR \uparrow	25,317	23,083	23,418	29,783
SSIM \uparrow	0,720	0,661	0,690	0,737
Jaccard \uparrow	0,761	0,793	0,780	0,970
LPIPS \downarrow	0,450	0,472	0,439	0,175

\uparrow Quanto maior, melhor; \downarrow Quanto menor, melhor.

5.4.2 Análise Qualitativa

O resultado visual desse experimento pode ser observado na Figura 5.12, em que destacamos uma região específica da imagem de satélite em sua resolução espacial original (3 m/pixel) e comparamos essa mesma região nas imagens geradas artificialmente, com suas respectivas técnicas utilizadas. É possível observar que a técnica **Real-ESRGAN** gera um resultado mais nítido e com mais detalhes do que os demais métodos testados.

No experimento a seguir, buscamos explorar uma nova perspectiva comparada às imagens geradas artificialmente com as imagens de **VANT** que possuem uma melhor resolução espacial, as imagens de **VANT** foram adotadas como *ground truth*, já que possuem a resolução espacial mais alta e irão servir como referência para avaliar a

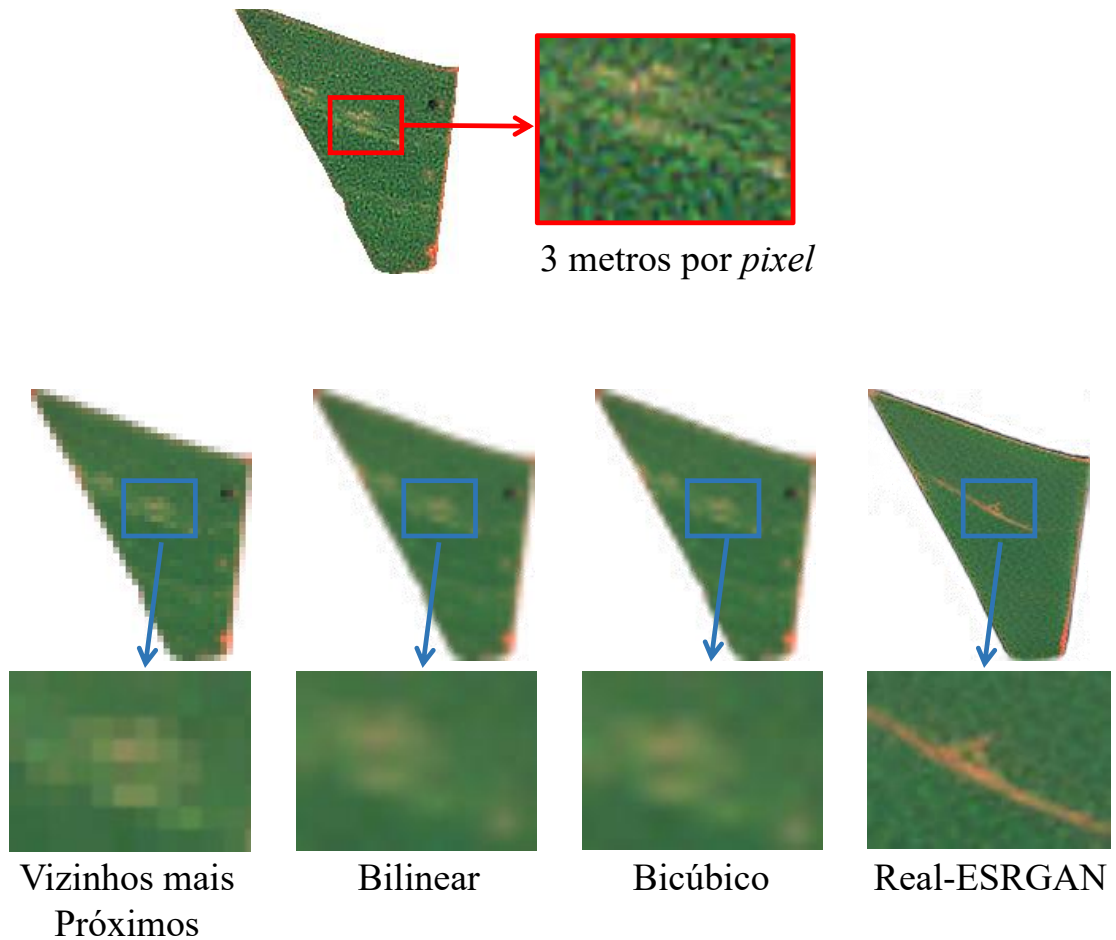


Figura 5.12: *Comparação entre as diferentes técnicas utilizadas para gerar as imagens artificiais. A região analisada da imagem original de satélite está destacada de vermelho, as regiões analisadas das imagens geradas artificialmente estão destacadas de azul.*

qualidade das imagens criadas. Para isso, dois bancos de dados foram utilizados: as imagens de cana-de-açúcar capturadas por VANT (descritas na Seção 4.2.1) e as imagens de satélite (descritas na Seção 4.2.2). Os passos para isso são descritos a seguir.

5.4.3 *Ground Truth* com as Imagens de VANT

Como possuíamos as imagens de VANT do mesmo local que as imagens de satélite, essas imagens de VANT foram usadas como *ground truth* para verificar a qualidade das imagens geradas artificialmente.

Uma análise que realizamos para comparar as imagens de satélite super resolvidas com as imagens de VANT foi reduzir a resolução espacial das imagens de VANT para uma escala mais próxima à das imagens de satélite. Isso pode ser feito por meio da técnica de reamostragem bicúbica, simulando uma versão de baixa resolução espacial das imagens de VANT.

Para isso, com o modelo treinado, o processo de teste seguiu os seguintes passos:

- **Alinhamento:** Primeiramente, verificamos o alinhamento geográfico das imagens de satélite e de **VANT**. Este passo foi crucial para verificar que ambas as imagens estejam registradas corretamente, ou seja, que os mesmos pontos no solo correspondam nas duas imagens.
- **Redução de Resolução das Imagens de Satélite:** A resolução espacial das imagens de satélite originais, com resolução espacial de 3 *m/pixel* foi reduzida usando a **TTR** Bicúbico. Essa redução simulou as condições de uma imagem de satélite com resolução espacial inferior, como uma imagem com 7 *m/pixel*, 10 *m/pixel*, ou até mais baixa. O objetivo foi criar uma versão de baixa resolução espacial da imagem de satélite, representando o que seria uma imagem típica de satélite em diferentes cenários de resolução espacial. Essas imagens foram a entrada das **TTRs** e das técnicas de **SRRP**.
- **Aplicação das **TTRs** e as técnicas de **SRRP**:** Aplicamos as **TTRs** e as técnicas de **SRRP** nas imagens de satélite de baixa resolução espacial com o intuito de melhorar sua qualidade e aumentar a resolução espacial das imagens para o nível original (3 *m/pixel*).
- **Redução de Resolução das Imagens de **VANT**:** Para as imagens de **VANT**, aplicamos a **TTR** Bicúbico, para reduzir a resolução espacial para aproximadamente 3 metros/*pixel*, para simular a resolução espacial das imagens de satélite, pois, originalmente, as imagens de **VANT** possuíam uma resolução espacial muito maior (5,63 *cm/pixel*).
- **Comparação com as Imagens de **VANT** de Baixa Resolução:** Após a redução de resolução espacial das imagens de **VANT**, realizamos uma comparação qualitativa entre as imagens de satélite super resolvidas e as imagens de **VANT** de baixa resolução espacial. A ideia foi avaliar como as **TTRs** e as técnicas de **SRRP** foram capazes de melhorar as imagens de satélite e compará-las com as imagens de **VANT** em termos de detalhes e qualidade visual.

Análise Quantitativa

Na análise quantitativa, foram observadas as médias dos resultados das **TTRs** em comparação com a **SRRP**, **Real-ESRGAN**. As métricas e a metodologia usadas foram as mesmas dos experimentos anteriores, descritas na Seção 4.5

Os resultados apresentados na Tabela 5.7 foram obtidos ao comparar as imagens artificiais geradas pelas **TTRs** e o **Real-ESRGAN** a partir das imagens de **VANT** com resolução espacial de 3 metros/*pixel* (mesma resolução espacial do que as imagens de satélite) representadas pela parte superior da Figura 5.13

Tabela 5.7: Avaliação das *TTRs* e *Real-ESRGAN* para gerar imagens artificiais a partir das imagens de *VANT* na mesma resolução espacial do que as imagens de satélite.

Métricas	Vizinhos mais Próximos	Bilinear	Bicúbico	Real-ESRGAN
PSNR ↑	20,742	18,527	19,591	27,214
SSIM ↑	0,799	0,759	0,787	0,777
Jaccard ↑	0,702	0,721	0,712	0,929
LPIPS ↓	0,348	0,442	0,403	0,228

↑ Quanto maior, melhor; ↓ Quanto menor, melhor.

De forma geral, *Real-ESRGAN* apresentou os melhores resultados nas métricas de *PSNR* (27,214), *Jaccard* (0,929) e *LPIPS* (0,228). Já o método *Bilinear* obteve os piores resultados entre os métodos tradicionais. O que sugere que ele não preservou bem os detalhes da imagem ao ser ampliada.

Já os resultados quantitativos apresentados na Tabela 5.8 mostram a similaridade entre as imagens artificiais geradas com as *TTRs* e as obtidas pelo *Real-ESRGAN*, comparadas com as imagens de satélite das regiões de cana-de-açúcar de (Rocha et al., 2022) representadas pela parte inferior da Figura 5.13

Tabela 5.8: Avaliação das *TTRs* em comparação com *Real-ESRGAN* para imagens de satélite das regiões de cana-de-açúcar de (Rocha et al., 2022).

Métricas	Vizinhos mais Próximos	Bilinear	Bicúbico	Real-ESRGAN
PSNR ↑	22,635	20,637	21,299	27,735
SSIM ↑	0,703	0,668	0,685	0,721
Jaccard ↑	0,735	0,757	0,748	0,912
LPIPS ↓	0,449	0,494	0,465	0,186

↑ Quanto maior melhor; ↓ Quanto menor melhor

Esses resultados mostram que o *Real-ESRGAN* se destacou em todas as métricas, como o *PSNR* (27,735), *SSIM* (0,721) e *LPIPS* (0,186), chegando a 58,57% no *LPIPS* em comparação com os algoritmos de Vizinhos mais Próximos, e refletem que a imagem artificial gerada por ele é mais fiel à imagem original.

O que podemos observar com esses experimentos das imagens de satélite é que os métodos tradicionais de reamostragem, apesar de amplamente utilizados em tarefas de aumento de resolução espacial, não preservam tão bem os detalhes da imagem de satélite ou imagens com resolução espacial muito baixa, quando comparados ao *Real-ESRGAN*.

Análise Qualitativa

Na análise qualitativa, a comparação visual das imagens geradas pelos métodos evidencia os resultados das métricas quantitativas, como pode ser observado na Figura 5.13. As imagens geradas pelo **Real-ESRGAN** são visualmente mais nítidas, com detalhes mais preservados e não possuem artefatos perceptíveis. **Real-ESRGAN** foi capaz de gerar imagens com um aspecto natural que se aproximou da imagem original.

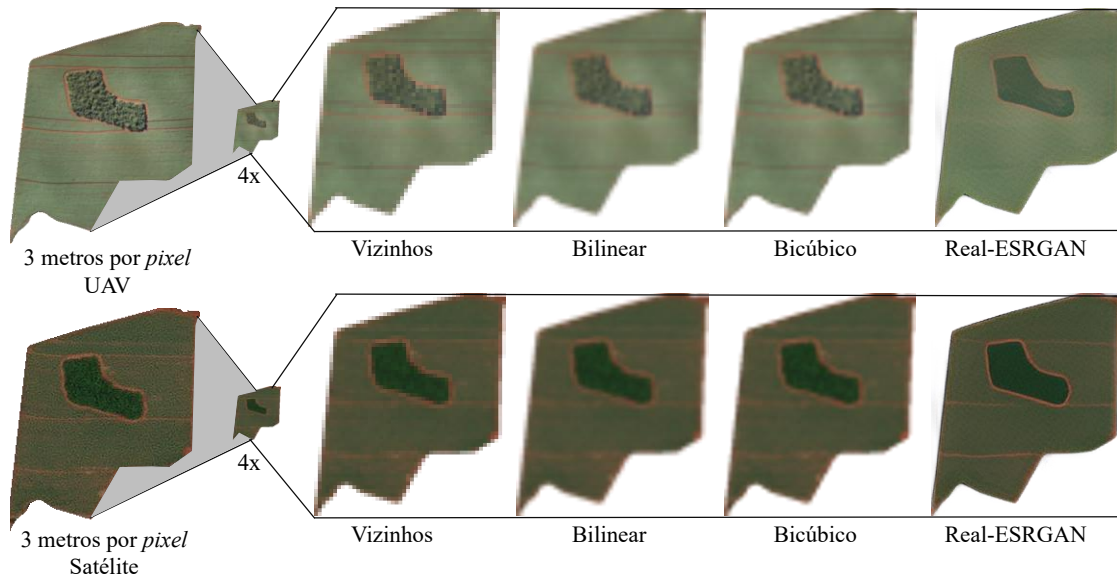


Figura 5.13: Comparação entre as técnicas aplicadas as imagens de satélite e **VANT** ambas com a mesma resolução espacial. (Ampliar para melhor visualização)

Por outro lado, os métodos Bicúbico e Bilinear produzem imagens de qualidade inferior, com uma suavização excessiva que resulta em uma perda de detalhes. O Bilinear, em particular, apresenta uma maior suavização, enquanto o Bicúbico consegue preservar um pouco mais os detalhes, mas continua distante do desempenho visual do **Real-ESRGAN**.

Por fim, o método Vizinhos Próximos gerou imagens de baixa qualidade visual, com bordas abruptas. As imagens ampliadas por este método têm um aspecto “serrilhado” e não conseguem preservar a fidelidade das imagens originais, o que se alinha com os resultados das métricas quantitativas, especialmente no **PSNR** e **LPIPS**.

O **Real-ESRGAN** demonstrou ser o melhor método para melhorar a resolução espacial das imagens, não apenas nas métricas numéricas, mas também na percepção visual das imagens, produzindo resultados mais agradáveis ao observador e mais próximos das imagens de referência.

É possível observar que, ao comparar as similaridades *pixel a pixel* entre as imagens de **AR** e **BR** utilizando as métricas tradicionais (**PSNR**, **SSIM** e Jaccard), os ganhos numéricos não correspondem proporcionalmente aos ganhos visuais. No entanto, quando

comparamos o julgamento humano com as avaliações dessas métricas tradicionais em termos de similaridade de imagem, há uma discordância significativa entre quais imagens são mais similares. Em contrapartida, as redes neurais profundas, tanto em cenários supervisionados (Russakovsky et al., 2015), autosupervisionados (Zhang et al., 2017) quanto não supervisionados (Krähenbühl et al., 2016), apresentam uma concordância surpreendentemente alta com a percepção humana. A métrica LPIPS (Zhang et al., 2018) é uma referência importante nesse contexto, e nossos resultados confirmam essa tendência.

Além desses experimentos realizados com as imagens de VANT (*ground truth*), conduzimos outro experimento no qual utilizamos apenas a imagem de satélite em sua resolução espacial original (3 m/pixel). O objetivo deste teste foi ampliar essa imagem artificialmente em 3× e 4×, com o intuito de observar como a resolução espacial da imagem de satélite poderia ser aumentada para se aproximar ao máximo da resolução espacial de uma imagem de VANT com 5,63 cm/pixel.

Com esse experimento a qualidade de uma imagem que teve sua resolução espacial ampliada de 3 m/pixel para 1 m/pixel (3×) e 0,75 m/pixel (4×) e ambas foram comparadas com a imagem de VANT de resolução espacial 5,63 cm/pixel, para simular o que seria esperado caso a imagem de satélite fosse melhorada além da resolução espacial disponível pelo serviço da Planet. Dessa forma, poderíamos ter uma ideia de como a ampliação da resolução espacial do satélite se comportaria em relação à imagem de VANT.

No entanto, o método Real-ESRGAN foi treinado com imagens que originalmente eram de 3 m/pixel, mas tiveram sua resolução espacial diminuída em 4×, 3× e 2×, resultando assim em imagens de resolução espacial de 12 m/pixel, 9 m/pixel e 6 m/pixel, respectivamente.

Por esse motivo o experimento não gerou resultados satisfatórios. A imagem gerada artificialmente parece irreal, como um desenho, o que comprometeu a comparação com a imagem de VANT. Esse teste pode ser observado na Figura 5.14, em que a imagem ampliada apresenta características visuais “falsas”, evidenciando a limitação dos métodos de ampliação para simular uma imagem de resolução espacial superior ao que foi realizado no treinamento.

Com todas as informações apresentadas, surge uma questão importante: **será que as técnicas de melhoramento de imagens realmente podem contribuir para o monitoramento agrícola?** A seção seguinte busca explorar justamente esse ponto, investigando os impactos das imagens de alta resolução espacial geradas artificialmente no contexto agrícola.

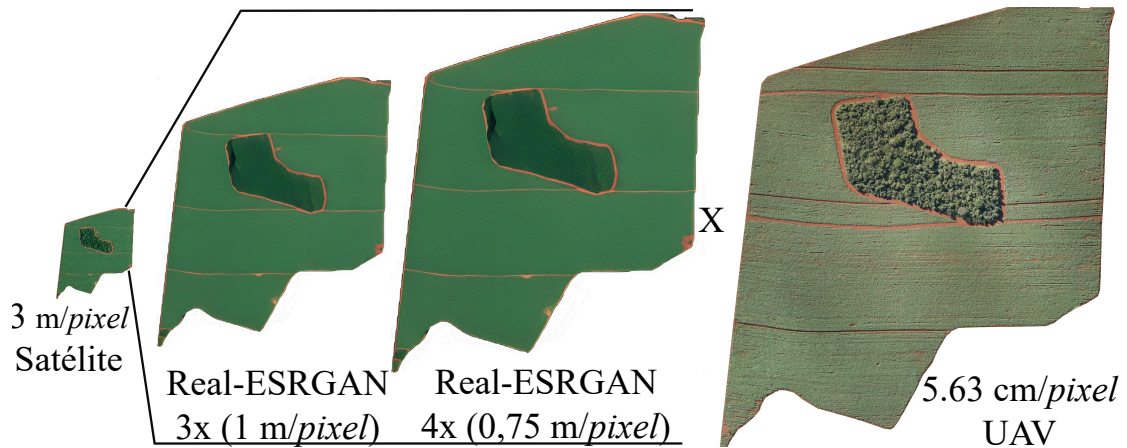


Figura 5.14: Comparação entre as imagens criadas artificialmente via *Real-ESRGAN* (aumentando em $3\times$ e $4\times$) com a imagem de *VANT* em sua resolução espacial original. (Ampliar para melhor visualização)

5.5 Investigação do Impacto das Imagens de Alta Resolução no Monitoramento Agrícola

A investigação sobre o impacto das imagens de alta resolução espacial geradas artificialmente é essencial para compreender tanto as vantagens quanto às limitações desse processo no monitoramento agrícola. Um dos principais benefícios esperados é a melhoria na precisão da detecção de anomalias nas culturas, como doenças, deficiências nutricionais, estresse hídrico e variações no crescimento. No entanto, é preciso considerar que o aumento artificial de imagens pode introduzir artefatos visuais, como distorções, contornos falsos ou texturas irreais, que podem comprometer a análise. Mesmo com o uso de métodos avançados de super-resolução, como o *Real-ESRGAN*, é possível que detalhes sutis ou informações visíveis nas imagens de alta resolução espacial reais não sejam recriados adequadamente, o que pode impactar negativamente a interpretação das imagens.

Um exemplo claro dessa limitação é observado na Figura 5.12, em que uma árvore (representada como um ponto preto) próxima à margem superior direita da imagem desapareceu após a aplicação da técnica de super-resolução. Isso ilustra como o aumento artificial pode resultar em perda de detalhes críticos que seriam importantes para o monitoramento agrícola.

Além das limitações, alguns benefícios das imagens geradas artificialmente foram identificados. Na Figura 5.15, foi possível observar que, dependendo da técnica aplicada, as características das plantas, como manchas de estresse hídrico ou sinais de doenças, tornam-se mais visíveis. Esse aumento na visibilidade dessas manchas pode facilitar a distinção entre diferentes tipos de anomalias, o que pode auxiliar em processos

de classificação ou segmentação. Dessa forma, as técnicas de super-resolução podem fornecer um auxílio importante no diagnóstico e no manejo agrícola adequado, permitindo aos profissionais identificar problemas de forma mais eficiente.

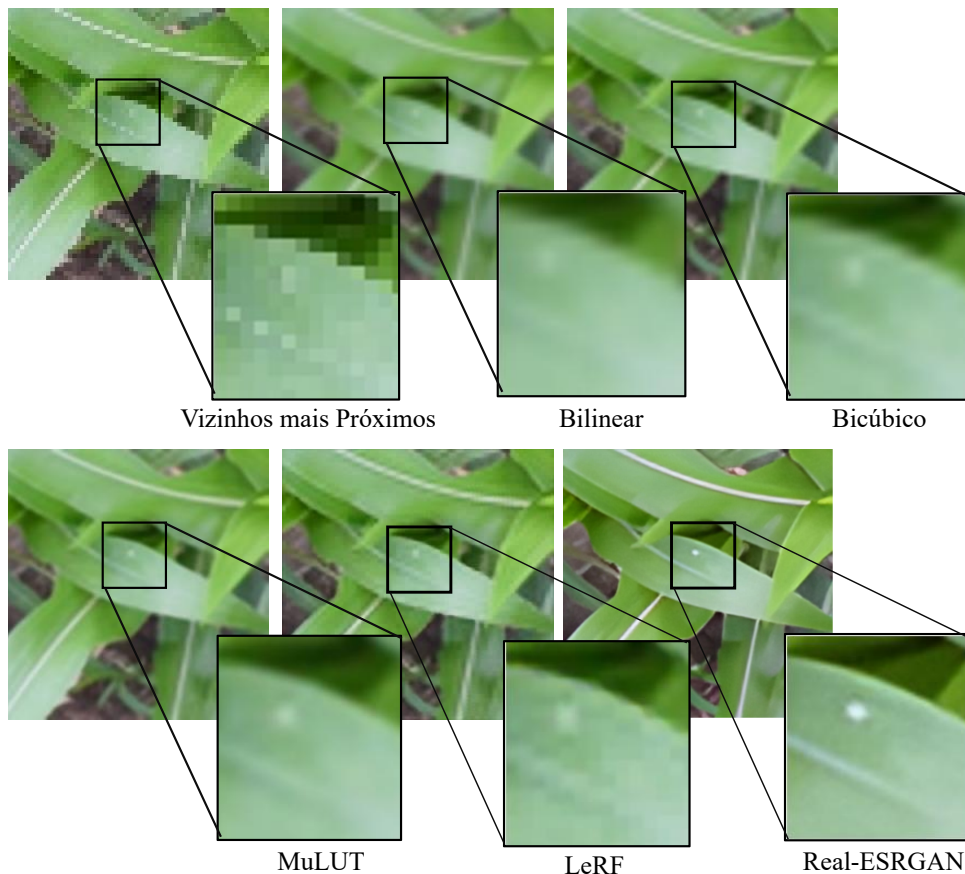


Figura 5.15: Comparação das imagens geradas artificialmente aplicando as *TTRs* e as técnicas *SRRP* em uma região de mancha na planta. (Ampliar para melhor visualização)

Essas observações sugerem que, embora as imagens de alta resolução espacial geradas artificialmente tenham um grande potencial para o monitoramento agrícola, é necessário um cuidado adicional na escolha das técnicas e na interpretação dos resultados, para garantir que os benefícios superem as limitações e as imagens melhoradas realmente contribuam para um manejo agrícola mais preciso e eficiente.

Conclusões, Contribuições e Trabalhos Futuros

Este trabalho teve como objetivo investigar o impacto das técnicas de super-resolução baseadas em aprendizado profundo na melhoria da qualidade de imagens agrícolas, comparando-as com métodos clássicos de reamostragem. Para isso, foram conduzidos quatro experimentos distintos envolvendo imagens de cana-de-açúcar e milho, capturadas por VANT e satélites.

Os resultados mostraram que os modelos baseados em aprendizado profundo, como Real-ESRGAN, MuLUT e LeRF, superaram as abordagens tradicionais em termos de preservação de detalhes, fidelidade estrutural e qualidade visual das imagens. Além disso, observou-se que o aumento do tamanho do conjunto de treinamento impacta significativamente no resultado dos modelos, com melhores valores para as métricas quantitativas conforme o número de imagens cresce.

Assim, os resultados comprovam que a super-resolução baseada em aprendizado profundo pode desempenhar um papel essencial na análise de imagens agrícolas, contribuindo para a detecção de doenças, estimativas de produtividade e otimização da gestão das culturas. A seguir são apresentadas as principais conclusões e por fim, são discutidas as direções para trabalhos futuros.

6.1 Conclusões

Durante esta pesquisa, foi possível evidenciar a eficácia das técnicas de super-resolução na melhoria da qualidade das imagens agrícolas.

No **Experimento I**, o foco era a cana-de-açúcar com um conjunto pequeno de 40 imagens, as técnicas de super-resolução mostraram-se eficientes na recuperação de detalhes importantes da imagem, superando os métodos clássicos na qualidade visual das imagens, deixando a desejar na análise quantitativa.

No **Experimento II**, ao comparar conjuntos de 40 e 500 imagens da mesma cultura, observou-se uma melhoria substancial no desempenho dos modelos com o aumento do número de imagens. Esse resultado evidenciou que conjuntos de dados

maiores potencializam os resultados das técnicas de aprendizado profundo, melhorando tanto as métricas quantitativas quanto a qualidade visual das imagens geradas.

No **Experimento III**, que envolveu o milho e utilizou 200 e 1.000 imagens, os resultados reforçaram a importância de conjuntos de dados mais amplos para a fidelidade das imagens geradas. Os métodos baseados em aprendizado profundo obtiveram resultados superiores tanto em medidas quantitativas quanto em análises qualitativas.

Por fim, no **Experimento IV**, as imagens de satélite foram super resolvidas até alcançar qualidade comparável às capturadas por **VANT** (com resolução espacial reduzida). Nesse experimento, o modelo baseado em rede neural **Real-ESRGAN** obteve os melhores resultados, tanto de forma quantitativa como qualitativa.

Com base nos resultados obtidos, a hipótese inicial deste trabalho, de que as técnicas de aprendizado profundo proporcionam melhores resultados do que os métodos clássicos para a melhoria da resolução espacial de imagens agrícolas, foi confirmada. A melhoria obtida com as técnicas propostas aumenta significativamente a utilidade prática das imagens para análises mais detalhadas e para auxiliar na tomada de decisão no campo. Na seção seguinte ficam claras as contribuições deste trabalho.

6.2 Contribuições

Esta pesquisa oferece avanços significativos no campo do processamento de imagens agrícolas, tanto nas contribuições acadêmicas quanto nas contribuições práticas.

6.2.1 Contribuições Acadêmicas

Primeiramente, realizamos uma comparação detalhada entre as **TTRs** e as técnicas modernas de **SRRP**, evidenciando a superioridade das técnicas baseadas em redes profundas. Com isso, foi possível realizar a validação do uso de técnicas de aprendizado profundo (**Real-ESRGAN**, **MuLUT** e **LeRF**) para melhorar a resolução espacial de imagens agrícolas. Outra contribuição é adaptar essas redes de super-resolução para trabalhar com imagens de satélite, gerando melhorias na qualidade das imagens para aplicações práticas.

6.2.2 Contribuições Práticas

Os resultados desta pesquisa têm implicações significativas para a área de processamento de imagens agrícolas. Pois, com os testes realizados em diferentes técnicas para melhorar a resolução espacial de imagens, foi possível observar quais se adequam mais ao contexto agrícola, com o intuito de potencializar o monitoramento agrícola em

larga escala, permitindo uma análise mais detalhada de grandes áreas cultivadas, com custos reduzidos e maior eficiência.

Na prática, os resultados deste trabalho podem ser utilizados de diferentes formas:

1. **Monitoramento da Saúde das Plantas:** Usando índices de vegetação como o Índice de Vegetação por Diferença Normalizada (NDVI), sob as imagens de alta resolução espacial, com o intuito de auxiliar na detecção de áreas de estresse nas plantas, como a falta de água, nutrientes ou a presença de doenças e pragas.
2. **Estimativa de Produtividade:** As imagens de alta resolução espacial, podem auxiliar a calcular a densidade das plantas, de forma que seja possível realizar estimativas de produtividade.
3. **Detecção de Problemas de Solo:** As imagens de alta resolução espacial, podem auxiliar na identificação de áreas do campo com problemas relacionados à variabilidade do solo, como zonas compactadas, falta de drenagem ou problemas de fertilidade.
4. **Mapeamento de Parcelas e Delimitação de Áreas:** Imagens de alta resolução espacial são úteis também para mapear com precisão as áreas cultivadas e para monitorar as fronteiras das parcelas, identificando variações no uso da terra e possíveis problemas de contaminação cruzada entre culturas. A delimitação precisa das áreas cultivadas ajuda na gestão de recursos, como água e insumos agrícolas, permitindo práticas de manejo mais sustentáveis e econômicas.
5. **Planejamento de Irrigação e Uso de Água:** As imagens de alta resolução espacial, podem auxiliar na identificação de áreas que estão recebendo água de forma desigual e ajustar o planejamento de irrigação para melhorar a eficiência hídrica.
6. **Análise de Crescimento e Desenvolvimento das Culturas:** De posse de imagens de resolução espacial ampliada é possível monitorar o crescimento das plantas ao longo do ciclo de cultivo, identificando padrões de desenvolvimento e áreas que podem estar crescendo de maneira mais lenta ou rápida. Essa análise permite os produtores a ajustar práticas de manejo, como adubação, irrigação e controle de pragas, para otimizar o desenvolvimento das culturas e melhorar a produtividade.
7. **Detecção de Deficiências Nutricionais:** As imagens de alta resolução espacial podem ser usadas para detectar deficiências nutricionais específicas nas plantas. Ao combinar imagens multiespectrais e índices de vegetação, pode facilitar a identificar áreas que precisam de adubação ou correção de nutrientes.

O intuito desta pesquisa foi contribuir para a literatura, ao explorar, pela primeira vez, o impacto dessas técnicas no contexto específico da agricultura. Ao melhorar a resolução espacial das imagens de satélites e **VANT**, estamos ampliando as possibilidades de uso dessas imagens na prática agrícola, de forma que o monitoramento fique mais

detalhado e preciso. Podendo resultar em melhores estratégias de manejo das culturas, planejamento de insumos, controle de pragas e doenças, e gestão de irrigação, tudo visando otimizar a produtividade e a sustentabilidade das culturas de milho e cana-de-açúcar.

No entanto, mesmo com todos os avanços providos por essa pesquisa, ela ainda possui limitações que serão discutidas na próxima seção.

6.3 Trabalhos Futuros

Apesar dos avanços apresentados neste estudo, ainda existem algumas limitações que abrem oportunidades para investigações futuras. Em primeiro lugar, a generalização das técnicas de super-resolução para outras culturas agrícolas necessita de mais exploração, uma vez que as características das plantas e dos solos podem variar consideravelmente de acordo com cada tipo de cultivo. Além disso, uma análise mais aprofundada dos artefatos gerados pelas redes de super-resolução é necessária para desenvolver estratégias que minimizem esses efeitos indesejáveis.

A validação prática do impacto das imagens com resolução espacial aumentada na extração de informações agronômicas também é uma área importante a ser explorada. Este será um dos focos de nossos trabalhos futuros, nos quais buscaremos avaliar se as imagens de alta resolução espacial realmente contribuem para o monitoramento da saúde das plantas, estimativas de produtividade e detecção de deficiências nutricionais.

Outro desafio a ser enfrentado está relacionado ao custo computacional das técnicas baseadas em aprendizado profundo. Embora esses métodos tenham mostrado resultados superiores, eles exigem recursos computacionais consideráveis, o que pode limitar sua aplicação em cenários de monitoramento em tempo real. Em nossos estudos futuros, planejamos explorar métodos alternativos, como o Bicubic++, que oferece tempos de processamento mais competitivos em comparação com outros algoritmos baseados em aprendizado profundo, sem comprometer significativamente a qualidade da imagem.

Por fim, pretendemos expandir a pesquisa incorporando dados multiespectrais e hiperespectrais, a fim de capturar informações mais detalhadas sobre as culturas. A ampliação do escopo do estudo para diferentes regiões geográficas e tipos das culturas agrícolas contribuirá para aumentar a robustez e a aplicabilidade das soluções propostas.

Publicações Científicas

Este capítulo apresenta as publicações resultantes no decorrer desta pesquisa, evidenciando a disseminação do conhecimento gerado em algumas conferências e periódicos científicos.

- **Conferências Internacionais:**

- Nogueira, E. A., Felix, J. P., Fonseca, A. U., Vieira, G., Ferreira, J. C., Fernandes, D. S., Soares, F. (2023, September). Upsampling of unmanned aerial vehicle images of sugarcane crop lines with a Real-ESRGAN. In 2023 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE) (pp. 285-290). IEEE. Qualis A3.
- Nogueira, E. A., Felix, J. P., Fonseca, A. U., Vieira, G., Ferreira, J. C., Fernandes, D. S., Soares, F. (2023, October). Deep Learning for Super Resolution of Sugarcane Crop Line Imagery from Unmanned Aerial Vehicles. In International Symposium on Visual Computing (ISVC) (pp. 597-609). Cham: Springer Nature Switzerland. Qualis A4.

- **Periódicos:**

- Nogueira, E., Oliveira, B., Bulcão-Neto, R., Soares, F. (2023). A systematic review of the literature on machine learning methods applied to high throughput phenotyping in agricultural production. *IEEE Latin America Transactions*, 21(7), 783-796. Qualis A4.
- Nogueira, E. A., Rocha, B. M., Vieira, G. S., Fonseca, A. U., Felix, J. P., Oliveira, A., Soares, F. (2024). Enhancing Corn Image Resolution Captured by Unmanned Aerial Vehicles with the Aid of Deep Learning. *IEEE Access*. Qualis A1.

- **Colaborações:**

- Nogueira, E. A.; Cabacinha, C. D.; Soares, F. A. A. M. N. Integration of Ecological Informatics, Remote Sensing, and Machine Learning: A Systematic

- Literature Review. In: Germano Leão Demolin-Leite. (Org.). *Global Biome Conservation and Global Warming*. 1ed. 2024, (pp. 600-647).
- Fonseca, A. U., Rocha, B. M., Nogueira, E. A., Vieira, G. S., Fernandes, D. S., Lima, J. C., Soares, F. (2022, June). Tuberculosis Detection in Chest Radiography: A Combined Approach of Local Binary Pattern Features and Monarch Butterfly Optimization Algorithm. In 2022 IEEE 46th annual computers, software, and applications conference (COMPSAC) (pp. 1408-1413). IEEE. Qualis A2.
 - Fonseca, A. U., Felix, J. P., Vieira, G. S., Rocha, B. M., Nogueira, E. A., Araújo, C. E. E., Soares, F. (2023). Diagnosticando Tuberculose com Redes Neurais Artificiais e Recursos BPPC. *Journal of Health Informatics*, 15(Especial). Qualis A4.
 - Fonseca, A. U., Nogueira, E. A., de Bastos Chagas, A. L., Felix, J. P., Fernandes, D. S. A., Soares, F. (2024). Uma nova abordagem de padrões binários em radiografias de tórax para avançar o diagnóstico de tuberculose. *Journal of Health Informatics*, 16(Especial). Qualis A4.
 - Silva, L.; Fernandes, Deborah; Nogueira, E. A.; Felix, Juliana Paula; Nascimento, T. H.; Soares, F. A. A. M. N. Exploring Gesture-Based Interaction in Smartwatch Games: A Comparative Study between Continuous Gesture Recognition and Hidden Markov Models. In: *International Symposium on Visual Computing (ISVC), 2024, Lake Tahoe. 19th International Symposium on Visual Computing, 2024*. Qualis A4.
 - Soares, F. A. A. M. N.; Siqueira, J.; Nogueira, E. A.; Felix, Juliana Paula; Fonseca, Afonso U.; Nascimento, T. H. BrailleÉcran: A Tangible Braille Approach for Smartphone Text Entry. In: *International Conference on Human-Computer Interaction (HCI), 2024, Washington. 26th International Conference on Human-Computer Interaction, 2024*. Qualis B2.

Referências Bibliográficas

- Al-Jarrah, M. A., Abu Qasmieh, I., and Alqudah, A. M. (2023). Novel hybrid computed axial phono-cardiac tomography system for heart sound sources localization. *Applied Acoustics*, 207:109339.
- Araus, J. L. and Cairns, J. E. (2014). Field high-throughput phenotyping: the new crop breeding frontier. *Trends in plant science*, 19(1):52–61.
- Bilecen, B. B. and Ayazoglu, M. (2023). Bicubic++: Slim, slimmer, slimmest-designing an industry-grade super-resolution network. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 1623–1632.
- Bishas, P. (2023). Can deep learning based super-resolution enhance the upsampling of diffusion mri for brain fiber tractography? Master’s thesis, Utrecht University.
- Bochkovskiy, A., Wang, C.-Y., and Liao, H.-Y. M. (2020). Yolov4: Optimal speed and accuracy of object detection. *ArXiv*, abs/2004.10934.
- Campbell, J. B. and Wynne, R. H. (2011). *Introduction to remote sensing*. Guilford press.
- Castro-Valdecantos, P., Apolo-Apolo, O., Pérez-Ruiz, M., and Egea, G. (2022). Leaf area index estimations by deep learning models using rgb images and data fusion in maize. *Precision Agriculture*, pages 1–18.
- Chang, Y., Li, D., Gao, Y., Su, Y., and Jia, X. (2023). An improved yolo model for uav fuzzy small target image detection. *Applied Sciences*, 13(9):5409.
- Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., and Ronneberger, O. (2016). 3d u-net: learning dense volumetric segmentation from sparse annotation. In *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2016: 19th International Conference, Athens, Greece, October 17-21, 2016, Proceedings, Part II 19*, pages 424–432. Springer.
- Colomina, I. and Molina, P. (2014). Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of photogrammetry and remote sensing*, 92:79–97.

- Czyża, S., Szuniewicz, K., Kowalczyk, K., Dumalski, A., Ogrodniczak, M., and Zieleńiewicz, Ł. (2023). Assessment of accuracy in unmanned aerial vehicle (uav) pose estimation with the real-time kinematic (rtk) method on the example of dji matrice 300 rtk. *Sensors*, 23(4):2092.
- Dang, F., Chen, D., Lu, Y., and Li, Z. (2023). Yoloweeds: a novel benchmark of yolo object detectors for multi-class weed detection in cotton production systems. *Computers and Electronics in Agriculture*, 205:107655.
- Dubey, S. R. and Singh, S. K. (2024). Transformer-based generative adversarial networks in computer vision: A comprehensive survey. *IEEE Transactions on Artificial Intelligence*, 5(10):4851–4867.
- FAOSTAT, F. (2023). Agriculture organization of the united nations fao statistical database available from: <https://www.fao.org/>. Accessed June, 40.
- Fedotova, S., Kushnir, O., and Seredin, O. (2020). Comparison of binary images based on jaccard measure using symmetry information. In *VISIGRAPP (4: VISAPP)*, pages 398–404.
- Fisher, J. R., Acosta, E. A., Dennedy-Frank, P. J., Kroeger, T., and Boucher, T. M. (2018). Impact of satellite imagery spatial resolution on land use classification accuracy and modeled water quality. *Remote Sensing in Ecology and Conservation*, 4(2):137–149.
- Gatys, L. A., Ecker, A. S., and Bethge, M. (2015). A neural algorithm of artistic style. *ArXiv*, abs/1508.06576.
- Giordan, D., Hayakawa, Y., Nex, F., Remondino, F., and Tarolli, P. (2018). The use of remotely piloted aircraft systems (rpass) for natural hazards monitoring and management. *Natural hazards and earth system sciences*, 18(4):1079–1096.
- Grandis, A., Fortirer, J. S., Navarro, B. V., de Oliveira, L. P., and Buckeridge, M. S. (2024). Biotechnologies to improve sugarcane productivity in a climate change scenario. *BioEnergy Research*, 17(1):1–26.
- Guebsi, R., Mami, S., and Chokmani, K. (2024). Drones in precision agriculture: A comprehensive review of applications, technologies, and challenges. *Drones*, 8(11).
- Guo, Y., Xiao, Y., Li, M., Hao, F., Zhang, X., Sun, H., de Beurs, K., Fu, Y. H., and He, Y. (2022). Identifying crop phenology using maize height constructed from multi-sources images. *International Journal of Applied Earth Observation and Geoinformation*, 115:103121.

- Hassan, S. I., Alam, M. M., Illahi, U., Al Ghamdi, M. A., Almotiri, S. H., and Su'ud, M. M. (2021). A systematic review on monitoring and advanced control strategies in smart agriculture. *Ieee Access*, 9:32517–32548.
- Jensen, J. R. (2009). *Remote sensing of the environment: An earth resource perspective 2/e*. Pearson Education India.
- Jo, Y. and Kim, S. J. (2021). Practical single-image super-resolution using look-up table. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 691–700.
- Jonak, M., Mucha, J., Jezek, S., Kovac, D., and Cziria, K. (2024). Spagri-ai: Smart precision agriculture dataset of aerial images at different heights for crop and weed detection using super-resolution. *Agricultural Systems*, 216:103876.
- Keys, R. (1981). Cubic convolution interpolation for digital image processing. *IEEE Transactions on acoustics, speech, and signal processing*, 29(6):1153–1160.
- Kim, T.-k., Kim, J. S., Cho, H.-c., et al. (2023). Deep-learning-based gestational sac detection in ultrasound images using modified yolov7-e6e model. *Journal of Animal Science and Technology*.
- Korhonen, J. and You, J. (2012). Peak signal-to-noise ratio revisited: Is simple beautiful? In *2012 Fourth International Workshop on Quality of Multimedia Experience*, pages 37–38. IEEE.
- Krähenbühl, P., Doersch, C., Donahue, J., and Darrell, T. (2016). Data-dependent initializations of convolutional neural networks. *International Conference on Learning Representations*.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *nature*, 521(7553):436–444.
- Ledig, C., Theis, L., Huzár, F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J., Wang, Z., et al. (2017). Photo-realistic single image super-resolution using a generative adversarial network. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4681–4690.
- Li, J., Chen, C., Cheng, Z., and Xiong, Z. (2022). Mulut: Cooperating multiple look-up tables for efficient image super-resolution. In *European Conference on Computer Vision*, pages 238–256. Springer.
- Li, J., Chen, C., Huang, W., Lang, Z., Song, F., Yan, Y., and Xiong, Z. (2023). Learning steerable function for efficient image resampling. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 5866–5875.

- Liang, J., Cao, J., Sun, G., Zhang, K., Van Gool, L., and Timofte, R. (2021). Swinir: Image restoration using swin transformer. In *Proceedings of the IEEE/CVF international conference on computer vision*, pages 1833–1844.
- Manalil, S., Coast, O., Werth, J., and Chauhan, B. S. (2017). Weed management in cotton (*gossypium hirsutum* L.) through weed-crop competition: A review. *Crop Protection*, 95:53–59.
- Manfreda, S., McCabe, M. F., Miller, P. E., Lucas, R., Pajuelo Madrigal, V., Mallinis, G., Ben Dor, E., Helman, D., Estes, L., Ciraolo, G., et al. (2018). On the use of unmanned aerial systems for environmental monitoring. *Remote sensing*, 10(4):641.
- Merchant, J. W. (2000). Remote sensing of the environment: an earth resource perspective. *Cartography and Geographic Information Science*, 27(4):311–311.
- Muchow, R. and Carberry, P. (1989). Environmental control of phenology and leaf growth in a tropically adapted maize. *Field Crops Research*, 20(3):221–236.
- Naidoo, L., Main, R., Cho, M. A., Madonsela, S., and Majozi, N. (2021). Estimating south african maize biomass using integrated high-resolution uav and sentinel 1 and 2 datasets. In *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*, pages 1594–1596. IEEE.
- Niu, Y., Han, W., Zhang, H., Zhang, L., and Chen, H. (2024). Estimating maize plant height using a crop surface model constructed from uav rgb images. *Biosystems Engineering*, 241:56–67.
- Nogueira, E., Moraes Rocha, B., da Silva Vieira, G., Ueslei da Fonseca, A., Paula Felix, J., Oliveira-Jr, A., and Soares, F. (2024). Enhancing corn image resolution captured by unmanned aerial vehicles with the aid of deep learning. *IEEE Access*, 12:149090–149098.
- Nogueira, E., Oliveira, B., Bulcão-Neto, R., and Soares, F. (2023a). A systematic review of the literature on machine learning methods applied to high throughput phenotyping in agricultural production. *IEEE Latin America Transactions*, 21(7):783–796.
- Nogueira, E. A., Felix, J. P., Fonseca, A. U., Silva, G. V., Ferreira, J. C., Fernandes, D. S. A., Oliveira, B. M., and Soares, F. (2023b). Upsampling of unmanned aerial vehicle images of sugarcane crop lines with a real-esrgan. In *2023 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)*, pages 1–4. IEEE.
- Nogueira, E. A., Felix, J. P., Fonseca, A. U., Vieira, G., Ferreira, J. C., Fernandes, D. S., Oliveira, B. M., and Soares, F. (2023c). Deep learning for super resolution of sugarcane


- crop line imagery from unmanned aerial vehicles. In *International Symposium on Visual Computing*, pages 597–609. Springer.
- Ong, P., Teo, K. S., and Sia, C. K. (2023). Uav-based weed detection in chinese cabbage using deep learning. *Smart Agricultural Technology*, 4:100181.
- Pan, Z., Li, B., He, D., Wu, W., and Ding, E. (2023). Effective invertible arbitrary image rescaling. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, pages 5416–5425.
- Rocha, B., Vieira, G., Pedrini, H., Fonseca, A., Fernandes, D., Lima, J. C., Ferreira, J. C., and Soares, F. (2022). Skew angle detection and correction in text images using rgb gradient. In *Image Analysis and Processing–ICIAP 2022: 21st International Conference, Lecce, Italy, May 23–27, 2022, Proceedings, Part II*, pages 249–262. Springer.
- Rombach, R., Blattmann, A., Lorenz, D., Esser, P., and Ommer, B. (2022). High-resolution image synthesis with latent diffusion models. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pages 10684–10695.
- Rosenfeld, A. (1969). Picture processing by computer. *ACM Computing Surveys (CSUR)*, 1(3):147–176.
- Rosenfeld, A. (1976). *Digital picture processing*. Academic press.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., et al. (2015). Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115:211–252.
- Schott, J. R. (2007). *Remote sensing: the image chain approach*. Oxford University Press.
- Segarra, J., Buchailot, M. L., Araus, J. L., and Kefauver, S. C. (2020). Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy*, 10(5).
- Sentinel Hub (2024). Agriculture: Applications and use cases. Website do Sentinel Hub. Acesso em: 2 dez. 2024.
- Sishodia, R. P., Ray, R. L., and Singh, S. K. (2020). Applications of remote sensing in precision agriculture: A review. *Remote sensing*, 12(19):3136.
- Sobrinho, O., Silva, G., Schalcher, A., Sousa, A., Júnior, W., and Santos, L. (2019). A cultura da cana-de-açúcar (*saccharum officinarum*) e o manejo da irrigação. *Revista em Agronegócio e Meio Ambiente*, 12:1605.

- Som-ard, J., Immitzer, M., Vuolo, F., and Atzberger, C. (2024). Sugarcane yield estimation in thailand at multiple scales using the integration of uav and sentinel-2 imagery. *Precision Agriculture*, pages 1–28.
- Tan, M. and Le, Q. (2021). Efficientnetv2: Smaller models and faster training. In *International conference on machine learning*, pages 10096–10106. PMLR.
- Technologies, D. M. (2024). Worldview satellites. Website da DigitalGlobe (Maxar Technologies). Acesso em: 2 dez. 2024.
- UN (2021). Un. united nations |population division. <https://www.un.org/en/desa/growing-slower-pace-world-population-expected-reach-97-billion-2050-and-could>. Acessado: 2024-11-04.
- Velumani, K., Lopez-Lozano, R., Madec, S., Guo, W., Gillet, J., Comar, A., and Baret, F. (2021). Estimates of maize plant density from uav rgb images using faster-rcnn detection model: Impact of the spatial resolution. *Plant Phenomics*.
- Verma, K., Song, X., Singh, M., de Mello Prado, R., Wu, J., and Li, Y. (2024). *Sugarcane Cultivation and Management: Challenges and Opportunities*. Apple Academic Press.
- Wang, C. and Myint, S. W. (2015). A simplified empirical line method of radiometric calibration for small unmanned aircraft systems-based remote sensing. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(5):1876–1885.
- Wang, X., Xie, L., Dong, C., and Shan, Y. (2021). Real-esrgan: Training real-world blind super-resolution with pure synthetic data. In *Proceedings of the CVF international conference on computer vision*, volume 2021-October.
- Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., Qiao, Y., and Change Loy, C. (2018). Esrgan: Enhanced super-resolution generative adversarial networks. In *Proceedings of the European conference on computer vision (ECCV) workshops*, pages 0–0.
- Wang, Z., Bovik, A. C., Sheikh, H. R., and Simoncelli, E. P. (2004). Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on image processing*, 13(4):600–612.
- Zermas, D., Nelson, H. J., Stanitsas, P., Morellas, V., Mulla, D. J., and Papanikolopoulos, N. (2021). A methodology for the detection of nitrogen deficiency in corn fields using high-resolution rgb imagery. *IEEE Transactions on Automation Science and Engineering*, 18(4):1879–1891.
- Zhang, C. and Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: a review. *Precision agriculture*, 13:693–712.


- Zhang, R., Isola, P., and Efros, A. A. (2017). Split-brain autoencoders: Unsupervised learning by cross-channel prediction. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1058–1067.
- Zhang, R., Isola, P., Efros, A. A., Shechtman, E., and Wang, O. (2018). The unreasonable effectiveness of deep features as a perceptual metric. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 586–595.
- Zhang, Y., Tian, Y., Kong, Y., Zhong, B., and Fu, Y. (2021). Residual dense network for image restoration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(7):2480–2495.
- Zhou, Z., Miao, N., Chen, X., Li, Y., Ding, L., and Shuang, F. (2022). Plenet: Efficient power line extraction network based on uav aerial imagery. *Journal of Applied Remote Sensing*, 16(3):034512.
- Zhu, J.-Y., Park, T., Isola, P., and Efros, A. A. (2017). Unpaired image-to-image translation using cycle-consistent adversarial networks. In *Proceedings of the IEEE international conference on computer vision*, pages 2223–2232.

Termos de Direitos de Cópia de Publicações Utilizadas Nesta Tese

8.1 Artigo: A Systematic Review of the Literature on Machine Learning Methods Applied to High Throughput Phenotyping in Agricultural Production



[Sign in/Register](#)



Requesting permission to reuse content from an IEEE publication

A Systematic Review of the Literature on Machine Learning Methods Applied to High Throughput Phenotyping in Agricultural Production

Author: Emilia Nogueira
 Publication: IEEE Latin America Transactions
 Publisher: IEEE
 Date: July 2023

Copyright © 2023, IEEE

Thesis / Dissertation Reuse

The IEEE does not require individuals working on a thesis to obtain a formal reuse license, however, you may print out this statement to be used as a permission grant:

Requirements to be followed when using any portion (e.g., figure, graph, table, or textual material) of an IEEE copyrighted paper in a thesis:

- 1) In the case of textual material (e.g., using short quotes or referring to the work within these papers) users must give full credit to the original source (author, paper, publication) followed by the IEEE copyright line © 2011 IEEE.
- 2) In the case of illustrations or tabular material, we require that the copyright line © [Year of original publication] IEEE appear prominently with each reprinted figure and/or table.
- 3) If a substantial portion of the original paper is to be used, and if you are not the senior author, also obtain the senior author's approval.

Requirements to be followed when using an entire IEEE copyrighted paper in a thesis:


- 1) The following IEEE copyright/ credit notice should be placed prominently in the references: © [year of original publication] IEEE. Reprinted, with permission, from [author names, paper title, IEEE publication title, and month/year of publication]
- 2) Only the accepted version of an IEEE copyrighted paper can be used when posting the paper or your thesis online.
- 3) In placing the thesis on the author's university website, please display the following message in a prominent place on the website: In reference to IEEE copyrighted material which is used with permission in this thesis, the IEEE does not endorse any of [university/educational entity's name goes here]'s products or services. Internal or personal use of this material is permitted. If interested in reprinting/republishing IEEE copyrighted material for advertising or promotional purposes or for creating new collective works for resale or redistribution, please go to http://www.ieee.org/publications_standards/publications/rights/rights_link.html to learn how to obtain a License from RightsLink.


If applicable, University Microfilms and/or ProQuest Library, or the Archives of Canada may supply single copies of the dissertation.

BACK
CLOSE WINDOW

© 2025 Copyright - All Rights Reserved | [Copyright Clearance Center, Inc.](#) | [Privacy statement](#) | [Data Security and Privacy](#)
 | [For California Residents](#) | [Terms and Conditions](#) Comments? We would like to hear from you. E-mail us at customer-care@copyright.com

8.2 Artigo: Upsampling of Unmanned Aerial Vehicle Images of Sugarcane Crop Lines with a REAL-ESRGAN

Sign in/Register?🔍



Upsampling of Unmanned Aerial Vehicle Images of Sugarcane Crop Lines with a REAL-ESRGAN

Conference Proceedings:
2023 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)

Author: Emilia A. Nogueira

Publisher: IEEE

Date: 24 September 2023

Copyright © 2023, IEEE

Thesis / Dissertation Reuse

The IEEE does not require individuals working on a thesis to obtain a formal reuse license, however, you may print out this statement to be used as a permission grant:

Requirements to be followed when using any portion (e.g., figure, graph, table, or textual material) of an IEEE copyrighted paper in a thesis:

- 1) In the case of textual material (e.g., using short quotes or referring to the work within these papers) users must give full credit to the original source (author, paper, publication) followed by the IEEE copyright line © 2011 IEEE.
- 2) In the case of illustrations or tabular material, we require that the copyright line © [Year of original publication] IEEE appear prominently with each reprinted figure and/or table.
- 3) If a substantial portion of the original paper is to be used, and if you are not the senior author, also obtain the senior author's approval.

Requirements to be followed when using an entire IEEE copyrighted paper in a thesis:

- 1) The following IEEE copyright/ credit notice should be placed prominently in the references: © [year of original publication] IEEE. Reprinted, with permission, from [author names, paper title, IEEE publication title, and month/year of publication]
- 2) Only the accepted version of an IEEE copyrighted paper can be used when posting the paper or your thesis online.
- 3) In placing the thesis on the author's university website, please display the following message in a prominent place on the website: In reference to IEEE copyrighted material which is used with permission in this thesis, the IEEE does not endorse any of [university/educational entity's name goes here]'s products or services. Internal or personal use of this material is permitted. If interested in reprinting/republishing IEEE copyrighted material for advertising or promotional purposes or for creating new collective works for resale or redistribution, please go to http://www.ieee.org/publications_standards/publications/rights/rights_link.html to learn how to obtain a License from RightsLink.

If applicable, University Microfilms and/or ProQuest Library, or the Archives of Canada may supply single copies of the dissertation.

BACK

CLOSE WINDOW

© 2025 Copyright - All Rights Reserved | [Copyright Clearance Center, Inc.](#) | [Privacy statement](#) | [Data Security and Privacy](#)
| [For California Residents](#) | [Terms and Conditions](#)Comments? We would like to hear from you. E-mail us at customercare@copyright.com

8.3 Artigo: Deep Learning for Super Resolution of Sugarcane Crop Line Imagery from Unmanned Aerial Vehicles

04/04/2025, 07:41

RightsLink - Your Account

SPRINGER NATURE LICENSE TERMS AND CONDITIONS

Apr 04, 2025

This Agreement between Emilia Alves Nogueira ("You") and Springer Nature ("Springer Nature") consists of your license details and the terms and conditions provided by Springer Nature and Copyright Clearance Center.

License Number	6001860022449
License date	Apr 04, 2025
Licensed Content Publisher	Springer Nature
Licensed Content Publication	Springer eBook
Licensed Content Title	Deep Learning for Super Resolution of Sugarcane Crop Line Imagery from Unmanned Aerial Vehicles
Licensed Content Author	Emília A. Nogueira, Juliana Paula Felix, Afonso Ueslei Fonseca et al
Licensed Content Date	Jan 1, 2023
Type of Use	Thesis/Dissertation
Requestor type	academic/university or research institute
Format	electronic
Portion	figures/tables/illustrations
Number of figures/tables/illustrations	6
Will you be translating?	yes, without original language
Number of languages	1
Circulation/distribution	1 - 29
Author of this Springer Nature content	yes
Title of new work	Técnicas de Reamostragem e Super-Resolução em Imagens de Culturas Agrícolas
Institution name	Universidade Federal de Goiás
Expected presentation date	Apr 2025
Portions	Figure 1, Figure 2, Figure 3, Figure 4, Figure 5, Figure 6.
The Requesting Person / Organization to Appear on the License	Emilia Alves Nogueira
Specific Languages	Portuguese
Requestor Location	Dr. Emilia Nogueira Rua A-5, Qd 8, Lt 7, S. Sul Jatai, GO 75802620 Brazil
Customer Tax ID	BR69061629187
Billing Type	Invoice
Billing Address	Dr. Emilia Nogueira Rua A-5, Qd 8, Lt 7, Setor Sul Jataí, Brazil 75802620
Total	0.00 USD
Terms and Conditions	Springer Nature Customer Service Centre GmbH Terms and Conditions

04/04/2025, 07:41

RightsLink - Your Account

The following terms and conditions ("Terms and Conditions") together with the terms specified in your [RightsLink] constitute the License ("License") between you as Licensee and Springer Nature Customer Service Centre GmbH as Licensor. By clicking 'accept' and completing the transaction for your use of the material ("Licensed Material"), you confirm your acceptance of and obligation to be bound by these Terms and Conditions.

1. Grant and Scope of License

1. 1. The Licensor grants you a personal, non-exclusive, non-transferable, non-sublicensable, revocable, world-wide License to reproduce, distribute, communicate to the public, make available, broadcast, electronically transmit or create derivative works using the Licensed Material for the purpose(s) specified in your RightsLink Licence Details only. Licenses are granted for the specific use requested in the order and for no other use, subject to these Terms and Conditions. You acknowledge and agree that the rights granted to you under this License do not include the right to modify, edit, translate, include in collective works, or create derivative works of the Licensed Material in whole or in part unless expressly stated in your RightsLink Licence Details. You may use the Licensed Material only as permitted under this Agreement and will not reproduce, distribute, display, perform, or otherwise use or exploit any Licensed Material in any way, in whole or in part, except as expressly permitted by this License.

1. 2. You may only use the Licensed Content in the manner and to the extent permitted by these Terms and Conditions, by your RightsLink Licence Details and by any applicable laws.

1. 3. A separate license may be required for any additional use of the Licensed Material, e.g. where a license has been purchased for print use only, separate permission must be obtained for electronic re-use. Similarly, a License is only valid in the language selected and does not apply for editions in other languages unless additional translation rights have been granted separately in the License.

1. 4. Any content within the Licensed Material that is owned by third parties is expressly excluded from the License.

1. 5. Rights for additional reuses such as custom editions, computer/mobile applications, film or TV reuses and/or any other derivative rights requests require additional permission and may be subject to an additional fee. Please apply to journalpermissions@springernature.com or bookpermissions@springernature.com for these rights.

2. Reservation of Rights

Licensor reserves all rights not expressly granted to you under this License. You acknowledge and agree that nothing in this License limits or restricts Licensor's rights in or use of the Licensed Material in any way. Neither this License, nor any act, omission, or statement by Licensor or you, conveys any ownership right to you in any Licensed Material, or to any element or portion thereof. As between Licensor and you, Licensor owns and retains all right, title, and interest in and to the Licensed Material subject to the license granted in Section 1.1. Your permission to use the Licensed Material is expressly conditioned on you not impairing Licensor's or the applicable copyright owner's rights in the Licensed Material in any way.

3. Restrictions on use

3. 1. Minor editing privileges are allowed for adaptations for stylistic purposes or formatting purposes provided such alterations do not alter the original meaning or intention of the Licensed Material and the new figure(s) are still accurate and representative of the Licensed Material. Any other changes including but not limited to, cropping, adapting, and/or omitting material that affect the meaning, intention or moral rights of the author(s) are strictly prohibited.

3. 2. You must not use any Licensed Material as part of any design or trademark.

3. 3. Licensed Material may be used in Open Access Publications (OAP), but any such reuse must include a clear acknowledgment of this permission visible at the same time as the figures/tables/illustration or abstract and which must indicate that the Licensed Material is not part of the governing OA license but has been reproduced with permission. This may be indicated according to any standard referencing system but must include at a minimum 'Book/Journal title, Author, Journal Name (if applicable), Volume (if applicable), Publisher, Year, reproduced with permission from SNCSC'.

4. STM Permission Guidelines

4. 1. An alternative scope of license may apply to signatories of the STM Permissions Guidelines ("STM PG") as amended from time to time and made available at <https://www.stm-assoc.org/intellectual-property/permissions/permissions-guidelines/>.

04/04/2025, 07:41

RightsLink - Your Account

4. 2. For content reuse requests that qualify for permission under the STM PG, and which may be updated from time to time, the STM PG supersedes the terms and conditions contained in this License.

4. 3. If a License has been granted under the STM PG, but the STM PG no longer apply at the time of publication, further permission must be sought from the Rightsholder. Contact journalpermissions@springernature.com or bookpermissions@springernature.com for these rights.

5. Duration of License

5. 1. Unless otherwise indicated on your License, a License is valid from the date of purchase ("License Date") until the end of the relevant period in the below table:

Reuse in a medical communications project	Reuse up to distribution or time period indicated in License
Reuse in a dissertation/thesis	Lifetime of thesis
Reuse in a journal/magazine	Lifetime of journal/magazine
Reuse in a book/textbook	Lifetime of edition
Reuse on a website	1 year unless otherwise specified in the License
Reuse in a presentation/slide kit/poster	Lifetime of presentation/slide kit/poster. Note: publication whether electronic or in print of presentation/slide kit/poster may require further permission.
Reuse in conference proceedings	Lifetime of conference proceedings
Reuse in an annual report	Lifetime of annual report
Reuse in training/CME materials	Reuse up to distribution or time period indicated in License
Reuse in newsmedia	Lifetime of newsmedia
Reuse in coursepack/classroom materials	Reuse up to distribution and/or time period indicated in license

6. Acknowledgement

6. 1. The Licensor's permission must be acknowledged next to the Licensed Material in print. In electronic form, this acknowledgement must be visible at the same time as the figures/tables/illustrations or abstract and must be hyperlinked to the journal/book's homepage.

6. 2. Acknowledgement may be provided according to any standard referencing system and at a minimum should include "Author, Article/Book Title, Journal name/Book imprint, volume, page number, year, Springer Nature".

7. Reuse in a dissertation or thesis

7. 1. Where 'reuse in a dissertation/thesis' has been selected, the following terms apply: Print rights of the Version of Record are provided for; electronic rights for use only on institutional repository as defined by the Sherpa guideline (www.sherpa.ac.uk/romeo/) and only up to what is required by the awarding institution.

7. 2. For theses published under an ISBN or ISSN, separate permission is required. Please contact journalpermissions@springernature.com or bookpermissions@springernature.com for these rights.

7. 3. Authors must properly cite the published manuscript in their thesis according to current citation standards and include the following acknowledgement: *'Reproduced with permission from Springer Nature'*.

8. License Fee

You must pay the fee set forth in the License Agreement (the "License Fees"). All amounts payable by you under this License are exclusive of any sales, use, withholding, value added or similar taxes, government fees or levies or other assessments. Collection and/or remittance of such taxes to the relevant tax authority shall be the responsibility of the party who has the legal obligation to do so.

9. Warranty

04/04/2025, 07:41

RightsLink - Your Account

9. 1. The Licensor warrants that it has, to the best of its knowledge, the rights to license reuse of the Licensed Material. **You are solely responsible for ensuring that the material you wish to license is original to the Licensor and does not carry the copyright of another entity or third party (as credited in the published version).** If the credit line on any part of the Licensed Material indicates that it was reprinted or adapted with permission from another source, then you should seek additional permission from that source to reuse the material.

9. 2. EXCEPT FOR THE EXPRESS WARRANTY STATED HEREIN AND TO THE EXTENT PERMITTED BY APPLICABLE LAW, LICENSOR PROVIDES THE LICENSED MATERIAL "AS IS" AND MAKES NO OTHER REPRESENTATION OR WARRANTY. LICENSOR EXPRESSLY DISCLAIMS ANY LIABILITY FOR ANY CLAIM ARISING FROM OR OUT OF THE CONTENT, INCLUDING BUT NOT LIMITED TO ANY ERRORS, INACCURACIES, OMISSIONS, OR DEFECTS CONTAINED THEREIN, AND ANY IMPLIED OR EXPRESS WARRANTY AS TO MERCHANTABILITY OR FITNESS FOR A PARTICULAR PURPOSE. IN NO EVENT SHALL LICENSOR BE LIABLE TO YOU OR ANY OTHER PARTY OR ANY OTHER PERSON OR FOR ANY SPECIAL, CONSEQUENTIAL, INCIDENTAL, INDIRECT, PUNITIVE, OR EXEMPLARY DAMAGES, HOWEVER CAUSED, ARISING OUT OF OR IN CONNECTION WITH THE DOWNLOADING, VIEWING OR USE OF THE LICENSED MATERIAL REGARDLESS OF THE FORM OF ACTION, WHETHER FOR BREACH OF CONTRACT, BREACH OF WARRANTY, TORT, NEGLIGENCE, INFRINGEMENT OR OTHERWISE (INCLUDING, WITHOUT LIMITATION, DAMAGES BASED ON LOSS OF PROFITS, DATA, FILES, USE, BUSINESS OPPORTUNITY OR CLAIMS OF THIRD PARTIES), AND WHETHER OR NOT THE PARTY HAS BEEN ADVISED OF THE POSSIBILITY OF SUCH DAMAGES. THIS LIMITATION APPLIES NOTWITHSTANDING ANY FAILURE OF ESSENTIAL PURPOSE OF ANY LIMITED REMEDY PROVIDED HEREIN.

10. Termination and Cancellation

10. 1. The License and all rights granted hereunder will continue until the end of the applicable period shown in Clause 5.1 above. Thereafter, this license will be terminated and all rights granted hereunder will cease.

10. 2. Licensor reserves the right to terminate the License in the event that payment is not received in full or if you breach the terms of this License.

11. General

11. 1. The License and the rights and obligations of the parties hereto shall be construed, interpreted and determined in accordance with the laws of the Federal Republic of Germany without reference to the stipulations of the CISG (United Nations Convention on Contracts for the International Sale of Goods) or to Germany's choice-of-law principle.

11. 2. The parties acknowledge and agree that any controversies and disputes arising out of this License shall be decided exclusively by the courts of or having jurisdiction for Heidelberg, Germany, as far as legally permissible.

11. 3. This License is solely for Licensor's and Licensee's benefit. It is not for the benefit of any other person or entity.

Questions? For questions on Copyright Clearance Center accounts or website issues please contact springernaturesupport@copyright.com or +1-855-239-3415 (toll free in the US) or +1-978-646-2777. For questions on Springer Nature licensing please visit <https://www.springernature.com/gp/partners/rights-permissions-third-party-distribution>

Other Conditions:

Version 1.4 - Dec 2022

Questions? E-mail us at customercare@copyright.com.

8.4 Artigo: Enhancing Corn Image Resolution Captured by Unmanned Aerial Vehicles With the Aid of Deep Learning

Enhancing Corn Image Resolution Captured by Unmanned Aerial Veh...

<https://ieeexplore.ieee.org/abstract/document/10707634>

Journals & Magazines > IEEE Access > Volume: 12

Enhancing Corn Image Resolution Captured by Unmanned Aerial Vehicles With the Aid of Deep Learning

Publisher: IEEE [Cite This](#)

<< Results

Emilia Alves Nogueira ; Bruno Moraes Rocha ; Gabriel da Silva Vieira ; Afonso Ueslei da Fonseca ; Juliana Paula Felix ; Antonio Oliveira-Jr

302 Full Text Views

Comment(s)

Under a Creative Commons License

- Abstract
- Authors
- Figures
- References
- Keywords
- Metrics
- More Like This
- Footnotes

As presented in the Graphical Abstract, this work is organized into six main parts: 1) Problem summary and goals, 2) main related studies, 3) Dataset creation and image c... [Show More](#)

Abstract: The increasing global population has heightened the demand for food, making it crucial to optimize agricultural practices. As a versatile crop, corn plays a crucial role ... [Show More](#)

Metadata

Contents

PDF Help



Attribution 4.0 International Creative Commons

You are free to:

1. **Share** — copy and redistribute the material in any medium or format for any purpose, even commercially.
2. **Adapt** — remix, transform, and build upon the material for any purpose, even commercially.
3. The licensor cannot revoke these freedoms as long as you follow the license terms.

Under the following terms:

1. **Attribution** — You must give [appropriate credit](#), provide a link to the license, and [indicate if changes were made](#). You may do so in any reasonable manner, but not in any way that suggests the licensor endorses you or your use.
2. **No additional restrictions** — You may not apply legal terms or [technological measures](#) that legally restrict others from doing anything the license permits.

You do not have to comply with the license for elements of the material in the public domain or where your use is permitted by an applicable [exception or limitation](#).

No warranties are given. The license may not give you all of the permissions necessary for your intended use. For example, other rights such as [publicity, privacy, or moral rights](#) may limit how you use the material.

Notice

This deed highlights only some of the key features and terms of the actual license. It is not a license and has no legal value. You should carefully review all of the terms and conditions of the actual license before using the licensed material.

Creative Commons is not a law firm and does not provide legal services. Distributing, displaying, or linking to this deed or the license that it summarizes does not create a lawyer-client or any other relationship.