



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

PRISCILA MARQUES KAI

**Deep Learning Aplicado à classificação em Nível de Pixel de  
Variedades de Culturas por Imagens Multiespectrais**

GOIÂNIA  
2024

Processo: 23070.043335/2024-70 Documento: 5021674



UNIVERSIDADE FEDERAL DE GOIÁS  
INSTITUTO DE INFORMÁTICA

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

Priscila Marques Kai

### 3. Título do trabalho

Deep Learning Aplicado à classificação em Nível de Pixel de Variedades de Culturas por Imagens Multiespectrais

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

Concorda com a liberação total do documento  SIM  NÃO<sup>1</sup>

[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(a) autor(a) e ao(a) 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 **Ronaldo Martins Da Costa, Professor do Magistério Superior**, em 07/12/2024, às 08:06, 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 **Priscila Marques Kai, Discente**, em 14/12/2024, às 12:49, 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](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **5021674** e o código CRC **51871089**.

PRISCILA MARQUES KAI

## **Deep Learning Aplicado à classificação em Nível de Pixel de Variedades de Culturas por Imagens Multiespectrais**

Tese apresentada ao Programa de Pós-Graduação em Ciência da Computação do Instituto de Informática da Universidade Federal de Goiás (UFG), como requisito 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. Doutor Ronaldo Martins da Costa

Co-Orientadora: Profa. Doutora Bruna Mendes de Oliveira

GOIÂNIA

2024

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

Marques Kai, Priscila

Deep Learning Aplicado à classificação em Nível de Pixel de Variedades de Culturas por Imagens Multiespectrais [manuscrito] / Priscila Marques Kai. - 2024.  
CIII, 103 f.

Orientador: Prof. Dr. Ronaldo Martins da Costa; co-orientadora Dra. Bruna Mendes de Oliveira.

Tese (Doutorado) - Universidade Federal de Goiás, Instituto de Informática (INF), Programa de Pós-Graduação em Ciência da Computação, Goiânia, 2024.

Bibliografia.

Inclui gráfico, tabelas, lista de figuras, lista de tabelas.

1. Cana-de-açúcar. 2. Classificação. 3. Aprendizado Profundo. I. Martins da Costa, Ronaldo, orient. II. Título.

CDU 004



UNIVERSIDADE FEDERAL DE GOIÁS

INSTITUTO DE INFORMÁTICA

## ATA DE DEFESA DE TESE

Ata nº 34 da sessão de Defesa de Tese de **Priscila Marques Kai**, que confere o título de Doutora em Ciência da Computação, na área de concentração em Ciência da Computação.

Aos seis dias do mês de novembro de dois mil e vinte e quatro, a partir das catorze horas, na sala 257 do INF, realizou-se a sessão pública de Defesa de Tese intitulada “**Deep Learning Aplicado à classificação em Nível de Pixel de Variedades de Culturas por Imagens Multiespectrais**”. Os trabalhos foram instalados pelo Orientador, Professor Doutor Ronaldo Martins da Costa (INF/UFG) com a participação dos demais membros da Banca Examinadora: Professor Doutor Fabrizzio Alphonsus Alves de Melo Nunes Soares (INF/UFG), membro titular interno; Professor Doutor Plínio de Sá Leitão Júnior (INF/UFG), membro titular interno; Professor Doutor Eduardo Moraes Arraut (ITA), membro titular externo; e Professor Doutor Kelton Augusto Pontara da Costa (UNESP/Bauru), membro titular externo. A participação dos professores Eduardo Moraes Arraut e Kelton Augusto Pontara da Costa ocorreu por meio de videoconferência. Durante a arguição os membros da banca não 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 Ronaldo Martins da Costa, 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 seis dias do mês de novembro de dois mil e vinte e quatro.

## TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **Kelton Augusto Pontara da Costa, Usuário Externo**, em 18/12/2024, às 16:45, 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 18/12/2024, às 18:31, 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 **Priscila Marques Kai, Discente**, em 18/12/2024, às 20:41, 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 **Plinio De Sa Leitao Junior, Professor do Magistério Superior**, em 19/12/2024, às 07:34, 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 **Fabrizzio Alphonsus Alves De Melo Nunes Soares, Professor do Magistério Superior**, em 19/12/2024, às 10:15, 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 **Eduardo Moraes Arraut, Usuário Externo**, em 19/12/2024, às 11:25, 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](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **5051218** e o código CRC **7237648B**.

Referência: Processo nº 23070.043335/2024-70

SEI nº 5051218

---

## Agradecimentos

---

Gostaria de expressar minha profunda gratidão a todos que, de alguma forma, contribuíram para a realização desta tese. Primeiramente, agradeço ao meu esposo, Willian Isao Tokura, por seu incentivo incansável para que eu continuasse meus estudos após a graduação, por transformar minha perspectiva sobre a docência e por me apoiar em todos os momentos difíceis, tanto na vida acadêmica quanto na pessoal.

Agradeço também ao meu orientador, Prof. Ronaldo, por sua orientação paciente, seu conhecimento, por todo o suporte e incentivo ao longo do desenvolvimento desta pesquisa, essenciais para a conclusão deste trabalho. Estendo minha gratidão à Prof. Bruna, por ter me proporcionado a oportunidade de explorar este tema e por fornecer informações cruciais que foram fundamentais para o desenvolvimento desta tese.

Minha gratidão se estende ao Instituto de Informática, pela infraestrutura e recursos necessários para a execução desta pesquisa, e à CAPES, pelo apoio financeiro que possibilitou minha dedicação integral a este projeto.

Agradeço, de coração, à minha família e aos meus amigos, cujo apoio e encorajamento constantes foram vitais para que eu superasse os desafios e concluísse esta etapa da minha vida acadêmica.

Por fim, queria incluir o ser de quatro patas mais doce que já encontrei na vida, Melzinha, por ser esse animalzinho perfeito e carinhoso.

A tarefa não é tanto ver aquilo que ninguém viu, mas pensar o que ninguém ainda pensou sobre aquilo que todo mundo vê.

**Arthur Schopenhauer,**  
*1981.*

---

## Resumo

---

Marques Kai, Priscila. **Deep Learning Aplicado à classificação em Nível de Pixel de Variedades de Culturas por Imagens Multiespectrais**. Goiânia, 2024. 103p. Tese de Doutorado. Programa de Pós-Graduação em Ciência da Computação, Instituto de Informática, Universidade Federal de Goiás (UFG).

A classificação de diferentes variedades ainda enfrenta desafios significativos devido à semelhança nas características espectrais dos cultivos. Para abordar esse problema, a integração de técnicas de sensoriamento remoto com métodos de aprendizado profundo oferece uma solução promissora, analisando dados de pixels com base em bandas espectrais, combinações de bandas e índices de vegetação. Neste trabalho, desenvolvemos uma metodologia de rede neural profunda cruzada, denominada DCN-S, com estudo de caso voltado para a classificação de variedades de cana-de-açúcar. A metodologia foi aplicada em dados de sensoriamento remoto de áreas de cultivo no estado de Goiás, coletados entre 2019 e 2021. O modelo DCN-S foi comparado com classificadores tradicionais, como kNN, SVM e Floresta Aleatória, além de outras configurações de redes neurais. Os resultados indicaram que o modelo DCN-S obteve uma acurácia competitiva em cenários de validação, incluindo a consideração de variedade temporal, quando comparado a outras investigações presentes na literatura. Além disso, o modelo se destacou na classificação de variedades sem a necessidade de separação das fases de desenvolvimento, superando os métodos tradicionais, com melhoria na performance do modelo após a aplicação de um processo de votação. Finalmente, as principais contribuições deste trabalho incluem o desenvolvimento de uma abordagem para a classificação de variedades agrícolas, combinando aprendizado profundo com dados de sensoriamento remoto, e a validação dessa metodologia em um cenário prático. Os resultados evidenciam o potencial do modelo DCN-S em superar técnicas tradicionais, oferecendo uma ferramenta para o monitoramento agrícola de forma automatizada.

### Palavras-chave

Cana-de-açúcar, Classificação, Aprendizado Profundo.

---

## Abstract

---

Marques Kai, Priscila. **Deep Learning Applied to Pixel-Level classification of Crop Varieties by Multispectral Images**. Goiânia, 2024. 103p. PhD. Thesis. Programa de Pós-Graduação em Ciência da Computação, Instituto de Informática, Universidade Federal de Goiás (UFG).

The classification of different crop varieties still faces significant challenges due to their similar spectral characteristics. To address this issue, the integration of remote sensing techniques with deep learning methods offers a promising solution by analyzing pixel-level data based on spectral bands, band combinations, and vegetation indices. In this study, we developed a cross-deep neural network methodology, referred to as DCN-S, with a case study focused on the classification of sugarcane varieties. The methodology was applied to remote sensing data from cultivation areas in the state of Goiás, Brazil, collected between 2019 and 2021. The DCN-S model was compared with traditional classifiers, such as k-Nearest Neighbors (kNN), Support Vector Machines (SVM), and Random Forest, as well as other neural network configurations. The results indicated that the DCN-S model achieved competitive accuracy in validation scenarios, including temporal variety considerations when compared to other studies in the literature. Moreover, the model excelled in classifying varieties without requiring the separation of developmental stages, surpassing traditional methods. Performance improvements were further observed after applying a voting process. Finally, this work's main contributions include developing an approach for classifying agricultural varieties by combining deep learning with remote sensing data and validating this methodology in a practical scenario. The results highlight the potential of the DCN-S model to outperform traditional techniques, offering a tool for automated agricultural monitoring.

### Keywords

Sugarcane, Classification, Deep Learning.

---

# Sumário

---

Lista de Figuras	12
Lista de Tabelas	14
<b>1</b> Introdução	<b>16</b>
1.1 Descrição do Problema	16
1.2 Objetivos	18
1.2.1 Objetivos Específicos	19
1.3 Contribuições	19
1.3.1 Publicações	19
1.4 Organização do texto	20
<b>2</b> Referencial Teórico	<b>21</b>
2.1 Variedades de cana-de-açúcar	21
2.1.1 Estágios Fenológicos da cana-de-açúcar	22
2.2 Sensoriamento aplicado ao monitoramento da cana-de-açúcar	23
2.2.1 Sensoriamento Remoto	23
2.2.2 Sensores de Satélite	25
2.2.3 Pré-Processamento em Produtos de Sensoriamento Remoto	28
Índices de Vegetação	30
2.3 Modelos de Classificação	31
2.3.1 Cana-de-açúcar	33
k-Vizinhos mais Próximos	33
Máquina de Vetor de Suporte	34
Floresta Aleatória	34
Redes Neurais Artificiais	35
Rede Profunda e Cruzada	39
2.4 Avaliação de Desempenho do Modelo	40
2.5 Ajuste de Hiperparâmetros	41
2.5.1 Otimização Bayesiana	41
2.6 Métricas de desempenho	42
2.6.1 Considerações Finais	43
<b>3</b> Revisão da Literatura	<b>45</b>
3.1 Revisão da Literatura na Classificação de Variedades	45
3.2 Metodologia para a classificação de variedades de cultura por imagens de satélite	47
3.2.1 Aquisição	47
Instrumento Sensores na Classificação de Variedades Agrícolas	48
3.2.2 Extração de Características	48

3.2.3	Bandas	49
	Índices de Vegetação	50
3.2.4	Modelos para Classificação	51
3.2.5	Comparação de Métodos na Classificação de Variedades de Cana-de-açúcar	53
	Quantidade de Entradas na Análise de Variedades de Cana-de-Açúcar	54
3.2.6	Considerações Finais	55
<b>4</b>	<b>Método para Classificação de Variedades de Cana-de-açúcar</b>	<b>57</b>
4.1	Método Proposto	57
4.1.1	Arquitetura da Rede Neural Profunda	57
4.1.2	Arquitetura da Rede Neural Cruzada profunda	59
<b>5</b>	<b>Estudo de Caso – Design de Experimento</b>	<b>62</b>
5.1	Materiais e Métodos	62
5.1.1	Variedades de Cana-de-açúcar	62
5.1.2	Imagens	64
5.1.3	Seleção de Datas	65
5.1.4	Extração de Características	67
5.1.5	Base de dados	69
5.1.6	Ajuste de Hiperparâmetros	70
<b>6</b>	<b>Resultados</b>	<b>72</b>
6.1	Efeitos da Reamostragem na Classificação de Variedades de Cana de Açúcar	73
6.1.1	Preparação da Base de Dados	73
6.1.2	Resultados do Estudo	74
6.2	Aprendizado Profundo Aplicado na Classificação de Variedades de Cana-de-açúcar	76
6.2.1	Ajuste de Hiperparâmetros	78
6.2.2	Resultados do Estudo	79
6.2.3	Rede Neural Resultante	79
6.2.4	Redes Neurais e Modelos Clássicos de Aprendizado de Máquina	81
6.3	Rede Cruzada Profunda na Diferenciação de Variedades de Cana-de-Açúcar	83
6.3.1	Classificação com Separação de Datas por Local	84
6.3.2	Análise por variedade de cana-de-açúcar	88
6.3.3	Classificação sem Separação de Datas por Local	89
<b>7</b>	<b>Conclusão</b>	<b>92</b>
7.0.1	Trabalhos futuros	93
	<b>Referências Bibliográficas</b>	<b>94</b>

---

## Lista de Figuras

---

1.1	Diferentes variedades de cana-de-açúcar. Fonte: Embrapa e foto por Raffaella Rossetto [EMBRAPA 2024].	17
2.1	Estágios fenológicos da cana-de-açúcar. Fonte: GASCHO,1983.	22
2.2	Representação do espectro eletromagnético, destacando regiões de interesse no sensoriamento remoto, como o espectro visível, sensível ao olho humano e amplamente utilizado por sensores ópticos para diversas análises. À direita, destaca-se a região do infravermelho, com comprimentos de onda maiores, empregada em aplicações como monitoramento ambiental e estudos de vegetação.	24
2.3	Características de uma imagem digital.	26
2.4	Eventos resultantes da interação de diferentes comprimentos de onda com a matéria, incluindo fenômenos como absorção, reflexão, refração, dispersão e transmissão, de acordo com as propriedades materiais e espectrais.	26
2.5	Imagens do Sentinel-2 sobre a cidade de Goiânia, com diferentes porcentagens de cobertura de nuvens, disponíveis na plataforma Sentinel Playground.	29
	(a) 02/04/2023	29
	(b) 01/01/2023	29
	(c) 07/01/2023	29
	(d) 07/05/2023	29
2.6	Métodos de amostragem pelo vizinho mais próximo, por interpolação bilinear e interpolação de convolução cúbica.	30
2.7	(a) Imagem do Sentinel-2 produto 2A sobre a região que engloba a UFG. (b) Imagem gerada pelo cálculo do NDVI.	31
2.8	Imagens de um local contendo a variedade RB867515 em crescimento, na região de Serranópolis e o cálculo obtido da média do NDVI para cada data.	32
	(b) 01/01/19 NDVI:0.19	32
	(c) 05/02/19 NDVI:0.71	32
	(d) 17/03/19 NDVI:0.38	32
	(e) 11/04/19 NDVI:0.05	32
	(f) 06/05/19 NDVI:0.77	32
	(g) 10/06/19 NDVI:0.64	32
2.9	Estrutura básica de rede neural com um único neurônio.	36
2.10	Estrutura de um Perceptron multicamadas (MLP).	37
3.1	Quantidade de artigos resultantes da busca por base de dados segundo a string de busca.	46

4.1	Metodologia desenvolvida com o propósito de classificar variedades de cana-de-açúcar.	58
4.2	Modelo de rede neural cruzada alimentado apenas por um conjunto de características com concatenação das saídas da rede cruzada e da rede densa.	60
5.1	Bandas do sensor do Sentinel-2 produto 2A traduzida em diferentes imagens.	65
5.2	Gráfico de caixas contendo a distribuição dos valores de reflectância das sete variedades de cana-de-açúcar em diferentes bandas espectrais do Sentinel-2.	70
6.1	Metodologia para discriminação entre pixels de três variedades de cana-de-açúcar por uso de seis índices de vegetação relacionados à análise de clorofila.	75
6.2	Acurácia por número de camadas.	80
6.3	Arquiteturas de rede cruzada profunda com quantidade diferente de entradas a cada camada de concatenação.	85
6.4	Comparação da acurácia observada entre os modelos testados na classificação de variedades de cana-de-açúcar sem votação e com inclusão.	88
6.5	Classificação binária por variedade por uso do modelo DCN-S	89

---

## Lista de Tabelas

---

2.1	Exemplo ilustrativo de amostras de cana de açúcar e não-cana-de-açúcar contendo como características o NDVI e o valor de brilho da banda do vermelho.	39
2.2	Características de segunda ordem adquirida a partir dos dados originais da Tabela 2.1 com amostras ilustrativas de cana de açúcar e não-cana-de-açúcar contendo como características o NDVI e o valor de brilho da banda do vermelho.	40
3.1	Tabela contendo informações sobre estudos importados de diferentes bases de dados, considerando as fontes IEEEExplore, ScienceDirect e Scopus, com foco em estudos publicados no período de 2019 a 2024.	47
3.2	Índices de vegetação (IVs) mais encontrados em estudos para destacar diferenças entre variedades de culturas entre os estudos dos últimos cinco anos.	50
3.3	Índices de vegetação mais comumente utilizados para classificar variedades de culturas de acordo com os estudos encontrados na literatura.	51
3.4	Modelos classificatórios, tipo de dado, planta estudada e acurácia na diferenciação de variedades de culturas.	52
3.5	Estudos de Discriminação de Variedades de Cana-de-Açúcar Utilizando Sensores Espectrais	55
5.1	Informações de variedades de cana-de-açúcar utilizadas no estudo e o ciclo de colheita no estado de Goiás.	63
5.2	Locais selecionados para coleta de dados.	63
5.3	Bandas do Sentinel-2	64
5.4	Quantidade de dias selecionados para cada variedade a partir do cálculo do NDVI.	66
5.5	Tabela de dados das variedades investigadas, incluindo a localidade, quantidade de pixels adquiridos por local e métricas relacionadas ao Índice de Diferença Normalizada (NDVI) como a média (M) dos valores dos pixels e desvio padrão (DP).	67
5.6	Características de cada amostra pertencente à base de dados do estudo.	68
5.7	Índices de vegetação foram utilizados nos estudos para destacar as diferenças entre as variedades de cana-de-açúcar.	69
5.8	Parâmetros dos Classificadores Testados	71
6.1	Datas obtidas para o estudo de acordo com a variedade, dia, sigla e localidade	73

6.2	Discriminação de cana-de-açúcar por pixel por diferentes métodos de reamostragem.	75
6.3	Discriminação de cana-de-açúcar pela média dos valores de pixel por diferentes métodos de reamostragem.	76
6.4	Datas de coleta das imagens para os experimentos.	77
6.5	Modelos avaliados no estudo e parâmetros testados.	78
6.6	Avaliação dos modelos de rede neural para diferentes números de neurônios nas camadas ocultas a partir do conjunto de dados de treinamento.	81
6.7	Resultados de classificadores com diferentes parâmetros para quatro variedades de cana-de-açúcar.	82
6.8	Resultados de classificadores com diferentes parâmetros para sete variedades de cana-de-açúcar.	86
6.9	Resultados de classificadores com processo de votação com diferentes parâmetros para sete variedades de cana-de-açúcar.	87
6.10	Métricas e parâmetros de modelos por uso de base de dados sem separação de datas para treino e teste.	90

---

## Introdução

---

Este capítulo dedica-se a detalhar a problemática investigada no âmbito desta tese de doutorado, os objetivos da pesquisa, as contribuições alcançadas e a estrutura do texto.

### 1.1 Descrição do Problema

A cultura da cana-de-açúcar (*Saccharum officinarum*) é caracterizada como semi-perene [Rossetto e D. 2022], com plantio ocupando uma área por cerca de cinco anos, com custos relacionados à implementação variando conforme a localidade e a produtividade almejada. A cana-de-açúcar possui significativa relevância econômica para o Brasil, que lidera como o maior produtor mundial de açúcar. Além de fornecer diversas formas de agroenergia, impulsiona setores estratégicos da economia nacional. No cenário nacional, o estado de São Paulo destaca-se como o principal produtor de cana-de-açúcar, seguido por Goiás, Minas Gerais e Mato Grosso do Sul, consolidando essas regiões como polos fundamentais dessa cadeia produtiva [Conab 2024].

Destacando-se como um insumo essencial para a produção de açúcar, etanol e geração de energia elétrica, a cana-de-açúcar desempenha um papel crucial tanto no desenvolvimento sustentável quanto na geração de emprego e renda. Ainda, sua contribuição como fonte de energia limpa reafirma sua importância no contexto energético.

Segundo a Conab (Companhia Nacional de Abastecimento) [Conab 2023], para a safra 2023/2024, investimentos no setor sucroalcooleiro brasileiro resultaram no aumento da produção de cana-de-açúcar, no qual a região Centro-Oeste, a segunda maior produtora do país, possui uma estimativa de produção superior a 143 milhões de toneladas.

Dada a relevância da planta, instituições de pesquisa voltadas ao melhoramento genético da cana-de-açúcar desenvolvem novas variedades visando o aumento do rendimento do setor canavieiro, financiadas por usinas, fornecedores de cana e destilarias [Barbosa 2021]. Dessa forma, melhoristas de plantas podem adquirir direitos sobre essas novas variedades desenvolvidas por meio da Lei de Proteção de Cultivares (LPC), que representa uma modalidade de propriedade intelectual que garante a detenção de direitos

sobre os cultivares, visando estimular o desenvolvimento de novas variedades e fomentar a pesquisa [BRASIL 1997].

Com a grande diversidade de variedades no mercado, como observado na Figura 1.1, encontram-se plantas com vários tipos de perfis, desde aspectos gerais, produtividade agrícola, tempo de crescimento, recomendações de manejo e outras características específicas de cada variante [Barbosa 2021]. Entre os elementos que influenciam o rendimento e a durabilidade da planta, podem ser incluídos a escolha da área de plantio, práticas de manejo do solo e da planta, escolha da variedade, condições climáticas, medidas fitossanitárias e técnicas de colheita [SILVA et al. 2017]. Dessa forma, conforme a necessidade de cada produtor, as variedades podem ser selecionadas considerando uma combinação de diferentes características, visando uma alta produtividade.

**Figura 1.1:** *Diferentes variedades de cana-de-açúcar. Fonte: Embrapa e foto por Raffaella Rossetto [EMBRAPA 2024].*



Para monitorar as plantações de cana-de-açúcar localizadas em diversos locais ao redor do globo, vários estudos têm sido desenvolvidos com a aplicação de técnicas de sensoriamento remoto em conjunto com técnicas de aprendizado de máquina. Essas técnicas são utilizadas para investigar a incidência de doenças em crescimento [Apan et al. 2004], analisar a aplicação de nutrientes [Everingham et al. 2007, Liang et al. 2021], avaliar variáveis bioquímicas [Sharma 2020], como também para diferenciar entre diferentes variedades [Tisot 2005, Demattê 2006]. Essas abordagens visam a observação remota associada à coleta de informações, proporcionando a redução do deslocamento físico até a localidade com plantas em desenvolvimento, o que, conseqüentemente, reduz os custos de deslocamento até os talhões<sup>1</sup> em crescimento. Dessa forma, é possível adquirir dados durante vários dias de uma localidade, de acordo com o produto escolhido, utilizando opções de imagens com acesso gratuito, como os dados de sensores provenientes de produtos como

<sup>1</sup>Correspondem às divisões de áreas em um terreno de acordo com a topografia, tipo de colheita e homogeneidade do solo [Rossetto e D. 2022].

o CBERS, Sentinel-2, Landsat-7, Landsat-8, MODIS, entre outros, mediante registro na plataforma.

Após a aquisição, as imagens são compostas por várias bandas de diferentes comprimentos de onda, dependendo do sensor utilizado nos experimentos de sensoriamento remoto. Diferentemente dos dados obtidos em ambientes controlados, os dados dos sensores de satélite exigem atenção devido a elementos adversos como nuvens ou sombras sobre áreas de interesse, requerendo processamento de imagem para análise posterior. Selecionar imagens adquiridas em dias com condições climáticas favoráveis permite construir bases de dados menos suscetíveis a ruídos.

O sensoriamento remoto oferece ainda benefícios adicionais, como a ampla cobertura espacial, que permite monitorar eficientemente vastas áreas em curtos períodos. Além disso, possibilita a coleta de informações em regiões de difícil acesso e o uso de dados multiespectrais e hiperspectrais, ampliando a resolução espectral para comprimentos de onda além da luz visível e fornecendo informações ambientais valiosas. O sensoriamento remoto também permite a aquisição de dados de alvos sem contato físico, utilizando a interação única de cada alvo com a radiação eletromagnética em diferentes comprimentos de onda [Campbell e Wynne 2011]. Isso facilita a coleta de dados de plantações e outras características a longas distâncias, inclusive em diferentes países.

No entanto, a classificação das variedades da cultura da cana-de-açúcar continua a ser um campo em desenvolvimento e exploração, oferecendo espaço significativo para experimentação e desenvolvimento de metodologias que combinem sensoriamento remoto com aprendizado de máquina, como o uso de redes neurais profundas. Embora essas redes estejam cada vez mais presentes em pesquisas recentes sobre a classificação de variedades de diversas culturas, ainda há um potencial considerável a ser explorado, destacando a importância desses modelos computacionais na diferenciação de culturas e suas variedades.

Por esta razão, este documento visa apresentar uma metodologia para classificar diferentes variedades de cana-de-açúcar utilizando redes neurais profundas concatenadas. Ele incluirá uma comparação entre os métodos tradicionalmente empregados para essa tarefa, utilizando imagens do Sentinel-2, nível 2A, selecionadas no período de 2019 a 2021.

## 1.2 Objetivos

O objetivo do trabalho é apresentar uma metodologia aplicada ao sensoriamento remoto para classificar variedades de culturas através do uso de características extraídas dos pixels de imagens representantes às bandas do sensor Sentinel-2, produto 2A, com estudo de caso aplicado à separação de variedades de cana-de-açúcar de locais no estado de Goiás.

### 1.2.1 Objetivos Específicos

Entre os objetivos específicos, incluem-se a avaliação estatística de métodos de classificação aplicados às variedades de cultura, como o K-Vizinhos mais Próximos (KNN), Máquinas Vetores de Suporte, Florestas Aleatórias e arquiteturas de Redes Neurais Artificiais, com desenvolvimento de uma metodologia para classificar diferentes variedades de uma mesma cultura, utilizando como estudo de caso a cana-de-açúcar através de produtos de sensoriamento remoto.

Além disso, os resultados derivados da pesquisa serão incluídos posteriormente em uma plataforma digital visando a disponibilização dos modelos desenvolvidos à outros pesquisadores para a análise de culturas por meio de dados de sensoriamento remoto.

## 1.3 Contribuições

Para as contribuições deste trabalho podemos incluir:

1. Desenvolver um novo método para a diferenciação de variedades de culturas, oferecendo métodos auxiliares para classificar plantas por meio da aplicação de arquiteturas de redes neurais artificiais, realizando a análise por uso de valores dos pixels;
2. Disponibilização dos modelos classificatórios desenvolvidos na pesquisa para posterior uso em uma plataforma web focada na análise de plantas, com estudo de caso inicialmente aplicado à cana-de-açúcar.

### 1.3.1 Publicações

Durante o desenvolvimento da pesquisa voltada à classificação de variedades de cana-de-açúcar foram disponibilizados em anais de eventos internacionais dois artigos:

- Discrimination of Sugarcane Varieties by Remote Sensing: A Review of Literature. Em: 2020 IEEE 44th Annual Computers, Software, and Applications Conference (COMPSAC).
- Effects of resampling image methods in sugarcane classification and the potential use of vegetation indices related to chlorophyll. Em: 2021 IEEE 45th Annual Computers, Software, and Applications Conference (COMPSAC).

E um artigo em periódicos especializado com Qualis A2:

- Deep Learning-Based Method for Classification of Sugarcane Varieties. *Agronomy* 2022, 12, 2722. <https://doi.org/10.3390/agronomy12112722>.

## 1.4 Organização do texto

Após a introdução abordada neste capítulo contendo a motivação do estudo que impulsionou a realização da pesquisa, a tese foi estruturada da seguinte maneira:

- Capítulo 2: O capítulo dois traz o referencial teórico necessário para o desenvolvimento da tese, fornecendo um alicerce para a proposta neste trabalho.
- Capítulo 3: Neste capítulo é apresentada a revisão da literatura, com inclusão das técnicas tradicionalmente utilizadas na classificação de variedades de culturas a fim de identificar lacunas no conhecimento existente.
- Capítulo 4: O quarto capítulo detalha a metodologia desenvolvida para a classificação de imagens de cana-de-açúcar por meio de redes neurais profundas concatenadas, desde a seleção e preparação dos dados até a implementação dos modelos de redes neurais, destacando os ajustes e escolhas metodológicas.
- Capítulo 5: No quinto capítulo explora os materiais e processos empregados no desenvolvimento da metodologia para a classificação de variedades de cana-de-açúcar por meio do uso, integrando técnicas de aprendizado de máquina e sensoriamento remoto.
- Capítulo 6: No sexto capítulo apresentamos os resultados de experimentos realizados com a metodologia proposta, comparando desempenhos, identificando pontos fortes e limitações, e discutindo as implicações dos achados para o campo de estudo.
- Capítulo 7: Finalmente, serão apresentadas as conclusões derivadas dos resultados alcançados e possibilidades de pesquisas futuras baseadas no resultado do estudo.

---

## Referencial Teórico

---

Esta seção tem por objetivo apresentar o referencial teórico sobre o estudo de variedades de culturas utilizando dados derivados de sensoriamento remoto, em especial à dados de sensores de satélite, apontando as técnicas e metodologias usadas na análise de variedades utilizadas como base para a criação da metodologia para classificar variedades de cana-de-açúcar.

### 2.1 Variedades de cana-de-açúcar

De maneira a assegurar a lucratividade na indústria sucroalcooleira, o aprimoramento genético compreende em um dos principais aspectos agronômicos capazes de impulsionar a produtividade da cultura de cana-de-açúcar, permitindo a criação de variedades mais adequadas. Desde 1990, a RIDESA (Rede Interuniversitária para o Desenvolvimento do Setor Sucroenergético), composta por Universidades Federais tem desempenhado um papel fundamental no progresso da indústria sucroenergética brasileira na obtenção das variedades de cana-de-açúcar da linhagem RB, correspondendo em mais da metade da área cultivada da cultura no país [Barbosa 2021].

Ao longo do tempo tem-se observado um aumento na produtividade média dos canaviais, crescimento atribuído ao uso de variedades geneticamente melhoradas. Desta forma, processos que visam a maximizar a produtividade na cultura necessitam de planejamento cuidadoso do plantio, além de um manejo adequado das variedades [Marin]. Assim, a escolha de variedades adequadas consideram diversos fatores, incluindo adaptação às condições de solo e clima da região, teor de açúcar (sacarose), resistência a pragas e doenças, e também ciclo de crescimento, em função de diferentes variedades possuem ciclos distintos de maturação com colheita em períodos diferentes [SILVA et al. 2016].

Para o plantio, recomenda-se variedades com ciclos diferenciados, de crescimento precoce e médio a tardio, permitindo a obtenção de cana-de-açúcar de qualidade por toda temporada de colheita [SILVA et al. 2017]. Ademais, as particularidades de cada variedade de cana-de-açúcar para com as fases de desenvolvimento da planta podem oscilar em função do ambiente e do genótipo (variedade de cana), afetando a duração dos estádios de

acordo com a fertilidade do solo, densidade de plantio, temperatura, assim como outros fatores [Marafon 2012].

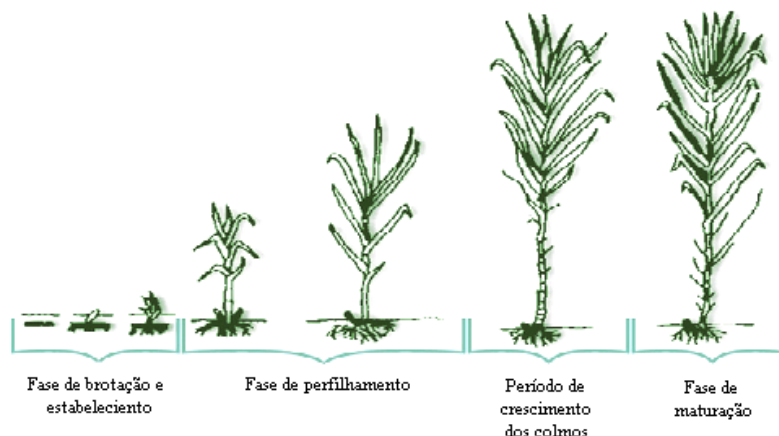
Entre as principais variedades de cana-de-açúcar plantadas no país de acordo com o Censo varietal IAC de cana-de-açúcar no Brasil - safra 2021/22 [Junior et al. 2023], no estado de Goiás, a variedade RB867515 foi a mais cultivada considerando as principais variedades de unidades produtoras no estado. Além dela, destacam-se as variedades CTC4, RB966928 e RB975242.

### 2.1.1 Estágios Fenológicos da cana-de-açúcar

Os estágios fenológicos de uma planta compreendem em mudanças relatadas a uma cultura, com distintas etapas divididas em períodos de tempo com transformações externas da planta, analisando como uma cultura se desenvolve.

De acordo com Gascho e Shih [Shih 1983], a cana-de-açúcar possui um desenvolvimento definido em quatro estágios, iniciando pela brotação e estabelecimento (emergência), perfilhamento, crescimento (fase com começo do acúmulo de açúcar nos colmos), finalizando com a fase de maturação (Figura 2.1).

**Figura 2.1:** Estágios fenológicos da cana-de-açúcar. Fonte: GAS-CHO, 1983.



Após o plantio da cana-de-açúcar, a duração do ciclo da cultura dependerá da variedade selecionada, processo que poderá estender-se por um período de 12 à 18 meses, conhecido como ciclo de cana-planta. Na primeira fase, ocorre o rompimento da gema e o surgimento de raízes, resultando no broto e no aparecimento de folhas durante o primeiro mês após o plantio. Em seguida, na fase de perfilhamento, há o crescimento dos brotos e a emergência dos colmos.

Com a cobertura do solo pela folhagem da cana-de-açúcar, inicia-se a fase de crescimento, caracterizada pelo acúmulo de açúcar na base e pelo aumento da altura das plantas. Nesse estágio, observa-se um tom verde mais intenso na superfície, influenciado

pela absorção de luz e água necessárias para o desenvolvimento, o que contribui, por exemplo, na análise da clorofila das folhas.

Na fase de maturação, ocorre o crescimento acentuado dos colmos e a coloração das folhas torna-se cada vez mais amarelada, juntamente com a intensa concentração de açúcar em cada colmo. É importante destacar que cada variedade possui características diferentes em relação ao tempo de crescimento, duração de cada fase e período adequado para plantio e colheita.

Para a aquisição de dados de plantações é preferível datas de áreas com dossel fechado (cobertura superior), onde as informações extraídas das variedades adquiridas serão consideradas adequadas devido à pouca influência de solo exposto. Assim, dados de variedades são considerados mais “puros” com fechamento completo da copa [Biradar 2019], observado no estudo com variedades de milho. A fase de floração também é considerada importante na diferenciação de variedades de algumas culturas como a quinoa [Sankaran et al. 2019]. Por isso, dias que abrangem estágios fenológicos de crescimento e maturação são preferíveis uma vez que o fechamento do dossel permite obter uma leitura mais precisa de cada variedade.

## **2.2 Sensoriamento aplicado ao monitoramento da cana-de-açúcar**

A criação de novas variedades têm despertado o interesse de pesquisadores no desenvolvimento de metodologias de reconhecimento e classificação de variedades de diversas culturas, possibilitando a otimização de recursos com deslocamentos, aprimoramento de modelos para a previsão de produtividade, além de outros benefícios, permitindo avaliar plantas sem a necessariamente danificar suas partes [Demattê 2006].


Unindo o sensoriamento remoto à finalidade de identificar e classificar variedades é possível monitorar áreas plantadas e observar exemplares de variedades que melhor se adaptem às condições climáticas e de solo encontradas, revelando-se uma ferramenta muito eficaz para especialistas agrônomos, bem como para os produtores agrícolas.

### **2.2.1 Sensoriamento Remoto**

O Sensoriamento Remoto é o processo de obtenção de dados sobre objetos, fenômenos e regiões sem o contato direto com o objeto, através de dispositivos sensores responsáveis por coletar a energia emitida ou refletida da superfície terrestre, permitindo a extração de informações para uso em aplicações práticas através da análise de variações de ondas acústicas ou em distribuições de energia eletromagnética. Essa energia, resultante da liberação ou absorção por partículas carregadas, é chamada radiação eletromagnética,

possuindo características magnéticas e elétricas. A porção de comprimento de onda correspondente à radiação eletromagnética é denominada espectro eletromagnético, definido pela frequência, comprimento de onda e energia do fóton [Manickavasagan e Jayasuriya 2014], com a frequência sendo inversamente proporcional ao comprimento de onda.

Com enfoque na energia eletromagnética, a energia refletida ou emitida dos objetos de interesse pode ser expressada em diferentes colorações [Chipman 2015]. A luz visível, por exemplo, representa uma das formas de energia eletromagnética. Deste modo, o espectro eletromagnético é representado como uma faixa contínua que abrange as frequências da radiação eletromagnética, dividida em diferentes regiões espectrais, como apresentado na Figura 2.2.



**Figura 2.2:** Representação do espectro eletromagnético, destacando regiões de interesse no sensoriamento remoto, como o espectro visível, sensível ao olho humano e amplamente utilizado por sensores ópticos para diversas análises. À direita, destaca-se a região do infravermelho, com comprimentos de onda maiores, empregada em aplicações como monitoramento ambiental e estudos de vegetação.

No contexto do sensoriamento remoto, as regiões de maior interesse abrangem a faixa visível do espectro e infravermelho (infravermelho próximo, infravermelho médio e infravermelho distante) [Campbell e Wynne 2011], com cada banda espectral delimitada em um intervalo discreto do espectro eletromagnético. A interação entre a atmosfera terrestre e a radiação eletromagnética pode resultar em comportamentos distintos relacionados ao comprimento de onda na representação da imagem gerada pelo dispositivo, tornando algumas bandas espectrais mais adequadas do que outras para problemas envolvendo sensoriamento remoto. É desejável explorar bandas que contribuam para a identificação do objeto de estudo, uma vez que as características de reflectância espectral da superfície, resultantes da interação entre o objeto e a radiação, bem como as condições encontradas, influenciam as informações adquiridas.

Aliás, os comprimentos de onda também permitem que outras características das plantas sejam obtidas, como os índices de vegetação. Esses índices possibilitam a

observação de características da vegetação, como estado e sanidade da planta, estresse hídrico, doenças e parâmetros bioquímicos (absorção de clorofila, carotenoides, lignina, sensibilidade ao nitrogênio, etc.). Assim, índices de vegetação calculados em comprimentos de onda sensíveis a parâmetros bioquímicos podem destacar diferenças entre variedades de plantas [Darvishsefat, Abbasi e Schaepman 2011].

Além disso, na diferenciação entre variedades de plantas, a curva espectral de uma variedade pode ser influenciada por diversos fatores, como condições climáticas, efeitos de espalhamento, propagação de luz e parâmetros bioquímicos foliares [Mirzaei et al. 2019].


### 2.2.2 Sensores de Satélite

Um benefício do uso de dados advindos de sensores é a disponibilização por meio de formato digital, contendo pixels que traduzem a informação da região observada em diferentes comprimentos de onda, permitindo posterior processamento em máquinas. Deste modo, o valor de um pixel da imagem representa o brilho advindo da superfície observada, com valor distinto para cada componente [Richards, Richards et al. 2022].

Em produtos de sensoriamento remoto, consideram-se diferentes tipos de resolução: espacial, espectral e temporal. A resolução espacial está relacionada à capacidade de um sensor em capturar detalhes de uma área, onde cada pixel da imagem representa a menor porção de terreno registrada pelo sensor. A resolução espectral refere-se ao número de bandas que o sensor pode detectar, indicando a variedade de comprimentos de onda no espectro eletromagnético que ele consegue registrar [Bernardi et al. 2014]. No caso da resolução temporal, esta se refere ao tempo de revisita de um satélite à uma região. Cada satélite possui um intervalo de revisita, como por exemplo a missão Sentinel-2, composta por satélites gêmeos, com tempo de revisita de 10 dias (5 dias combinando ambos os satélites) [ESA 2015]. A representação das características de uma imagem digital obtida por sensores é ilustrada na Figura 2.3, na qual os pixels que compõem a imagem são expressos por valores que indicam o nível de brilho. Cada pixel pode ser associado a múltiplas informações, incluindo diferentes comprimentos de onda, com a quantidade e tipo de características extraídas podendo variar de acordo com as especificidades de cada sensor.

Ao classificarmos sensores em sensoriamento remoto, podemos separá-los em sensores passivos e ativos. Os sensores passivos capturam a energia eletromagnética refletida ou emitida pelo alvo, incluindo sensores em satélites como o Landsat 8, TERRA e Sentinel-2. Em sensores ativos, estes por sua vez geram sua própria fonte de energia eletromagnética, como por exemplo radares, sonares e LiDAR (Light Detection and Ranging) [Bernardi et al. 2014].


Considerando sistemas de sensoriamento remoto mais comumente utilizados, tem-



**Figura 2.3:** Características de uma imagem digital.

se os sistemas ópticos, baseados na refletância, absorção e dispersão, responsáveis por capturar dados do espectro visível até o infravermelho próximo e médio. A energia emitida pela Terra, predominante na faixa do infravermelho térmico, também pode ser medida em diferentes comprimentos de onda, auxiliando na análise das propriedades da superfície terrestre [Richards, Richards et al. 2022]. Assim, é possível agrupar tipos de cobertura de terra de acordo com sua resposta espectral e a partir disso analisar as informações para tarefas diversas, como distinção de variedades de cobertura terrestre.

Com base nas diferentes propriedades de imagem, é possível obtermos uma assinatura espectral de um objeto de estudo por diferentes padrões observados de acordo com as propriedades do material, como observado na Figura 2.4, baseado na energia, sendo esta variante em diferentes comprimentos de onda [Campbell e Wynne 2011].



**Figura 2.4:** Eventos resultantes da interação de diferentes comprimentos de onda com a matéria, incluindo fenômenos como absorção, reflexão, refração, dispersão e transmissão, de acordo com as propriedades materiais e espectrais.

A faixa referente ao espectro visível compreende em uma pequena região do

espectro eletromagnético com muitas aplicações práticas na resolução de problemas que envolvam o processamento digital de imagens, permitindo a coleta de informações úteis para serem utilizadas em processos posteriores, sejam em propósitos de identificação, agrupamento, classificação, entre outras finalidades, de acordo com a distribuição de cores, distribuição dos valores de pixels em níveis de cinza, análise de textura, etc.

Isto posto, temos que a cor de uma dada superfície será resultado da luz que é incidida e/ou refletida sobre ela, de acordo com as propriedades do material encontrado. Assim, a curva de reflectância espectral de uma planta pode ser influenciada por muitos fatores, como condições climáticas, propagação da luz, parâmetros bioquímicos foliares, dentre outros [Mirzaei et al. 2019]. No entanto, a diferenciação entre variedades de uma mesma cultura apenas por uso apenas desse recurso é desafiadora, dada similaridade observada pelas curvas espectrais, dificultando o processo de classificação.

Ao selecionar o produto utilizado no estudo de plantas e suas variedades, é possível adquirir imagens hiperespectrais ou multiespectrais. A principal diferença entre os dois tipos de imagem está relacionada à quantidade de bandas discretizadas pelo sensor, com alta resolução espectral em imagens hiperespectrais, oferecendo maior precisão para os comprimentos de onda, e resolução espacial superior em imagens multiespectrais, composta por bandas mais amplas e em quantidade reduzida [Feng et al. 2020].

A imagem hiperespectral distingue-se pela captura de inúmeras bandas espectrais ultrafinas, abrangendo uma ampla faixa do espectro eletromagnético, o que possibilita análises detalhadas e precisas. No entanto, devido à grande quantidade de dados gerados, essa tecnologia requer um processamento complexo, demandando conhecimento e software avançado para interpretação. Por outro lado, a imagem multiespectral caracteriza-se pela captura de um número reduzido de bandas espectrais, abrangendo faixas mais amplas do espectro eletromagnético, como a faixa do espectro visível e algumas bandas de infravermelho. Esse formato permite uma interpretação mais rápida, tornando-se uma opção mais prática, especialmente em aplicações que demandam rapidez e eficiência [Analytics 2024].

Atualmente, existem opções de bancos de dados de imagens de sensores de satélite com acesso gratuito a alguns produtos. Entre as plataformas disponíveis, podemos citar a EOS LandViewer (<https://eos.com/landviewer/>), USGS Earth Explorer (<https://earthexplorer.usgs.gov/>) e a EO Browser (<https://apps.sentinel-hub.com/eo-browser/>). Por meio dessas interfaces intuitivas, é possível adquirir imagens da superfície terrestre capturadas por sensores como Sentinel-1, Sentinel-2, Landsat-7, Landsat-8, MODIS e Hyperion, mediante cadastro na plataforma.

### 2.2.3 Pré-Processamento em Produtos de Sensoriamento Remoto

O pré-processamento de dados constitui uma etapa fundamental para corrigir, estruturar e converter os dados, tornando-os mais adequados para análises subsequentes [Szeliski 2010]. No caso de imagens capturadas por sensores de satélite, estas podem apresentar ruídos ou erros causados pelo próprio dispositivo sensor ou por interferências ambientais, resultando em diversas perturbações que podem comprometer a qualidade das informações obtidas. Assim, as medições realizadas estão sujeitas a alterações devido aos efeitos de absorção e dispersão atmosférica durante o processo de aquisição. Tais efeitos, derivados da interação entre a radiação eletromagnética, a atmosfera e a superfície terrestre, impactam diretamente o sinal detectado, fazendo com que as imagens adquiridas diferem da radiância real da superfície.

Nesse contexto, o pré-processamento visa minimizar essas distorções, garantindo a padronização e a comparabilidade dos dados obtidos em diferentes momentos [Jensen e Epiphanyo 2009]. Métodos como correções radiométrica e atmosférica são amplamente aplicados nesse estágio para ajustar os dados e mitigar os efeitos indesejados. Em algumas situações, dependendo do tipo de produto adquirido, os dados podem ser disponibilizados já com correções aplicadas.


Além disso, a fusão de imagens constitui uma técnica relevante para o aprimoramento da resolução espacial e espectral de bandas originalmente limitadas. Esse processo utiliza a banda pancromática — uma imagem em preto e branco de alta resolução espacial — para incorporar detalhes adicionais às imagens, preservando as informações originais e enriquecendo o conteúdo disponível. A fusão também pode integrar dados de diferentes sensores, ampliando a capacidade de análise e facilitando, por exemplo, a identificação e separação de culturas agrícolas, o que aumenta significativamente o potencial analítico dos dados processados.

Os métodos de pré-processamento de imagens abrangem tanto o aprimoramento da qualidade visual, por meio de transformações no brilho dos pixels, quanto a restauração de imagens, utilizando técnicas que corrigem distorções e removem artefatos indesejados. Essas etapas são fundamentais para garantir a precisão e a confiabilidade das análises subsequentes. Nesse contexto, uma imagem é considerada ortorretificada quando as distorções geométricas são corrigidas, ajustando a posição dos pixels para alinhar a perspectiva da imagem com a realidade geográfica.

Após o pré-processamento e a ortorretificação, a etapa seguinte envolve a definição das áreas de estudo. Isso é realizado através do recorte da área de interesse na imagem processada, delimitando-a com pontos que formam um polígono conhecido como ROI (Região de Interesse). Para a seleção da ROI, podem ser utilizadas abordagens como a seleção manual [Demattê 2006] com traçado de polígonos a partir de coordenadas, uso de mapas de referência [Shao et al. 2001] sobre o relevo da região, métodos de segmentação

por agrupamento [Hoekman, Vissers e Tran 2010] e classificação de terras por técnicas clássicas de sensoriamento remoto, seja através da análise espectral [Huang et al. 2006, Huang et al. 2010] ou do uso de índices de vegetação [Youngentob et al. 2011]. Além disso, arquivos específicos, como shapefiles, arquivos KML do Google Earth e coordenadas capturadas por GPS portátil, podem ser usados para mascarar uma região, mantendo as informações geográficas.

Uma vez que o processo de seleção da ROI seja realizado, é preciso atentar-se a elementos que possam influenciar negativamente a análise de variedades de culturas, como a escolha de dias com ocorrência de nuvens e sombras. A Figura 2.5, por exemplo, ilustra a ocorrência de nuvens sobre a região metropolitana de Goiânia entre os meses de janeiro à maio de 2023, da maior para menor ocorrência de nuvens.

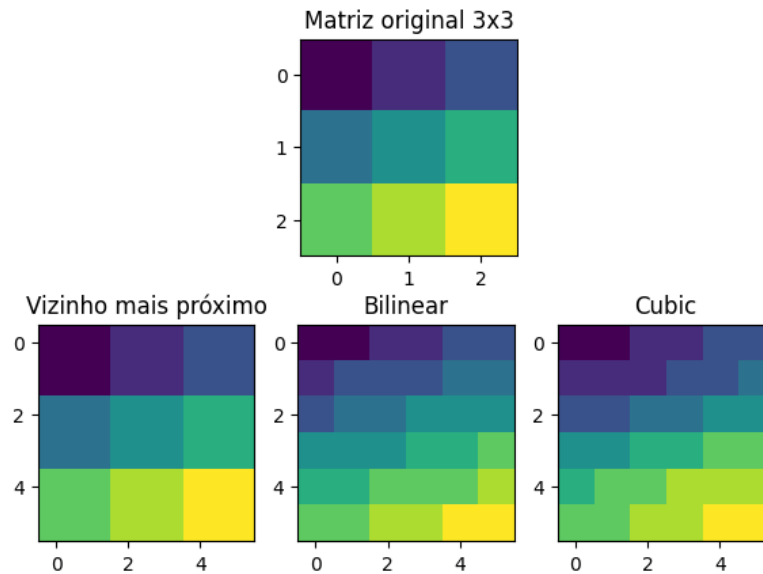


**Figura 2.5:** *Imagens do Sentinel-2 sobre a cidade de Goiânia, com diferentes porcentagens de cobertura de nuvens, disponíveis na plataforma Sentinel Playground.*

Em situações com alta porcentagem de nuvens em imagens, os dados sobre culturas são diretamente afetados, necessitando de processamento adicional para reduzir os elementos prejudiciais à análise ou optar por dias com condições climáticas favoráveis. A exclusão de datas com períodos pós-colheita, brotação e emergência, também se apresentam essenciais, uma vez que prejudicam a coleta de informações sobre variedades de culturas devido à reflectância gerado pelo fundo do solo [Chen et al. 2019].

Em produtos de sensoriamento remoto, imagens derivadas de diferentes comprimentos de onda podem possuir resolução espacial distinta. Desta forma, essa inadequação de resolução impede que a extração de algumas características seja realizada, exigindo distribuição de linhas e colunas da imagem igualitárias para todas as imagens relacionadas a um local. Para adequar o tamanho, o processo de reamostragem pode ser aplicado. Na reamostragem, essa disparidade pode ser resolvida ajustando-se as dimensões dos pixels, o que permite a extração de informações adicionais dos dados, como o cálculo de índices de vegetação. Para esse propósito, existem diversos métodos de reamostragem de imagens, como o método do vizinho mais próximo, bilinear e convolução cúbica (Figura 2.6), entre outros.

De acordo com as características dos três métodos mais comuns, a reamostragem por vizinho mais próximo consiste em atribuir o valor de um pixel com base no pixel mais próximo na imagem original. Esta abordagem preserva os dados originais, mas pode



**Figura 2.6:** Métodos de amostragem pelo vizinho mais próximo, por interpolação bilinear e interpolação de convolução cúbica.

resultar em duplicação de valores, perda de informações e erros de posicionamento, além de produzir uma imagem visualmente mais pixelizada. Além da simplicidade, este método é computacionalmente mais rápido em comparação com outros.

Na reamostragem bilinear, os quatro pixels mais próximos são usados para calcular o novo valor do pixel por meio de interpolação. A média ponderada dos quatro pixels mais próximos é calculada para cada novo valor de pixel, resultando em valores suavizados.

A reamostragem cúbica, por sua vez, utiliza os dezesseis pixels mais próximos da imagem original para calcular o novo valor do pixel na imagem reamostrada. A média ponderada desses pixels é utilizada para determinar o novo valor, resultando em imagens mais suavizadas. Embora este método exija mais tempo de processamento do que o método do vizinho mais próximo, ele tende a produzir resultados visualmente superiores devido ao uso de mais pontos de referência.

## Índices de Vegetação

Os índices de vegetação são métricas derivadas de valores de brilho, obtidas por meio de transformações lineares aplicadas às bandas espectrais. Essas transformações geram medidas que quantificam características como o vigor da vegetação, entre outros atributos. Esses índices são formados pela combinação de valores espectrais utilizando operações matemáticas, como soma, subtração, divisão e multiplicação [Campbell e Wynne 2011]. Assim, o cálculo de índices de vegetação possibilita a extração de características específicas de alvos, oferecendo uma representação quantitativa de atributos relevantes para análises ambientais e agrícolas.

Na Figura 2.7 temos o exemplo da aplicação do índice de vegetação de diferença normalizada (NDVI), que permite que a reflectância obtida da vegetação através de um equipamento sensor indique a presença de vegetação, assim como informação do estado de plantas, comparando a quantidade de luz vermelha absorvida e infravermelha refletida, resultando em maior absorção por parte da luz vermelha e conseqüentemente maior reflexão da luz infravermelha, significando grande atividade fotossintética, como também vegetação densa [Analytics 2023].

**Figura 2.7:** (a) Imagem do Sentinel-2 produto 2A sobre a região que engloba a UFG. (b) Imagem gerada pelo cálculo do NDVI.



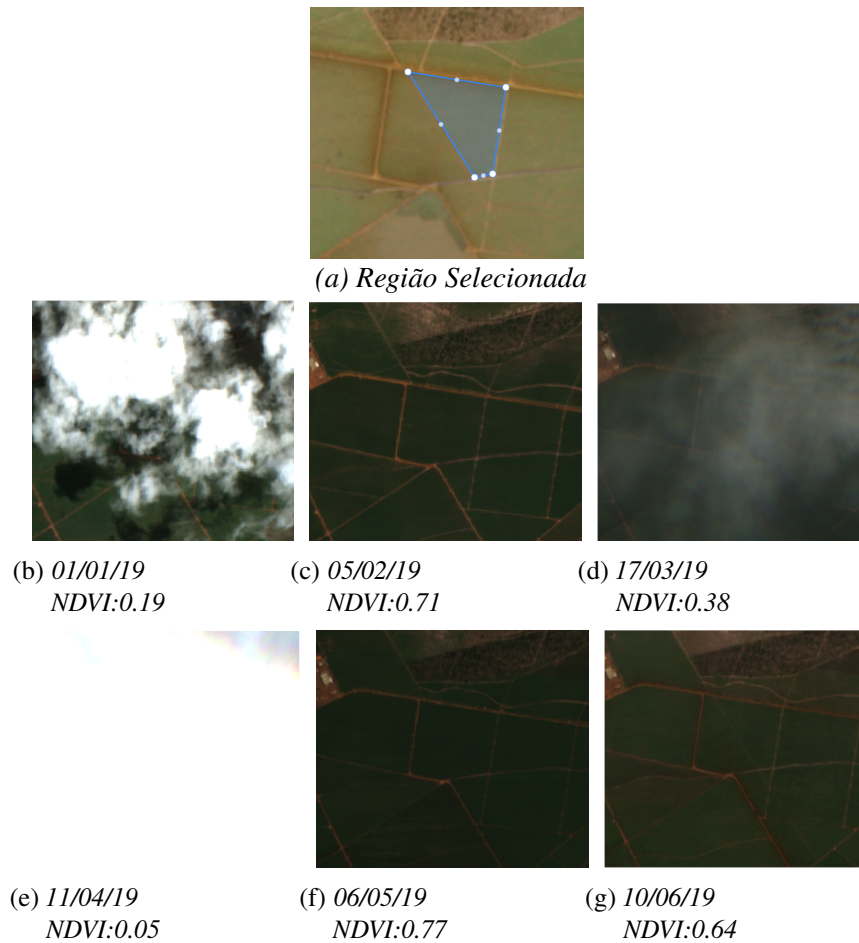
Além de detecção de vegetação, pode-se utilizar o índice para analisar a cobertura vegetal para distinção então outros tipos de cobertura. Assim, é possível também selecionar datas com menor influência de reflectância do solo, excluindo dias com grande presença de nuvens ou locais em período pós-colheita, assim como plantas em estágio de brotação devido à grande porção de solo exposto [Chen et al. 2019], causando valores discrepantes em relação aos convencionais observados.

Na Figura 2.8 é possível observar o valor de NDVI médio calculado de uma região contendo a variedade RB867515 em crescimento através de imagens obtidas entre os meses de janeiro à junho. O valor baixo de NDVI pode indicar ausência de vegetação, assim como ocorrência de nuvens, auxiliando no processo de seleção de dias.

Índices relatados à clorofila como o Índice Normalizado de Diferença Red-Edge (NDRE), Índice Normalizado de Diferença de Clorofila (NDCI), CI\_green, CI\_red\_edge, Índice de Clorofila da Vegetação (CVI) abordado em [Kai et al. 2021] mostraram-se como boas alternativas ao uso de índices como o NDVI em função da sensibilidade apresentada por este índice a cor de solo e saturação da vegetação.

## 2.3 Modelos de Classificação

A classificação está relacionada à compreensão da organização de um conjunto de amostras de dados para particioná-los em rótulos, também conhecidos como classes. Para



**Figura 2.8:** *Imagens de um local contendo a variedade RB867515 em crescimento, na região de Serranópolis e o cálculo obtido da média do NDVI para cada data.*

separar os dados em diferentes categorias, é necessário aplicar um modelo que estime as classes existentes no problema estudado, capaz de prever corretamente novos exemplos de amostras não utilizadas na fase de treinamento [Aggarwal et al. 2015]. Ao trabalhar com diferentes superfícies, os pixels presentes na imagem podem ser classificados utilizando informações sobre brilho, cor e textura para identificar padrões representativos de uma amostra. Assim, o uso de imagens com várias dimensões pode ser benéfico, pois mais bandas espectrais viabilizam mais dados para análise e extração.

A seleção do modelo para realizar a classificação dos dados abrange diversas opções, incluindo os classificadores clássicos de aprendizado supervisionado, tais como os k-vizinhos mais próximos (k-NN), Support Vector Machine (SVM) e Florestas Aleatórias (Random Forests - RF), além de métodos estatísticos como análise discriminante e de máxima verossimilhança (ML), técnicas de análise espectral e modelos mais contemporâneos como Redes Neurais Profundas (DNN) e Redes Neurais Convolucionais (CNN), especialmente adequados para aplicação em imagens.

### 2.3.1 Cana-de-açúcar

Normalmente, os valores dos pixels associados a cada variedade de cana-de-açúcar são utilizados como entrada em modelos de classificação, com uma prevalência de abordagens clássicas, como o k-vizinhos mais próximos (kNN), máquinas de vetores de suporte (SVM), florestas aleatórias (Random Forests - RF) e análise discriminante. Além disso, índices de vegetação (IV) podem ser incorporados como informações adicionais de entrada, com o intuito de destacar as condições da vegetação e contribuir para o processo de diferenciação entre as variantes. Dentre os índices de vegetação mais aplicados na literatura, o Índice de Vegetação de Diferença Normalizada (NDVI) é calculado na maior parcela dos estudos [Tisot 2005, Demattê 2006, Zimba 2008, Kai et al. 2021].

Métodos clássicos, como a análise discriminante, kNN e SVM, são amplamente utilizados para identificar, discriminar e classificar variedades de culturas. No entanto, técnicas como SVM e k-NN podem apresentar problemas relacionados a outliers, podendo levar à rotulagem errônea de uma variedade.

Observa-se também que metodologias como o uso de Redes Neurais Artificiais (RNAs) ainda não foram amplamente testadas para a classificação de variedades, apresentando, portanto, um potencial significativo para pesquisas futuras [Kai, Oliveira e Costa 2022].

#### k-Vizinhos mais Próximos

A classificação pelos k-vizinhos mais próximos (k-Nearest Neighbour) presente em [Ferreiro-Arman et al. 2007, Karakizi, Oikonomou e Karantzalos 2015, Karakizi, Oikonomou e Karantzalos 2016, Nidamanuri 2020, Gomes et al. 2020] trabalha com valores de atributos contínuos, embora possa ser adaptada para lidar com atributos categóricos [Aggarwal et al. 2015]. Consiste em estimar o quão similares são duas amostras, de maneira a classificar uma nova instância com base em outras mais próximas à ela, conforme um critério de proximidade previamente definido.

É um algoritmo simples com abordagem de agrupamento, sendo umas das técnicas mais utilizadas para problemas de classificação, baseada no cálculo de distância entre dois pontos (também denominada proximidade ou semelhança entre dados) em um espaço n-dimensional, permitindo ser calculada por diferentes métricas. A mais popular entre elas é a Distância Euclidiana.

Ao lidarmos com um problema bidimensional, podemos tratar cada instância como um ponto no plano composto por duas coordenadas (x,y). Quando temos mais de uma instância, podemos representá-las como pontos dispersos em um plano, além de categorizá-los. No entanto, o algoritmo é ineficiente para dados que apresentem alta dimensionalidade,

requerendo deste modo, um banco de dados balanceado. O kNN torna-se mais lento à medida que o número de variáveis aumenta, com sensibilidade a outliers.

### **Máquina de Vetor de Suporte**

Máquina de Vetor de Suporte (Support Vector Machine - SVM) usado em [Everingham et al. 2007, Ferreira-Arman et al. 2007, Gomes et al. 2020, Gutiérrez et al. 2018, Mirzaei et al. 2019, Nidamanuri 2014, Nidamanuri 2020], é um método classificatório de aprendizagem supervisionada que encontra o hiperplano ótimo entre classes, delimitando limites de decisão representadas como linhas de maneira a encontrar uma separação ótima entre elas. Funcionando como separadores lineares, objetiva-se a maximização da distância  $d$ , maximizando a margem de separação entre classes.

Entre as várias propriedades que definem a margem de separação entre classes, temos o ponto médio com distância  $d$ , sendo essa distância a mesma entre os pontos localizados na borda de ambas as classes. A delimitação da linha é realizada com base em uma pequena quantidade de pontos do mesmo lado do limite definido, ignorando pontos fora dele. No entanto, quando essa separação não pode ser obtida por um hiperplano, utilizamos o SVM não linear, que realiza uma transformação não linear, possibilitando posteriormente a aplicação de uma transformação linear.

As principais vantagens do SVM incluem sua eficácia em dados com alta dimensionalidade, flexibilidade de kernel e bom desempenho com margens de separação claras. No entanto, suas desvantagens são a inadequação para grandes bancos de dados e dados ruidosos. O algoritmo SVM é mais recomendado para problemas de classificação com margens de separação bem definidas e dados de alta dimensionalidade.

### **Floresta Aleatória**

Algoritmo de aprendizagem supervisionada que tem por característica a criação de uma floresta composta por árvores de decisão criadas aleatoriamente, combinando-as a fim de realizar previsões com maior acurácia. Presente em [Everingham et al. 2007, Gomes et al. 2020], a partição de nós é realizada a partir da escolha da melhor característica presente em um conjunto aleatório de características, mantendo a aleatoriedade do modelo.

As principais vantagens incluem a insensibilidade a outliers, a aplicabilidade em problemas de regressão, o baixo risco de overfitting e a boa eficiência em grandes conjuntos de dados. No entanto, apresenta desvantagens como treinamento lento, dificuldade de interpretação e alta demanda computacional. É mais recomendado para grandes conjuntos de dados com variabilidade e presença de outliers, onde a robustez e a redução de overfitting são importantes.

## Redes Neurais Artificiais

Pertencendo a uma subárea da Inteligência Artificial (IA), as Redes Neurais Artificiais (RNAs) são modelos computacionais populares de aprendizado de máquina, comportando centenas ou até milhares de unidades de processamento chamadas de neurônios, interligadas por meio de pesos que desempenham a mesma função das conexões sinápticas nos organismos biológicos. Por meio do uso das RNAs, muitos avanços importantes foram possíveis, em termos de utilidade para o dia a dia. Entre as características das RNAs estão o paralelismo, a capacidade de aprender por exemplos e de generalizar a informação aprendida, de forma a dar respostas a dados passados como entrada, mesmo que não tenham sido informados anteriormente à rede [Goodfellow 2016].

Ao construir uma rede neural simples, sem múltiplas camadas ocultas e com um número reduzido de unidades de processamento, o modelo se assemelha a técnicas clássicas de aprendizado de máquina, como regressão logística ou perceptrons de camada única. Dependendo da quantidade de camadas ocultas, as redes neurais podem receber diferentes classificações. Redes neurais com até uma ou duas camadas ocultas são chamadas de redes neurais rasas. Quando uma rede possui um número maior de camadas ocultas, ela é considerada uma rede neural profunda (ou *deep neural network*). As redes profundas são capazes de aprender representações mais complexas dos dados, o que as torna mais adequadas para tarefas sofisticadas.

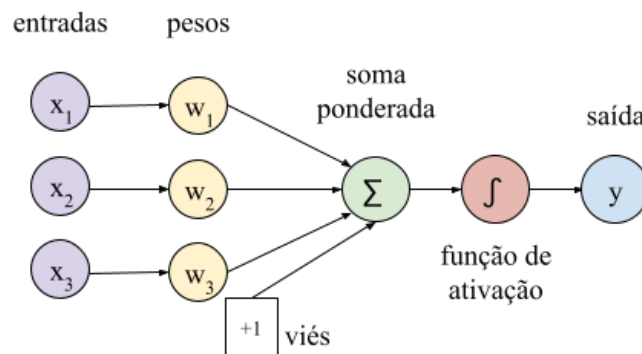
Entre os elementos construtivos das RNAs ([Oliveira 2018]), temos:

- Nós de entrada: São os responsáveis pelos dados de entrada utilizados no modelo, representando informações como características dos dados.
- Nós escondidos: Localizados nas camadas ocultas da rede neural, os nós escondidos são responsáveis pelo processamento interno dos sinais recebidos das camadas anteriores. Esses nós aplicam funções de ativação aos sinais de entrada para capturar e aprender padrões complexos presentes nos dados.
- Nós de saída: Localizados na última camada de uma rede neural, os nós de saída fornecem o resultado final do processamento realizado pela rede. Esses nós podem representar diferentes classes ou valores numéricos, dependendo do problema em questão. A quantidade de nós de saída é determinada com base no tipo de tarefa: em problemas de classificação multiclasse, o número de nós de saída corresponde ao número de classes distintas; em problemas de classificação binária, geralmente é utilizado apenas um nó de saída para representar as duas possíveis categorias.
- Conexões Saída/Entrada: Referem-se às ligações entre os nós de uma camada e os nós da camada subsequente em uma rede neural. Essas conexões transportam os valores dos nós de uma camada para a próxima, permitindo a propagação da informação através da rede. Cada conexão possui um peso associado, que ajusta a

influência do valor transmitido.

- **Pesos:** São parâmetros representando fatores de multiplicação para cada uma das conexões de entrada em um nó, ajustáveis de maneira a minimizar o erro produzido pela saída da rede neural que é medida através da diferença entre o valor real e o valor predito.
- **Viés:** É um parâmetro adicional que proporciona o ajuste da saída do nó independentemente dos valores de entrada, com a função de aumentar a flexibilidade de modelo.
- **Limiar:** Valor ajustado para cada nó que é comparado ao resultado da função de processamento. Assim, caso o valor resultante for maior que o limiar, um sinal de saída será gerado. Caso, contrário, nenhum sinal de saída será gerado.
- **Função de processamento (ou ativação):** Função matemática aplicada ao nó após a soma ponderada das entradas pelos respectivos pesos somados posteriormente a um viés, gerando um valor que será comparado ao limiar a fim de determinar a saída do nó.

Quando consideramos uma rede neural composta por um único neurônio, obtemos o que é conhecido como Perceptron (Figura 2.9)).



**Figura 2.9:** Estrutura básica de rede neural com um único neurônio.

Matematicamente, as operações realizadas em um perceptron podem ser representadas como uma combinação linear das entradas e pesos do neurônio. Esta combinação linear é expressa pela seguinte Equação 2-1:

$$u_k = \sum_{i=1}^m w_{ki}x_i \quad (2-1)$$

onde  $x_i$  são os sinais de entrada,  $w_{ki}$  são os pesos associados ao neurônio  $k$ , e  $u_k$  é a soma ponderada resultante. Para obter a saída do neurônio, aplicamos a função de ativação à soma ponderada acrescida do viés, conforme a seguinte Equação 2-2:

$$y_k = \varphi(u_k + b_k) \quad (2-2)$$


com  $b_k$  é o viés adicionado à soma ponderada ( $u_k$ ), e  $\varphi$  é a função de ativação aplicada ao resultado. A variável  $y_k$  representa o sinal de saída do neurônio.

Entre as funções de ativação mais comuns estão a função sigmoide, softmax, ReLU (*Rectified Linear Unit*) e a tangente hiperbólica. Esse processo de aplicação das funções de ativação é repetido em cada camada da rede neural até a camada de saída, que fornece o resultado final do processamento.

O uso de um único perceptron é eficaz para resolver problemas que são linearmente separáveis, ou seja, aqueles em que os dados podem ser separados por um único hiperplano. No entanto, um perceptron não é capaz de lidar com problemas que não são linearmente separáveis, onde os dados não podem ser separados por um único hiperplano. Para resolver esses problemas, é possível utilizar múltiplos perceptrons organizados em várias camadas, em uma estrutura de rede neural [Goodfellow 2016] denominada de Perceptron Multicamadas (MLP).

Em uma rede neural multicamadas (MLP), a estrutura é organizada em camadas ocultas, seguidas por uma camada de saída, que é a camada final da rede. O fluxo dos dados começa na camada de entrada, passa pelas camadas ocultas intermediárias e chega à camada de saída, configurando a arquitetura como uma rede *feedforward*. Nesta estrutura, os neurônios são distribuídos entre as camadas, e cada neurônio em uma camada está conectado aos neurônios da camada seguinte através de sinapses com pesos. A camada de entrada, que apenas fornece os sinais de entrada sem realizar processamento, não é contabilizada no número total de camadas da rede.

Assim como em um Perceptron, a MLP recebe sinais de entrada caracterizados como um vetor  $x = [x_1, x_2, \dots, x_n]$ , que representa características ou atributos coletados do problema, como, por exemplo, valores de brilho de uma imagem (Figura 2.10).



**Figura 2.10:** Estrutura de um Perceptron multicamadas (MLP).

Para que a rede neural aprenda, é aplicado o algoritmo *backpropagation*, que

ajusta os parâmetros da rede com base no valor da função de erro obtido na saída. O objetivo é encontrar os parâmetros ideais para o modelo, minimizando o erro derivado do modelo. O processo de atualização dos pesos começa pela camada de saída e retrocede até as camadas anteriores, incluindo a camada de entrada, com o intuito de minimizar o erro da rede.

Durante esse processo, os gradientes de cada peso são calculados para ajustar os pesos na direção que reduz o erro. Esse ajuste é feito com base em um número pré-estabelecido de iterações ou até que uma condição de parada seja atendida, como a estagnação da precisão do modelo após um número fixo de iterações.

Os componentes relacionados ao aprendizado de uma rede neural incluem os parâmetros ajustáveis, como pesos e vies, que são modificados durante o processo de treinamento, e os hiperparâmetros, que são ajustados externamente ao treinamento, como o número de camadas, o número de neurônios e a taxa de aprendizado da rede.

Durante o treinamento, a rede neural aprimora seu desempenho a cada ciclo por meio do ajuste dos parâmetros ajustáveis. Esses ajustes são feitos com base nos estímulos fornecidos pelos dados de entrada, que são processados e propagados através da rede, resultando em combinações de sinais de saída. As amostras da base de treinamento fornecem feedback sobre a precisão da rede neural, permitindo a minimização dos erros de classificação. Isso leva ao reajuste dos pesos, melhorando a precisão das previsões futuras e refinando a função calculada pela rede neural ao longo do tempo [Aggarwal et al. 2018].

Como exemplo, ao treinar uma rede neural com dados de uma planta específica, a rede eventualmente será capaz de reconhecer corretamente novas amostras relacionadas a essa mesma planta. Essa capacidade de fazer previsões precisas sobre dados não vistos, com base no treinamento realizado com um conjunto finito de dados, é conhecida como generalização do modelo. Assim, uma das principais características das redes neurais artificiais é o aprendizado, que se refere à construção do conhecimento a partir do ambiente apresentado. O desempenho da rede melhora à medida que mais amostras são fornecidas durante o processo de treinamento, permitindo que a rede refine suas previsões e se ajuste melhor aos dados.

Abordando o problema de classificar plantas e suas variedades, é evidente o crescimento do interesse e da aplicação das redes neurais em vários estudos [Guo, Jia e Paull 2018, Gutiérrez et al. 2018, Nidamanuri 2014, Nidamanuri 2020, Shao et al. 2001]. Essa preferência é explicada pela capacidade das redes neurais de realizar aprendizado contínuo e pela flexibilidade que oferecem tanto para problemas de regressão quanto para tarefas de classificação.

Ademais, o uso das redes neurais é recomendado para grandes volumes de dados e problemas complexos, onde a flexibilidade e a capacidade de aprendizado profundo são essenciais para o reconhecimento de padrões complexos. No entanto, as redes neurais

apresentam algumas desvantagens, como o treinamento lento, a dependência de hardware especializado, algoritmos complexos e uma eficiência reduzida em bancos de dados pequenos e ruidosos.

### Rede Profunda e Cruzada

Ao lidar com dados contendo características com relacionamentos complexos, o treinamento de um modelo de aprendizado de máquina pode se tornar demasiadamente desafiador, devido a conexão entre os atributos. Uma maneira de lidar com esse problema é através do cruzamento de características, realizando a combinação dos atributos de entrada em pares (correspondentes a recursos de primeira ordem), obtendo assim novas características de ordem superior.

A Rede Profunda e Cruzada (*Deep & Cross Network - DCN*) é uma arquitetura de rede neural projetada para aprender efetivamente interações de recursos explícitas e de grau limitado. Ela começa com uma camada de entrada (geralmente uma camada de incorporação), seguida por uma rede cruzada contendo várias camadas cruzadas que modelam interações de recursos explícitas, combinando-se com uma rede profunda que modela interações de recursos implícitas [Wang et al. 2017].

A arquitetura da rede é composta por uma camada de entrada, sendo esta normalmente uma camada de incorporação e possui várias camadas cruzadas que modelam interações de recursos explícitas. O modelo é construído pela combinação da saída de uma Rede Perceptron Multicamadas responsável por modelar interações de recursos implícitos com uma Rede Cruzada.

Por exemplo, considere as seguintes características ao construir um modelo para classificar cana-de-açúcar presente na Tabela 2.1.

Cana-de-açúcar	NDVI > 0.5	B4 > 0.3
1	1	1
0	0	0
1	1	0
0	0	1

**Tabela 2.1:** Exemplo ilustrativo de amostras de cana de açúcar e não-cana-de-açúcar contendo como características o NDVI e o valor de brilho da banda do vermelho.

O cruzamento dos dois vetores de atributos irá derivar um novo atributo contendo a cruzamento (multiplicação) desses atributos. Deste modo, a ideia compreende em fazer o modelo aprender associações relacionadas à essa conjunção obtida, gerando um novo atributo, como observada na Tabela 2.2.

Assim, a DCN faz uso desse cruzamento de recursos a fim de extrair novas características de maneira a associar atributos, obtendo recursos adicionais e com isso

Cana-de-açúcar	NDVI>0.5 B4>0.3	NDVI<0.5 B4<0.3	NDVI>0.5 B4<0.3	NDVI<0.5 B4>0.3
1	1	0	0	0
0	0	1	0	0
1	0	0	1	0
0	0	0	0	1

**Tabela 2.2:** *Características de segunda ordem adquirida a partir dos dados originais da Tabela 2.1 com amostras ilustrativas de cana de açúcar e não-cana-de-açúcar contendo como características o NDVI e o valor de brilho da banda do vermelho.*

aprendendo associações entre eles. Além disso, a DCN pode ser construída de duas formas: adicionando uma rede profunda no topo do modelo com posterior adição da rede cruzada (estrutura empilhada); ou construir ambas as redes em paralelo (estrutura paralela), unido ao final as saídas de ambas as redes.

Em comparação com as redes MPL tradicionais, essas por sua vez são aproximadoras universais de funções; no entanto não podem aproximar eficientemente interações de recursos de 2ª ou 3ª ordem. No caso da DCN, temos uma arquitetura de rede neural projetada para superar essas limitações envolvendo o cruzamento de recursos. Dessa forma, a DCN é eficaz para aprender interações de recursos, especialmente quando os dados são categóricos, levando a um espaço de recursos grande e esparsos.

## 2.4 Avaliação de Desempenho do Modelo

Um classificador é um algoritmo que classifica novas instâncias, separando-as em diferentes classes. Classificadores podem ser criados com base no mesmo conjunto de dados, mas apresentam desempenhos variados conforme o algoritmo utilizado. A avaliação do desempenho de um modelo requer estratégias como a separação entre dados de treinamento e de teste, validação cruzada k-fold e validação cruzada n-fold [Bramer 2007].

No método de separação entre amostras, os dados são divididos em conjunto de treinamento e conjunto de teste. O conjunto de treinamento serve para a construção do modelo e ajuste de parâmetros, enquanto o conjunto de teste é utilizado para predição, permitindo avaliar a precisão do classificador comparando os valores preditos com os valores reais. Esse procedimento evita resultados enviesados, pois a classificação é feita com amostras desconhecidas pelo modelo.

A validação cruzada k-fold divide as amostras em k conjuntos iguais, usando cada conjunto na etapa de aprendizagem do algoritmo, resultando em k execuções. A precisão é obtida somando as instâncias corretamente classificadas em cada execução e dividindo pelo total de instâncias. A validação cruzada n-fold, uma variação extrema do k-fold, divide os

dados em  $n$  partes, gerando  $n$  modelos para cada instância e calculando a precisão pela soma das instâncias corretamente classificadas dividida pelo total de instâncias.

## 2.5 Ajuste de Hiperparâmetros

Um etapa importante para a construção dos modelos classificatórios é o ajuste de hiperparâmetros, que compreende em encontrar hiperparâmetros que melhor se adequem ao problema, de acordo com os dados fornecidos como entrada para o modelo. Um hiperparâmetro representa uma característica externa do modelo definida antes do treinamento do modelo. Deste modo, o ajuste de hiperparâmetros busca encontrar uma combinação de hiperparâmetros que maximize o desempenho do modelo. Por exemplo, entre os hiperparâmetros do kNN, podemos definir a quantidade de vizinhos observada de acordo com um intervalo de possíveis valores e o tipo de distância aplicada.

Essa escolha pelos melhores hiperparâmetros pode ser feita por algumas abordagens diferentes, que incluem a busca em grade (Grid Search), a busca aleatória (Random Search) e a otimização Bayesiana (Bayesian Optimization).

### 2.5.1 Otimização Bayesiana

O processo de ajuste de hiperparâmetros do modelo é uma etapa frequente em algoritmos de aprendizado de máquina, geralmente exigindo buscas exaustivas para a otimização do modelo. Enquanto os parâmetros são ajustados durante a fase de treinamento, os hiperparâmetros são definidos externamente, sendo selecionados com o objetivo de melhorar o desempenho do modelo em relação aos dados de entrada.

Para esse propósito, os hiperparâmetros são tipicamente determinados por meio de várias combinações, o que, dependendo do algoritmo e da quantidade de hiperparâmetros avaliados, pode resultar em longos períodos de processamento, condicionados pela capacidade do hardware utilizado, como na técnica de ajuste de hiperparâmetros *Grid Search*, que a partir da definição dos valores de cada hiperparâmetro, testa todas as combinações possíveis, retornando a combinação com a melhor métrica e avaliação definida.

Na otimização Bayesiana, define-se um intervalo de possíveis valores para cada hiperparâmetro, uma métrica a ser utilizada na avaliação, e um número de iterações a serem consideradas. A cada iteração, é criado um modelo que busca prever a função objetivo – uma função composta por uma ou mais variáveis que se deseja minimizar ou maximizar. O ajuste dos hiperparâmetros é feito com base nas avaliações anteriores, utilizando amostras de valores aleatórios de hiperparâmetros. A cada combinação testada, uma pontuação é atribuída de acordo com a métrica de avaliação aplicada.

No contexto comum de otimização de modelos de aprendizado de máquina, o objetivo é geralmente encontrar o mínimo de uma função  $f(x)$ , onde  $f(x)$  representa o erro gerado pelo modelo. Esse erro é calculado comparando a saída do modelo com os valores originais, de forma a encontrar os hiperparâmetros que minimizem o erro. Na técnica de otimização Bayesiana, um modelo probabilístico é construído para  $f(x)$  denominado de modelo *surrogate*, estimando o comportamento de  $f(x)$  com base nos dados obtidos em iterações anteriores [Snoek, Larochelle e Adams 2012]. Esse modelo probabilístico é então utilizado para prever quais combinações de hiperparâmetros têm maior probabilidade de minimizar  $f(x)$ , guiando assim a busca de maneira mais eficiente.

Inicialmente, escolhe-se uma distribuição inicial que reflete as suposições sobre a função  $f(x)$  a ser otimizada. Após algumas iterações, cada ponto da função representará a probabilidade de que um determinado conjunto de hiperparâmetros produza uma boa pontuação de acordo com a métrica avaliada. Para modelar essa distribuição inicial, pode-se utilizar um processo Gaussiano, que permite modelar o comportamento de diferentes tipos de funções.

## 2.6 Métricas de desempenho

A aprendizagem estatística é uma presença significativa em diversas áreas, como ciência, finanças e indústria, desempenhando um papel fundamental em estatísticas, mineração de dados e inteligência artificial. Ao trabalhar com conjuntos de dados, estes podem conter informações quantitativas ou categóricas, expressas através de um conjunto de características. Com base nesses dados, é possível desenvolver modelos de previsão que permitem fazer projeções para novos objetos não observados. Um modelo de previsão eficaz é capaz de generalizar de forma adequada a partir dos dados fornecidos, o que auxilia na escolha dos hiperparâmetros do modelo. Esse tipo de modelo é chamado de "supervisionado" devido à presença de rótulos nas amostras que guiam o processo de aprendizado [Hastie et al. 2009].

No contexto de problemas envolvendo a classificação de amostras, é essencial avaliar o modelo desenvolvido para estimar a qualidade do resultado da classificação. Portanto, para a avaliação do desempenho de um modelo classificatório, uma variedade de métricas pode ser definida com base na previsão das amostras de dados do conjunto de testes. Entre as métricas mais reconhecidas estão Acurácia, Recall, Precisão e pontuação F1 (F1-Score). Essas métricas são calculadas a partir da matriz de confusão, que apresenta, em formato tabular, o número de amostras rotuladas corretamente ou incorretamente para cada classe.

A precisão é obtida pela quantidade de instâncias corretas classificadas, ou seja, os verdadeiros positivos (VP), dividido-os pelo total de instâncias, como apresentado na

Equação 2-3:

$$Precisão : \frac{VP}{VP + FP} \quad (2-3)$$

Outras informações importantes podem ser extraídas do modelo, como verdadeiros negativos (VN), que correspondem a instâncias negativas corretamente classificadas como negativas, falsos positivos (FP), que representam a quantidade de instâncias negativas erroneamente classificadas como positivas, e falsos negativos (FN), que são instâncias positivas erroneamente classificadas como negativas. Com base nessas informações, podemos definir medidas de desempenho de um modelo a partir de um conjunto de teste.

A métrica *Recall* relaciona as previsões dos verdadeiros positivos com os falsos negativos (Eq. 2-4). No caso do F1-Score, esta medida por sua vez combina a precisão e o *recall*, como uma métrica harmônica entre as duas medidas.

$$Recall = \frac{VP}{VP + FN} \quad (2-4)$$

$$F1 \text{ score} = \frac{2 * Precisão * Recall}{Precisão + Recall} \quad (2-5)$$

A acurácia possibilita estimar a performance geral do modelo, servindo como um indicativo de seu desempenho, devendo ser calculada a partir de uma quantidade balanceada de amostras para cada classe do conjunto de dados, pois o desbalanceamento pode resultar em indicadores que não representam realmente o problema.

A partir dos dados da matriz de confusão, também é possível representar o desempenho de diversos classificadores por um gráfico ROC por valores de verdadeiros positivos e falsos positivos obtidos de cada classificador. A avaliação entre modelos é realizada medindo a distância de cada classificador a um classificador ideal, ou seja, um classificador com predição perfeita das amostras [Aggarwal et al. 2015].

Além dessas métricas, a métrica Kappa (Estatística Kappa de Cohen) e a função de erro de perda também são comumente aplicadas em estudos.

### 2.6.1 Considerações Finais

Neste capítulo, explorou-se o uso do sensoriamento remoto como uma ferramenta para o estudo e a classificação de variedades de culturas, com foco especial na cana-de-açúcar. A integração de tecnologias avançadas e dados provenientes de sensores de satélite tem se mostrado um recurso de grande valor para a otimização da gestão agrícola, possibilitando a coleta de informações precisas sem a necessidade de intervenção direta nas plantas, o que representa uma significativa vantagem em termos de eficiência e

sustentabilidade. Considerando a relevância do aprimoramento genético das variedades de cana-de-açúcar para a maximização da produtividade no setor sucroalcooleiro, as metodologias de classificação e reconhecimento de variedades surgem como soluções promissoras.

Adicionalmente, o capítulo abordou as diferentes resoluções dos dados de sensoriamento remoto – espacial, espectral e temporal – que, quando corretamente aplicadas, enriquecem os modelos de classificação, oferecendo uma análise detalhada das áreas agrícolas. Por fim, a introdução de Redes Neurais Artificiais (RNAs) e arquiteturas avançadas, como a Rede Profunda e Cruzada (DCN), destaca o potencial das redes neurais em identificar e modelar interações complexas entre os fatores que impactam o crescimento e o desempenho das variedades de cana-de-açúcar, ampliando as possibilidades para um monitoramento mais eficiente e preciso.

---

## Revisão da Literatura

---

A criação de novas variedades e variedades híbridas de culturas é de grande interesse para pesquisadores e produtores, que por razões econômicas, ambientais e de direitos sobre cultivares, têm buscado por maneiras de gerir o desenvolvimento de plantas através de metodologias por meios remotos, possibilitando a otimização de recursos com deslocamentos, melhoria de modelos de predição de produtividade, além de outros benefícios relacionados à análise de plantas.

Devido à maior disponibilidade de produtos derivados do sensoriamento remoto, com opções gratuitas, disponibilização de bibliotecas espectrais, o desenvolvimento da tecnologia e a redução de custos para aquisição de hardware, o sensoriamento remoto pode ser um aliado quando aplicado com a finalidade de identificar e classificar variedades de culturas, motivando pesquisadores na área.

Na literatura foram encontradas algumas revisões com temas relacionados ao sensoriamento remoto em culturas, com foco em práticas de corte e classificação do tipo de diferentes culturas por uso de dados de sensoriamento remoto. Apesar de lidarem com o tema sobre culturas, não envolvem a classificação de diferentes variedades de uma mesma cultura, não incluindo-os nessa revisão.

No caso do levantamento relacionado à cana-de-açúcar, artigos encontrados na literatura incluídos na publicação "*Discrimination of Sugarcane Varieties by Remote Sensing: A Review of Literature*" [Kai et al. 2020] foram adicionados a Subseção 3.2.5.

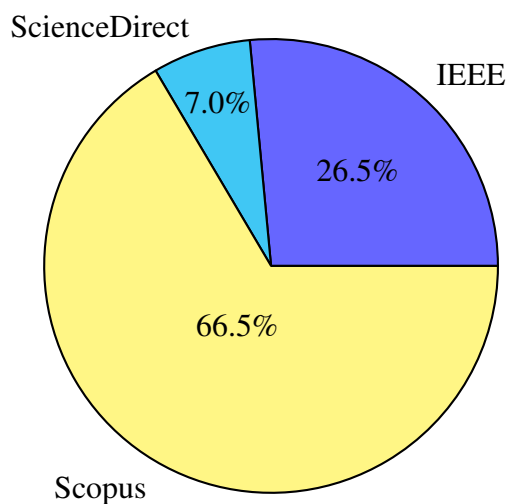
Portanto, essa revisão da literatura possui o objetivo de apresentar quais os métodos utilizados por outros pesquisadores para o problema de classificação em variedades de plantas, trazendo informações sobre as etapas componentes dos processos envolvidos, com foco na diferenciação entre variedades de uma mesma cultura.

### 3.1 Revisão da Literatura na Classificação de Variedades

Para obter artigos para a revisão da literatura, foi realizada uma busca por título, palavras-chave e resumo em três bases de dados: IEEE, Scopus e ScienceDirect. Os resultados dessas fontes foram compilados, incorporando vários trabalhos relacionados

ao tema pesquisado. Assume-se que os documentos recuperados pela pesquisa tenham passado por uma etapa de revisão por pares, um processo mais rigoroso para a publicação de conteúdo acadêmico. Para tal, a seguinte string de busca foi aplicada: *(variet\*) AND (classification OR discrimination OR identification) AND ("remote sensing"OR "satellite image\*"OR "satellite"OR "satellite sensor"OR "imaging spectrometer"OR "environmental monitoring")*.

O intervalo de datas para a publicação dos estudos foi definido para até cinco anos, com metadados adquiridos de todos os artigos retornados da busca totalizando 1905 trabalhos, com recente atualização em maio de 2024, separados em 1267 artigos da base Scopus, 504 do IEEE e 134 do Science Direct, com distribuição representada pela Figura 3.1.



**Figura 3.1:** *Quantidade de artigos resultantes da busca por base de dados segundo a string de busca.*

A revisão da literatura foi conduzida em etapas distintas. Inicialmente, os trabalhos foram categorizados em duas classes, sendo estas "aceitos" e "rejeitados", com base na avaliação do título, resumo, palavras-chave e disponibilidade dos mesmos.

Entre os artigos excluídos, foram removidos da extração final títulos duplicados ou artigos que não abordavam a análise entre variedades e suas características. Para as informações extraídas foram incluídas o tipo de entrada utilizada no estudo, índices de vegetação, bandas de sensores e métodos para a classificação de variedades de culturas. Também foi realizada uma comparação entre os métodos classificatórios em variedades de cana-de-açúcar.

Após a seleção inicial dos trabalhos, procedeu-se à leitura detalhada dos textos com o objetivo de identificar os artigos mais relevantes para o tema da revisão. Os artigos selecionados foram então submetidos à extração de informações pertinentes. Como

Base de Dados	Quantidade por Base	Duplicados	Aceitos
IEEE Digital Library	504	94	7
ScienceDirect	134	43	2
Scopus	1267	182	24

**Tabela 3.1:** Tabela contendo informações sobre estudos importados de diferentes bases de dados, considerando as fontes IEEEXplore, ScienceDirect e Scopus, com foco em estudos publicados no período de 2019 a 2024.

resultado desse processo, 33 artigos foram considerados relevantes e escolhidos para a extração de dados, cujos detalhes estão disponíveis para consulta na Tabela 3.1.

## 3.2 Metodologia para a classificação de variedades de cultura por imagens de satélite

### 3.2.1 Aquisição

O primeiro passo para uma metodologia que faça a diferenciação entre variedades de uma cultura é a escolha pelo dado de entrada. Entre os tipos existentes são encontrados dados derivados de sensores acoplados a satélites, a bordo de aeronaves e dispositivos portáteis à nível do solo, bem como aquisição realizadas em laboratório. A vantagem de usar dispositivos à nível de campo ou laboratório compreende na aquisição de dados em um ambiente mais controlado, permitindo a coleta de amostras em cenários favoráveis de iluminação e evitando condições climáticas adversas. No entanto são menos acessíveis que outros tipos de dados, como os advindos de sensores de satélite, que possuem como vantagem a periodicidade.

Ao considerar estudos para os últimos cinco anos voltados à classificação de variedades de cultura por imagens de sensoriamento remoto, os estudos revisados utilizaram diversas metodologias de coleta e análise de dados, com inclusão de sensores UAV [Wijayanto et al. 2023, Camenzind e Yu 2024], sensores orbitais, como o Sentinel-2 [Fiorio 2019, Purwar et al. 2019, Sharma 2020, Kai et al. 2021, Kai, Oliveira e Costa 2022, Rauf et al. 2022, Sun et al. 2023], Landsat-8 [Cipta, Jaelani e Sanjaya 2022] e Sentinel-1, que leva a bordo sensores de radar, usado para identificar fases de crescimento de diferentes variedades de arroz por uso de valores de retrodispersão [Nurhuda, Wibowo et al. 2022] e características de polarização na identificação de tipos de pastagens [Sun et al. 2023].

No caso do tipo de entrada selecionada, houve um equilíbrio entre imagens hiperespectrais e multiespectrais. Dados de instrumentos como espectrômetros e espectrorradiômetros também foram encontrados para a tarefa de discriminação de variedades.

Os espectrorradiômetros são preferidos para realizar medições, representando 30% dos artigos selecionados para leitura.

Ademais, para a classificação de alguns espécies, os dados de aquisição com datas abrangendo períodos específicos no desenvolvimento de plantas foram considerados, como por exemplo a fase de floração/maturação, que é a mais recomendada [Biradar 2019, Sencaki et al. 2019] em comparação com datas em estágios vegetativos da plantas, apresentando desempenho inferior devido principalmente à mistura espectral entre planta e solo exposto.

### **Instrumento Sensores na Classificação de Variedades Agrícolas**

Em pesquisas que visam a diferenciação entre variedades de culturas, considerando os últimos 5 anos, parte dos estudos engloba o uso de imagens de sensores acoplados à satélites, dispositivos sensores portáteis à nível do solo ou com uso em laboratório como espectrorradiômetros ou espectrômetros, com distribuição similar para imagens hiperespectrais [Biradar 2019, Mirzaei et al. 2019, Sencaki et al. 2019, Furlanetto et al. 2020, Gold et al. 2020, Gomes et al. 2020, Nidamanuri 2020, Sinha et al. 2020, Zhang et al. 2022, Domínguez-Cid et al. 2023, Székely et al. 2023, Zhang et al. 2023, Niedzielko et al. 2024] e multiespectrais [Purwar et al. 2019, Sharma 2020, Liang et al. 2021, Cipta, Jaelani e Sanjaya 2022, Rauf et al. 2022, Verma et al. 2022, Jamil et al. 2023, Navarro et al. 2021, Wijayanto et al. 2023, Camenzind e Yu 2024, Cipta, Jaelani e Sanjaya 2024].

A identificação de variedades de cana-de-açúcar por meio de imagens de satélite tem se concentrado, predominantemente, em pesquisas baseadas em imagens hiperespectrais. Estudos mais antigos frequentemente utilizam imagens do sensor EO-1 Hyperion ou dispositivos espectrorradiômetros, como o ASD FieldSpec. Já em análises de dados multiespectrais, destacam-se as aplicações dos produtos da série Landsat, especialmente os sensores Landsat-7 e Landsat-8 [Singh, Patel e Danodia 2022] e o Sentinel-2 [Fiorio 2019, Kai et al. 2021, Kai, Oliveira e Costa 2022, Sharma 2020]. Enquanto as imagens hiperespectrais oferecem maior riqueza espectral, os dados multiespectrais, por sua vez, geralmente apresentam melhor resolução espacial.

### **3.2.2 Extração de Características**

Ao trabalhar com dados contendo muitas dimensões, como bandas espectrais, é comum a adoção por técnicas a fim de extrair informações relevantes e reduzir a dimensionalidade dos dados para a remoção de ruídos que possam prejudicar a classificação dos dados.

Entre as características comumente usados nos estudos, temos dados derivados de comprimentos de onda e valores calculados usando índices de vegetação, permitindo à análise bioquímica de plantas, fases de desenvolvimento e discriminação de variedades.

### 3.2.3 Bandas

A partir dos artigos encontrados na literatura, as melhores bandas espectrais para classificar variedades de culturas estão na região de reflectância vermelha, sendo particularmente eficazes durante o período de crescimento de plantas no qual as folhas se sobrepõem evitando a incidência do sol diretamente no solo, como em estágios de floração e maturação para a maioria das características. A faixa compreendendo comprimentos de onda de 400 nm a 895 nm também mostram-se eficientes, sendo úteis para a discriminação em diferentes estágios fenológicos, onde de 510–520 nm à 550–625 nm apontaram diferenças significativas entre os períodos de crescimento do arroz sob condições naturais de estresse pelo frio [Székely et al. 2023]. Comprimentos de onda do infravermelho de ondas curtas também mostraram-se importantes na separação entre variedades de cana-de-açúcar [Fiorio 2019]. O uso de dias em estágios vegetativos iniciais foram menos eficientes em apontar diferenças significativa entre variedades, fato atribuído à mistura espectral influenciada pelo solo aparente [Biradar 2019].

As regiões do verde e NIR são consideradas as melhores para diferenciação entre algumas variedades, como o milho [Sencaki et al. 2019]. Para variedades de videiras, as bandas próximas a 695, 752, 1148 e 1606 nm resultaram em melhor separação. No caso do arroz, a reflectância do verde possui características espectrais particularmente discriminativas, capturando diferenças na estrutura das folhas, pigmentação ou características entre as variedades em todas as fases de crescimento [Wijayanto et al. 2023]. Adicionalmente, as regiões do espectro correspondentes à borda do vermelho, ao infravermelho próximo e ao infravermelho médio desempenham um papel fundamental na distinção entre variedades de culturas, conforme demonstrado em diversos estudos. A seleção de comprimentos de onda no infravermelho é especialmente vantajosa, pois, ao se analisar a vegetação, observa-se que a maior parte da biomassa das plantações reflete uma quantidade significativa de energia no infravermelho próximo. Isso possibilita a avaliação da distribuição e quantidade de vegetação, sendo uma ferramenta valiosa tanto para a identificação de culturas quanto para o realce de contrastes entre solo e vegetação [Jensen e Epiphanyo 2009].

A seleção de comprimentos de onda no infravermelho é vantajosa, pois não enfrenta problemas de dispersão atmosférica (influência nos dados causados por gases e poeira na atmosfera) como na região do espectro visível, especialmente no comprimento de onda azul [Campbell e Wynne 2011].

## Índices de Vegetação

Em muitos estudos observou-se o uso de características derivadas do cálculo de índices de vegetação, permitindo extrair dados relacionados à fenologia de uma cultura [Cipta, Jaelani e Sanjaya 2022]. Dependendo do tipo de cultura estudada, alguns índices são mais aplicados do que outros.

Entre os índices mais encontrados nos artigos da revisão, temos, majoritariamente o cálculo do Índice de Vegetação por Diferença Normalizada (NDVI), muito utilizado para verificar a condição da vegetação, comparando a luz absorvida e refletida nas faixas do vermelho e do infravermelho próximo. Um valor baixo de NDVI pode indicar diferentes motivos, como doenças, estresse ou regiões com pouca ou nenhuma atividade de clorofila, amparando o processo de identificação de variedades em crescimento. No caso de altos valores, pode representar alta absorção de luz pela clorofila indicando que a planta está sadia, medindo a atividade da clorofila nas folhas.

Um ponto contribuinte para a diferenciação de variedades está relacionado as condições externas encontradas no local estudado. Assim, se as plantas investigadas estiverem nas mesmas condições, a comparação entre os valores do NDVI será mais justa, baseada apenas nos dados da planta [Cemin e Ducati 2011].

Além do NDVI, foram encontrados alguns estudos com o Índice de Borda Vermelha de Diferença Normalizada (NDRE), também correlacionado à biomassa assim como o NDVI, e o Índice de Água de Diferença Normalizada (NDWI) capaz de classificar [Rauf et al. 2022], quantificar respostas de cultivares à infecções [Gold et al. 2020] e destacar o teor de água nas plantas permitindo a percepção de alterações no teor de água das folhas. Os índices mais aplicados podem ser visualizados na Tabela 3.2.

**Tabela 3.2:** Índices de vegetação (IVs) mais encontrados em estudos para destacar diferenças entre variedades de culturas entre os estudos dos últimos cinco anos.

IVs	Fórmula	Referência	Parâmetro Biológico
CI	$\frac{R-B}{R}$	[Escadafal, Belghith e Ben-Moussa]	Vegetação
GNDVI	$\frac{NIR-G}{NIR+G}$	[Gitelson, Kaufman e Merzlyak 1996]	Clorofila
MCARI	$((RE - R) - 0.2(R - G))(\frac{RE}{R})$	[Daughtry et al. 2000]	Clorofila
MNDWI	$\frac{G-SWIR}{G+SWIR}$	[Xu 2006]	Conteúdo de água
NDCI	$\frac{RE-R}{RE+R}$	[Mishra e Mishra 2012]	Clorofila
NDRE	$\frac{NIR-RE}{NIR+RE}$	[Barnes et al. 2000]	Clorofila
NDVI	$\frac{NIR-R}{NIR+R}$	[Jr et al. 1974]	Biomassa verde
NDWI	$\frac{NIR-SWIR}{NIR+SWIR}$	[Gao 1996]	Conteúdo de água
NPCI	$\frac{(R680-R430)}{(R680+R430)}$	[Peñuelas et al. 1994]	Clorofila
SAVI	$\frac{(1+L)(NIR-R)}{NIR+R+L}$	[Huete 1988]	Biomassa verde

A Tabela 3.3 traz os estudos contendo os três índices de vegetação (IVs) mais frequentemente utilizados na classificação de variedades, destacando as principais

referências bibliográficas e as culturas no qual foram mais aplicados.

IVs	Citações	Cultura mais usada
NDVI	[Fiorio 2019, Mirzaei et al. 2019, Sencaki et al. 2019, Liang et al. 2021, Kai, Oliveira e Costa 2022, Rauf et al. 2022, Sedighi et al. 2023, Székely et al. 2023, Wijayanto et al. 2023]	Todas
NDRE	[Kai et al. 2021, Kai, Oliveira e Costa 2022, Camenzind e Yu 2024]	Trigo, milho e cana-de-açúcar
NDWI	[Mirzaei et al. 2019, Kai, Oliveira e Costa 2022, Rauf et al. 2022, Székely et al. 2023]	Arroz

**Tabela 3.3:** Índices de vegetação mais comumente utilizados para classificar variedades de culturas de acordo com os estudos encontrados na literatura.

### 3.2.4 Modelos para Classificação

Na literatura, vários métodos foram utilizados para analisar e identificar as culturas e suas variedades. Para diferenciação entre variedades, majoritariamente foram aplicados modelos englobando análise discriminante [Biradar 2019, Furlanetto et al. 2020], máquinas vetores de suporte (SVM) [Gomes et al. 2020, Nidamanuri 2020, Kai et al. 2021, Sedighi et al. 2023], florestas aleatórias [Gold et al. 2020, Sinha et al. 2020, Sun et al. 2023, Camenzind e Yu 2024] e arquiteturas de redes neurais artificiais (ANN), como redes densas [Kai, Oliveira e Costa 2022, Wijayanto et al. 2023, Jamil et al. 2023], redes recorrentes [Purwar et al. 2019], redes de atenção [Zhang et al. 2022], redes adversárias gerativas (GANs) para aumento de dados [Zhang et al. 2023] e redes convolucionais [Navarro et al. 2021, Rauf et al. 2022]. Na Tabela 3.4 estão disponíveis os modelos classificatórios contendo informações referentes à acurácia adquirida por metodologias na diferenciação de variedades de culturas agrícolas, destacando o tipo de dados (espectrais ou hiperespectrais), as plantas estudadas e a acurácia alcançada em cada caso.

A variedade de plantas estudadas é diversificada, com a inclusão de culturas mais comumente cultivadas no país como a cana-de-açúcar, trigo e milho; arroz com trabalhos frequentemente advindos por pesquisadores chineses, bem como outras plantas, como alface, banana, chá verde, e videira. Dessa forma, diferentes abordagens de classificação foram identificadas, com acurácia diversas. Por exemplo, modelos como o SVM e a CNN foram altamente eficazes para videiras e arroz, enquanto outros modelos, como o PLS-DA e o CPPLS, apresentaram acurácias mais modestas em milho e banana, respectivamente.

O algoritmo SVM mostrou-se presente em várias metodologias de classificação de variedades com acurácia superior em comparação a outros métodos, com altos índices

de acurácia em estudos com cana-de-açúcar e videiras. Metodologias desenvolvidas por técnicas com análise discriminantes também foram encontradas aplicadas à investigações com alface, banana e milho, seguida pelas florestas aleatórias com aplicações em plantas como a cana-de-açúcar e trigo. As ANNs e as redes convolucionais demonstraram boas performances, especialmente em culturas como trigo e arroz. A RNN reusltou em acurácia de 95.0% ao ser aplicada em trigo, milho e legumes no trabalho de [Purwar et al. 2019].

**Tabela 3.4:** Modelos classificatórios, tipo de dado, planta estudada e acurácia na diferenciação de variedades de culturas.

Modelos	Tipo de Dados	Planta	Acurácia (%)
Floresta aleatória	M	cana-de-açúcar	86.0 [Fiorio 2019]
SVM			99.1 [Kai et al. 2021] 99.5 [Kai, Oliveira e Costa 2022]
	M e H		82.0 [Sedighi et al. 2023]
RNN	M	trigo, milho e legumes	95.0 [Purwar et al. 2019]
PLS-DA	H	milho	63.0 [Biradar 2019]
SSTNet			97.9 [Zhang et al. 2022]
GACNet	H	trigo	98.8 [Zhang et al. 2023]
ANN	M		97.0 [Jamil et al. 2023]
Floresta aleatória			92.0 [Camenzind e Yu 2024]
CNN	M	arroz	98.6 [Rauf et al. 2022]
ANN			64.4 [Wijayanto et al. 2023]
LDA	H	alface	81.0 [Furlanetto et al. 2020] 99.9 [Falcioni et al. 2022]
SVM	H	uva	89.9 [Mirzaei et al. 2019]
CNN	M		100 [Navarro et al. 2021]
CPPLS	H	banana	60% [Sinha et al. 2020]
SVM	H	videira	81.73 [Gomes et al. 2020]
CatBoost	H	árvore	80.9 [Niedzielko et al. 2024]
SVM	H	chá verde	75.0 [Nidamanuri 2020]
Floresta aleatória	M	pastagem	82.6 [Sun et al. 2023]

No caso do milho, ambas as metodologias empregam espectrômetros, diferenciando-se pela quantidade de variedades analisadas: o estudo de [Zhang et al. 2022] analisou 10 variedades, enquanto o de [Biradar 2019] investigou 25 variedades. Para o trigo, dados hiperespectrais demonstraram-se eficazes na diferenciação entre 19 variedades, como observado no estudo de [Zhang et al. 2023] por meio de redes adversárias generativas (GANs). Em variedades de arroz, arquiteturas de redes neurais foram a escolha preferida por pesquisadores, com melhor precisão por uso das redes convolucionais.

Portanto, apesar de métodos clássicos como análise discriminante, SVM e florestas aleatórias ainda serem amplamente usadas, é notável o aparecimento de investigações com

metodologias por aplicação de redes neurais, demonstrando versatilidade e desempenho para diferentes variedades, apontando para a tendência por pesquisadores em explorar técnicas mais recentes de aprendizado de máquina para o processamento de dados multiespectrais e hiperespectrais na agricultura moderna.

### 3.2.5 Comparação de Métodos na Classificação de Variedades de Cana-de-açúcar

Ao analisar estudos para a classificação de variedades de cana-de-açúcar na literatura, alguns métodos são encontrados para este fim, destacando abordagens com diferentes graus de sucesso. Dentre algumas metodologias mencionadas, o método por Schmidt [[Schmidt et al. 2000](#)], por uso de imagens multiespectrais e análise multivariada, aplicou a análise de componentes principais na remoção de ruído presente nos dados, destacando que a assinatura espectral das variedades deveria ser investigada com base no estágio de crescimento. A análise multivariada aplicada em dados multiespectrais também encontra-se no estudo de Fortes [[Demattê 2006](#)], com precisão de 93.55% na classificação de quatro variedades de cana-de-açúcar, utilizando imagens multiespectrais.

Na metodologia utilizada por Apan [[Apan et al. 2004](#)] a análise discriminante foi usada para separação entre oito variedades de cana, além de quarenta índices de vegetação, com a classificação de 72.4% para 8 variedades, apontando melhor separabilidade em algumas faixas espectrais, assim como no estudo de Galvão [[Tisot 2005](#), [Arnold 2006](#)], que além de dados de reflectância, incluiu índices sensíveis para clorofila, água da folha e lignina-celulose na discriminação de cinco variedades de cana-de-açúcar. Mais um estudo com adição de pigmentos na análise foi o estudo de Johnson [[Zimba 2008](#)], resultando na melhorias na classificação de sete variedades de cana-de-açúcar.

Outro estudo por uso de dados hiperespectrais foi a investigação realizada por Everingham [[Everingham et al. 2007](#)] na classificação de nove variedades de cana-de-açúcar, no qual a classificação mostrou-se mais eficiente por modelos como florestas aleatórias e SVM.

Em estudos mais recentes considerando os cinco últimos anos, modelos tradicionais de classificação como SVM e florestas aleatórias ainda são bastante aplicadas, como no artigo Amir [[Sedighi et al. 2023](#)], que faz uma análise comparativa entre dados multiespectrais e hiperespectrais no mapeamento de variedades de cana-de-açúcar para distinguir quatro variedades, através de valores de reflectância e IVs, com precisão geral de 82%; na investigação apresentada no artigo de [[Singh, Patel e Danodia 2022](#)] na diferenciação entre cana-planta e cana-soca com precisão geral de 84,5% e no estudo de Duft [[Fiorio 2019](#)], com precisão de 86%, com criado de três modelos, um para cada imagem utilizada na investigação.

De acordo com as investigações, uma baixa precisão na diferenciação de variedades de cana-de-açúcar pode ser atribuída à diferenças das variedades em estágios de desenvolvimento, maneiras distintas de manejo por produtores, influência relacionadas à saúde das plantas, como doenças, pragas e condições climáticas [Apan et al. 2004] (seca, alagamentos, geada).

Para os comprimentos de onda mais representativos na diferenciação de variedades de cana-de-açúcar temos os comprimentos que englobam o infravermelho de ondas curtas (SWIR), auxiliando na separabilidade por modelos de classificação e bandas do infravermelho próximo (NIR) [Tisot 2005, Arnold 2006, Fiorio 2019].

Ao tratarmos de índices mais comumente aplicados à tarefa que envolva identificação e discriminação de variedades de cana-de-açúcar, os índices tradicionalmente utilizados englobam além do NDVI, amplamente aplicado em vários trabalhos como [Tisot 2005, Demattê 2006, Apan et al. 2004, Sandoval, Gonzalez e Osorio 2011, Zimba 2008], o índice MCARI (Índice de Absorção e Refletância de Clorofila Modificado) [Tisot 2005, Arnold 2006, Apan et al. 2004], índice sensível à variação de clorofila, Ratio Vegetation Index (RVI) [Demattê 2006, Sandoval, Gonzalez e Osorio 2011] que indica a quantidade de vegetação, Índice de Vegetação Ajustado pelo Solo (SAVI) [Demattê 2006, Sandoval, Gonzalez e Osorio 2011] e Índice de Vegetação Global (GVI) [Demattê 2006, Sandoval, Gonzalez e Osorio 2011].

### **Quantidade de Entradas na Análise de Variedades de Cana-de-Açúcar**

Analisando a quantidade de informações voltadas ao número de imagens utilizadas como entrada para os modelos de classificação, além da variação quanto ao número de variedades (2 a 25 variedades de cana-de-açúcar) o número de imagens aplicadas normalmente envolvem o uso de uma única data. A Tabela 3.5 resume dados sobre a discriminação de variedades de cana-de-açúcar utilizando diferentes tipos de sensores espectrais, incluindo câmeras digitais multiespectrais, sensores hiperespectrais, e produtos de satélites, quantidade de variedades, número de datas e acurácia.

Sensores hiperespectrais, como o Hyperion, demonstraram alta eficácia, apresentando acurácias entre 71% e 97%. Da mesma forma, sensores multiespectrais, como o Landsat e o Sentinel-2, alcançaram precisão de até 93,55%. No entanto, apesar dos bons resultados obtidos em estudos que utilizaram dados de uma única data ou de poucas datas, a inclusão de um maior número de datas permite capturar uma variação mais ampla de informações sobre as variedades. Isso contribui para o aprimoramento do processo de generalização dos modelos, facilitando a predição precisa de novas amostras que não fizeram parte do conjunto de treinamento inicial.

**Tabela 3.5:** *Estudos de Discriminação de Variedades de Cana-de-Açúcar Utilizando Sensores Espectrais*

Referência	Tipo	Dispositivo / Sensor	Q.Var	Dado / Q.Imagens	Acurácia
[Schmidt et al. 2000]	M	Digital Multispectral Video Camera	24	1	-
[Apan et al. 2004]	H	Hyperion	8	1	97% (5var), 74% (8var)
[Tisot 2005, Arnold 2006]	H	Hyperion	5	1	87,5%
[Demattê 2006]	M	Landsat ETM+	7 4	1	93,55%
[Everingham et al. 2007]	H	Hyperion	9	1	71-97%
[Rao 2008]	H	Hyperion + Espectroradiômetro	3	1*	86.7%
[Zimba 2008]	H	Espectroradiômetro	7	1	95%
[Sandoval, Gonzalez e Osorio 2011]	M	Landsat ETM+	7 2	2	66.8-80.8%%
[Neto et al. 2018]	H	Espectrômetro	4	48	87,5-100%(cv) 61,4-100%(ve)
[Fiorio 2019]	M	Sentinel-2	25	3	86%*
[Sharma 2020]	M	Sentinel-2 + drone	-	1	-
[Singh, Patel e Danodia 2022]	M	Landsat 8	2	68	-
[Sedighi et al. 2023]	M e H	Hyperion, Landsat ETM+	4 7	2 (1 H, 1 M)	82.0%

### 3.2.6 Considerações Finais

Este capítulo abordou o uso do sensoriamento remoto, com base em artigos da literatura que investigam a classificação de variedades agrícolas. A criação de novas variedades e híbridas tem gerado grande interesse entre pesquisadores e produtores, devido à necessidade de otimizar recursos e melhorar a predição de produtividade. Nesse contexto, o sensoriamento remoto surge como uma ferramenta importante, explorando diferentes métodos de sensoriamento remoto, utilizando imagens multiespectrais e hiperespectrais, bem como índices de vegetação como NDVI, NDRE e NDWI, que permitem acompanhar o crescimento das plantas e fornecer informações sobre seu estado fisiológico.

Embora as técnicas tradicionais de classificação ainda sejam amplamente utilizadas, o uso de redes neurais artificiais tem ganhado destaque, especialmente na análise de dados mais complexos, devido ao seu grande potencial em identificar padrões e interações entre variáveis que outras abordagens podem não captar. No entanto, ainda existem desafios, como a variação no estágio de desenvolvimento das plantas e as influências de fatores ambientais, que podem afetar a precisão das classificações.

Apesar desses desafios, as tecnologias de sensoriamento remoto continuam a evoluir, oferecendo novas possibilidades para aprimorar a acurácia e a eficiência na

classificação de variedades agrícolas.

# Método para Classificação de Variedades de Cana-de-açúcar

---

## 4.1 Método Proposto

Nesta seção é apresentado o método proposto para a classificação de variedades de cana-de-açúcar através de algoritmos de aprendizado profundo em conjunto com técnicas de aprendizado de máquina.

### 4.1.1 Arquitetura da Rede Neural Profunda

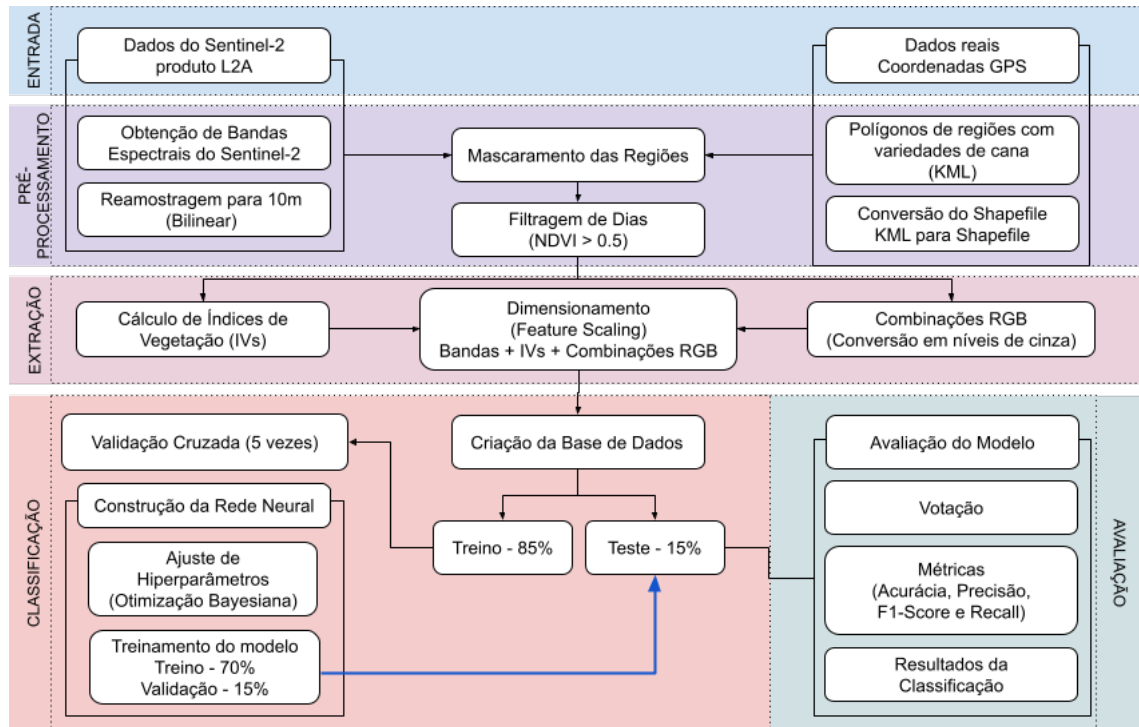
Nesta investigação, foram desenvolvidos dois tipos de arquiteturas de redes neurais, com variações na quantidade de entrada por modelo considerando três diferentes conjuntos de entrada, com o objetivo de avaliar a eficiência da classificação ao incorporar diversas características das variedades de cana-de-açúcar. O primeiro modelo utilizou como entrada apenas as bandas do sensor. O segundo modelo combinou bandas e índices de vegetação, enquanto o terceiro modelo integrou todas as características disponíveis, incluindo bandas, índices de vegetação e combinações RGB.

A decisão de construir um modelo utilizando exclusivamente as bandas do sensor foi fundamentada em estudos anteriores, os quais evidenciaram o potencial desses comprimentos de onda para diferenciar variedades de cana-de-açúcar em comparação com outras características.

A metodologia desenvolvida para o problema de classificar diferentes variedades de cana-de-açúcar está presente na Figura 4.1.

O primeiro modelo é fundamentado na arquitetura de Redes Multicamadas Perceptron (MLP), onde cada neurônio de uma camada está totalmente conectado a todos os neurônios da camada subsequente. Para a construção da arquitetura de rede neural, o processo de desenvolvimento do modelo foi estruturado através dos seguintes componentes:

**Figura 4.1:** Metodologia desenvolvida com o propósito de classificar variedades de cana-de-açúcar.



1. Definição de camadas ocultas: Foram desenvolvidas várias redes neurais densas, com variação de quatro a sete camadas ocultas, de acordo com a quantidade estabelecida em estudos anteriores [Kai, Oliveira e Costa 2022]. O número final de camadas foi selecionado com base na precisão alcançada pelo modelo, aplicando essa mesma configuração para a construção da rede cruzada.
2. Ajuste de hiperparâmetros: No ajuste de hiperparâmetros alguns parâmetros são testados a fim de otimizar o desempenho do modelo, como funções de ativação, inicializador de pesos, número de neurônios nas camadas ocultas e tamanho do lote.
3. Entrada: A rede utiliza como entrada um conjunto de valores que correspondem às características extraídas das bandas do sensor. Cada conjunto de dados é processado por uma arquitetura de rede neural profunda adequada à quantidade de entradas fornecidas.
4. Saída: A saída de cada rede é composta pelos neurônios de saída, que representam as sete variedades de cana-de-açúcar.
5. Validação (Treinamento): O desempenho do modelo durante o treinamento é avaliado por meio de validação cruzada, dividindo o conjunto de amostras em cinco partes. Em cada iteração, uma das partes é usada para validação, enquanto as demais são usadas para treinamento.
6. Validação (Teste): Para cada iteração da validação cruzada, a predição das amostras

do conjunto de teste é realizada para avaliar o desempenho do modelo.

7. Votação: Ao final do processo, realiza-se a etapa de votação, onde a classificação de uma amostra é determinada com base na maior frequência de saída da rede neural.

É fundamental destacar que, para a predição de cada modelo, os pixels pertencentes ao conjunto de teste são oriundos de datas distintas das dos pixels no conjunto de treinamento. Dessa forma, pixels com valores semelhantes não são utilizados simultaneamente no treinamento e no teste do modelo.

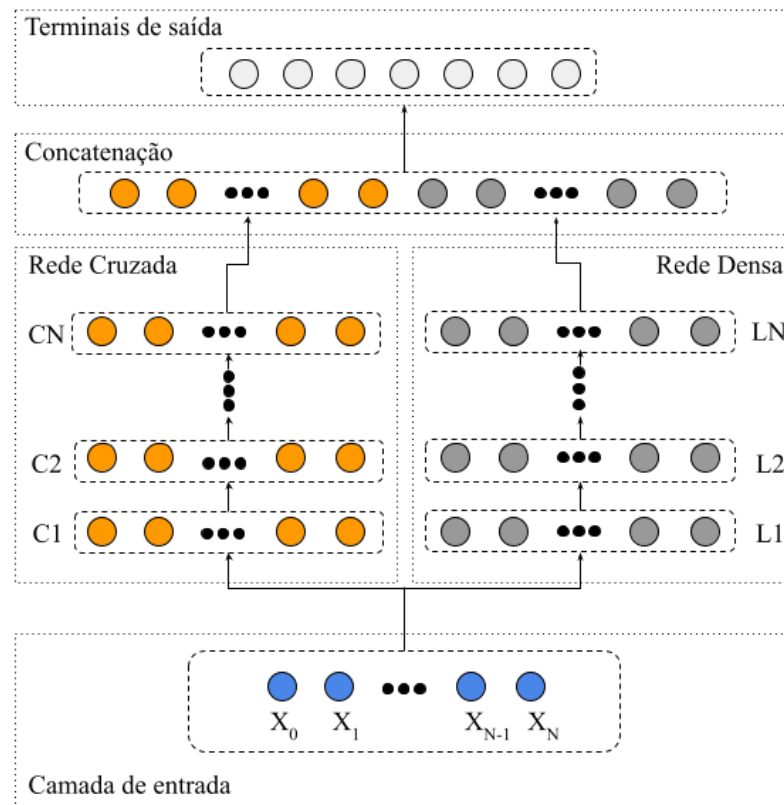
### 4.1.2 Arquitetura da Rede Neural Cruzada profunda

A arquitetura da rede neural cruzada e profunda (DCN) é baseada na rede densa, apresentando a diferenciação de possuir dois tipos de rede com processamento paralelo das entradas. O resultado de cada subrede é concatenado em uma camada combinada, a qual serve como entrada para a camada de saída. O número total de neurônios de saída é mantido em sete, correspondentes às diferentes variedades de cana-de-açúcar. Em função dos dados utilizados como entrada na rede, a sigla "S", correspondente à palavra "*Sugar*" em inglês, foi adicionada como sufixo à sigla DCN, denominando assim a rede como DCN-S. A estrutura formada pode ser visualizada na Figura 4.2.

A combinação dos dois modelos de rede neural tem como objetivo integrar o poder de processamento da rede neural densa com o cruzamento explícito de características proporcionado pelo modelo de rede cruzada. Essa abordagem visa a aprender interações complexas entre as características, potencializando a capacidade da rede para capturar e modelar relacionamentos detalhados nos dados.

Para o segundo modelo, a arquitetura da rede neural foi projetada utilizando as mesmas entradas aplicadas na rede densa inicial. Cada conjunto de entradas é processado separadamente por duas sub-redes distintas: uma "Rede Cruzada" e uma "Rede Profunda", ambas com o mesmo número de camadas. As saídas de cada sub-rede são então combinadas e concatenadas com o próximo conjunto de características, repetindo-se esse processo para cada conjunto adicional de características. Os conjuntos de características utilizados no modelo incluem: doze bandas espectrais do sensor Sentinel-2, treze índices de vegetação e dez combinações RGB derivadas das bandas do primeiro conjunto. O modelo final resulta da integração das redes cruzadas e profundas, combinando suas respectivas saídas com as características disponíveis no conjunto de dados do estudo.

Diversas configurações da rede cruzada foram elaboradas para identificar a arquitetura mais eficaz na discriminação entre variedades de cana-de-açúcar. Essas configurações variaram na inclusão ou exclusão de redes cruzadas, bem como na forma de concatenar as camadas, dependendo das características consideradas. A seleção da melhor



**Figura 4.2:** Modelo de rede neural cruzada alimentado apenas por um conjunto de características com concatenação das saídas da rede cruzada e da rede densa.

configuração baseou-se na capacidade de maximizar a acurácia do modelo na diferenciação entre as diferentes variedades.

O processo de construção do modelo de rede neural seguiu as etapas descritas abaixo:

1. **Entrada:** O modelo recebe três conjuntos de dados de entrada distintos: o primeiro conjunto consiste em 12 bandas do sensor Sentinel-2; o segundo, em 13 índices de vegetação; e o terceiro, em 10 combinações RGB derivadas das bandas espectrais do primeiro conjunto.
2. **Rede Cruzada:** Cada um dos conjuntos de dados de entrada é processado por uma Rede Cruzada específica, projetada para capturar interações não-lineares entre as características.
3. **Rede Profunda:** Paralelamente, cada conjunto de dados é também processado por uma Rede Profunda correspondente, focada em capturar padrões complexos e representações de alto nível das características.
4. **Combinação:** As saídas geradas pela Rede Cruzada e pela Rede Profunda são combinadas e utilizadas como entrada para a próxima camada. Esse processo de combinação é repetido para cada conjunto adicional de características.

5. **Saída:** A combinação das saídas das sub-redes é usada como entrada para a camada final, que gera a predição da rede neural.
6. **Votação:** Ao final, a classificação de uma amostra é determinada com base na maior frequência de saída da rede neural, utilizando uma abordagem de votação para melhorar a robustez do modelo.

O treinamento do modelo foi realizado ao longo de 1000 épocas, utilizando o critério de paciência (early stopping) com limite de 10 épocas sem melhora significativa na acurácia. Para validação, foi empregada a técnica de validação cruzada k-fold com  $k=5$ , garantindo uma avaliação robusta do desempenho do modelo. Além disso, a eficácia do modelo foi testada em um conjunto de dados externo ao treinamento, abrangendo dias distintos e diferentes locais de coleta, assegurando a generalização do modelo para novos cenários e condições ambientais.

## Estudo de Caso – Design de Experimento

---

Com base na literatura, foi desenvolvida uma metodologia para a discriminação varietal de cana-de-açúcar utilizando redes neurais profundas. Esta abordagem é escolhida devido às características inerentes do modelo, como a capacidade de generalização de dados e de aprendizado, bem como a flexibilidade na construção de camadas e o poder de processamento.

### 5.1 Materiais e Métodos

Esta seção explorará os materiais e métodos empregados no desenvolvimento da metodologia para a classificação de variedades de cana-de-açúcar por meio do uso de modelos computacionais, como redes neurais profundas, integrando técnicas de aprendizado de máquina e sensoriamento remoto.

A implementação dos códigos, definição da base de dados, bem como as fases de treinamento e testes dos modelos classificatórios, foram desenvolvidas utilizando a linguagem Python em conjunto com o ambiente de desenvolvimento integrado Spyder.

#### 5.1.1 Variedades de Cana-de-açúcar

Neste estudo foram utilizadas sete variedades de cana-de-açúcar, com a disponibilização de dados a partir do apoio de parceiros da Ridesa (Rede Interuniversitária para o Desenvolvimento Sucroalcooleiro) em parceria com a Escola de Agronomia da UFG, lançadas pelas seguintes instituições:

- UFAL (Universidade Federal de Alagoas): variedade RB92579;
- UFG (Universidade Federal de Goiás): variedades RB034045 e RB064292;
- UFPR (Universidade Federal do Paraná): variedade RB966928;
- UFSCAR (Universidade Federal de São Carlos): variedade RB975201;
- UFV (Universidade Federal de Viçosa): variedade RB867515 e RB988082;

Para o estudo, diferentes regiões com cultivo de cana-de-açúcar no estado de Goiás serviram como fonte de dados. Inicialmente, as coordenadas dos locais de interesse foram

obtidas com o auxílio de aparelhos GPS (Sistema de Posicionamento Global) portáteis em unidades produtoras parceiras da RIDESA. Dentre as variedades escolhidas, três delas (RB867515, RB92579 e RB966928) correspondem às mais cultivadas no país, de acordo com a safra 2021/2022 [Junior et al. 2023]. As características de cada variedade, referentes ao ciclo de colheita da cana-de-açúcar, estão disponíveis para visualização na Tabela 5.1.

**Tabela 5.1:** *Informações de variedades de cana-de-açúcar utilizadas no estudo e o ciclo de colheita no estado de Goiás.*

Variedade	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
RB034045							X	X	X	X		
RB064292						X	X	X				
RB92579				X	X	X	X					
RB867515							X	X	X	X	X	
RB966928				X	X	X						
RB975201							X	X	X			
RB988082						X	X	X	X			

A pesquisa contou com um total de 23 áreas de regiões do estado de Goiás, apresentadas na Tabela 5.2, com a localidade de cada área investigada. Devido a alguns locais possuírem área insuficiente para a obtenção de dados advindos de sensores de satélite gratuitos, estes foram desconsiderados. Por esse motivo, um número reduzido de regiões para algumas variedades estudadas foi considerado. Locais dos quais as coordenadas fornecidas resultaram em amostras com sobreposições de pixels entre variedades também foram descartados.

**Tabela 5.2:** *Locais selecionados para coleta de dados.*

Variedade	Localidade	Variedade	Localidade
RB034045	Cooper-Rubi Jalles Machado	RB064292	Bunge Tropical Goiasa Jalles Machado
RB92579	Cooper-Rubi Goiasa São Francisco SJC Serranópolis	RB867515	Atvos Unid. Rio Claro Cooper-Rubi Jalles Machado Serranópolis
RB966928	Atvos Unid. Água Emendada Cooper-Rubi Goiasa Jalles Machado	RB975201	Floresta Jalles Machado
RB988082	Cooper-Rubi Denusa Jalles Machado Serranópolis		

Selecionado os locais, a próxima etapa compreende em transformar as coordenadas adquiridas pelo GPS portátil para uma representação vetorial através dos valores de latitude e longitude padrão do Google Earth para arquivos do tipo Shapefile (SHP), mantendo as informações geográficas dos locais. Para isso, inicialmente as coordenadas são inseridas manualmente para a plataforma do Google Earth de cada região estudada e descarregadas para um arquivo contendo linguagem de marcação (Keyhole Markup Language (KML)). Após, o arquivo em formato KML é transformado para SHP com meio do software QGIS para adaptar os dados georreferenciados ao mesmo sistema de coordenadas das imagens do Sentinel-2.

### 5.1.2 Imagens


O instrumento multiespectral Sentinel-2, lançado em 2015, possui um total de 13 bandas espectrais na parte do espectro visível, NIR (*Near InfraRed*) e SWIR (*Short Near Infrared*), com resolução espacial de 10m nas bandas do espectro visível e NIR (B2, B3, B4 e B8), 20m (B5, B6, B7, B8A, B11 e B12) e 60m (B1 - Aerossol, B9 - vapor de água e B10 - Cirrus), disponível para fins de visualização na Tabela 5.3. Os produtos Nível-1C e Nível-2A são ortorretificados com a disponibilização de imagens divididas em blocos de 100 km na projeção UTM/WGS84 [ESA 2015]. Para os experimentos foram utilizadas imagens do Sentinel-2, nível 2A, com valores de pixels fornecidos em reflectância de superfície (do inglês *Bottom of Atmosphere* - BOA).

Banda	Resolução (m)	Comprimento de Onda (nm)	Descrição
1	60	443	Aerossol costeiro
2	10	490	Azul
3	10	560	Verde
4	10	665	Vermelho
5	20	705	Borda vermelha 1 (RE)
6	20	740	Borda vermelha 2 (RE)
7	20	783	Borda vermelha 3 (RE)
8	10	842	Infravermelho próximo (NIR)
8A	20	865	Borda vermelha estreita
9	60	945	Vapor d'água
10	60	1375	Cirrus
11	20	1610	Infravermelho de onda curta 1 (SWIR)
12	20	2190	Infravermelho de onda curta 2 (SWIR)

**Tabela 5.3:** Bandas do Sentinel-2

As imagens adquiridas no estudo foram obtidas pela biblioteca do *SentinelHub*, através de serviços de download de imagens com o uso de lotes de datas, permitindo assim o download de um grande volume de dados em um intervalo de tempo predefinido. Dessa

forma, por meio dos serviços da plataforma, polígonos derivados das coordenadas de cada área selecionada serviram de entrada para obtenção de imagens das sete variedades de cana-de-açúcar estudadas. Somente doze bandas foram utilizadas, devido a banda Cirrus (B10) não estar disponível em reflectância de superfície. Como exemplo, na Figura 5.1 é possível visualizar cada banda do sensor do Sentinel-2 produto 2A representada por diferentes imagens, com valores distintos de reflectância. Dessa forma, para cada região e data adquirida, foram obtidas doze imagens.



**Figura 5.1:** *Bandas do sensor do Sentinel-2 produto 2A traduzida em diferentes imagens.*

Para construir a base de dados para o treinamento dos modelos de classificação, foram selecionados de dois a quatro locais para cada variedade, conforme a disponibilidade de áreas cultivadas com cana-de-açúcar. O intervalo de datas utilizado foi de 1º de janeiro de 2019 a 31 de dezembro de 2021. Considerando que os produtos Sentinel-2 nos níveis 1C e 2A possuem aproximadamente 1.7 GB (contendo as bandas do Sentinel-2 em imagens separadas), apenas a área do polígono de cada local com talhões das variedades em desenvolvimento foi considerada para download, agilizando assim o processamento e a extração dos dados.

### 5.1.3 Seleção de Datas

A base do estudo é composta por pixels, onde cada pixel corresponde a uma área de 10m por 10m, referente a maior resolução espacial disponível pelo Sentinel-2.

Imagens derivadas de outras bandas são reamostradas para a melhor resolução do sensor, padronizando o tamanho por pixel para cada comprimento de onda.

Com base em investigações anteriores utilizando imagens do Sentinel-2 para discriminar entre pixels de quatro variedades de cana-de-açúcar [Kai et al. 2021], foi observada pouca variação na precisão ao aplicar diferentes métodos de reamostragem. Isso indica que o impacto dos métodos de reamostragem na discriminação e classificação da cana-de-açúcar é mínimo. Portanto, para este estudo, optou-se pelo uso do método de reamostragem bilinear para processar as imagens das bandas do Sentinel-2.

Para filtrar os dias com ocorrência de nuvens, períodos pós-colheita ou fases iniciais da cana-de-açúcar que apresentem solo exposto, foi calculado o NDVI, considerando apenas as datas com NDVI médio por local maior ou igual a 0,5. Os dias selecionados para cada variedade de cana-de-açúcar, em cada localidade, estão apresentados na Tabela 5.4. Para manter a diversidade de datas e a variabilidade dos estágios de crescimento das variedades de cana-de-açúcar, os pixels foram escolhidos aleatoriamente, assegurando uma quantidade igual de amostras para cada classe e garantindo, assim, uma base de dados balanceada. Além disso, a tabela fornece informações sobre a quantidade de imagens de cada variedade utilizadas para extração de informações após serem submetidas ao cálculo do NDVI. Para maximizar o número de amostras por variedade, foram considerados dois ou mais locais para cada variedade.

VAR	Quantidade de Dias						
	RB966928	RB867515	RB92579	RB988082	RB034045	RB064292	RB975201
Local 1	120	114	85	98	123	103	83
Local 2	115	84	108	107	114	138	107
Local 3	116	109	97	109	-	53	-
Local 4	94	92	140	140	-	-	-
Treino	378	339	365	385	201	249	161
Teste	67	60	65	69	36	45	29
<b>Total</b>	<b>445</b>	<b>399</b>	<b>430</b>	<b>454</b>	<b>237</b>	<b>294</b>	<b>190</b>

**Tabela 5.4:** *Quantidade de dias selecionados para cada variedade a partir do cálculo do NDVI.*

Após a seleção das imagens por data, os valores de cada pixel da imagem são adicionados a uma linha da matriz, cujas colunas são compostas pelas características dos pixels, inicialmente representadas pelas bandas do sensor, correspondendo a diferentes comprimentos de onda. A partir dessas bandas, derivam-se índices de vegetação e combinações RGB. Pixels sem valores, ou seja, aqueles pertencentes a áreas fora do polígono de interesse, recebem o valor NaN (*Not a Number*, indicando valor numérico indefinido ou irrepresentável) e são removidos da análise.

Informações adicionais sobre os pixels que compõem a base de dados utilizada como entrada para os modelos de classificação podem ser conferidas na Tabela 5.5, que

Variedade	Localidade	Q. Pixeis (Total)	NDVI (M)	NDVI (DP)
RB966928	Cooper-Rubi	424	0,6675	0,1113
	Atvos Unid. Água Emendada	1182	0,6846	0,1480
	Goiasa	1665	0,6886	0,0889
	Jalles Machado	140	0,7201	0,0984
RB867515	Atvos Unid. Rio Claro	1752	0,6381	0,1089
	Jalles Machado	151	0,6469	0,1032
	Serranópolis	1531	0,6511	0,1161
	Cooper-Rubi	76	0,7045	0,1105
RB92579	Goiasa	943	0,6426	0,1221
	São Francisco SJC	968	0,6543	0,1110
	Serranópolis	1925	0,6620	0,1166
	Cooper-Rubi	1069	0,7176	0,1092
RB988082	Jalles Machado	842	0,6752	0,1228
	Cooper-Rubi	64	0,6436	0,1106
	Denusa	2865	0,7162	0,1199
	Serranópolis	110	0,6662	0,1260
RB064292	Goiasa	682	0,6897	0,1131
	BP Bunge Tropical	12	0,7288	0,1022
	Jalles Machado	77	0,5883	0,1411
RB034045	Cooper-Rubi	218	0,6938	0,1049
	Jalles Machado	55	0,6785	0,1087
RB975201	Jalles Machado	209	0,7046	0,1109
	Floresta	78	0,6793	0,1362

**Tabela 5.5:** Tabela de dados das variedades investigadas, incluindo a localidade, quantidade de pixels adquiridos por local e métricas relacionadas ao Índice de Diferença Normalizada (NDVI) como a média (M) dos valores dos pixels e desvio padrão (DP).

apresenta dados sobre as variedades de cana-de-açúcar e suas respectivas localidades. Observa-se variabilidade no NDVI médio e no desvio padrão entre as diferentes combinações de variedade e localidade, o que indica diferenças nas condições de vegetação e saúde das plantas, dependendo do local e do tipo de planta analisado.

#### 5.1.4 Extração de Características

Distinguir entre variedades de cana-de-açúcar baseando-se apenas em comprimentos de onda do sensor pode ser desafiadora. Portanto, a incorporação de índices de vegetação e combinação entre bandas pode fornecer fontes adicionais sobre as características das variedades. Deste modo, os experimentos são construídos com base em três conjuntos distintos de dados: valores de cada banda do sensor do Sentinel-2 produto 2A, treze índices de vegetação, calculados por modelos matemáticos por uso de bandas do sensor, e dez combinações RGB entre bandas do sensor, criando amostras com 35 características (Tabela 5.6) para a finalidade de distinguir variedades de cana-de-açúcar.

Para evitar a repetição de informações associadas a cada pixel, combinações RGB adquirida foram convertidas em níveis de cinza, transformando os valores das três bandas usadas para construir a combinação em um único valor de brilho.

É possível observar que a quantia selecionada para formar a base de dados foi influenciada pelo menor número adquirido de variedades como a RB034045 e RB975201, com poucos locais disponibilizados, além de talhões consideravelmente menores do que de outras variedades.

Características					
Bandas do Sensor		Índices de Vegetação		Combinações RGB	
B1	B7	CHL-RE	NDMI	C1(B4,B3,B2)	C6(B4,B3,B1)
B2	B8	EVI2	NDVI	C2(B8,B4,B3)	C7(B8,B6,B4)
B3	B8A	GNDVI	NDWI	C3(B12,B8,B4)	C8(B8,B11,B4)
B4	B9	mARI	PSSRb1	C4(B11,B8,B2)	C9(B8,B11,B12)
B5	B11	mCARI	SAVI	C5(B12,B11,B2)	C10(B11,B8,B3)
B6	B12	MSI	SIPI		
		NDCI			

**Tabela 5.6:** Características de cada amostra pertencente à base de dados do estudo.

Para os experimentos foram empregados treze índices de vegetação encontrados para diferentes propósitos na literatura envolvendo plantas, disponíveis na Tabela 5.7. Entre os índices incluídos temos o Índice de Vegetação por Diferença Normalizada (NDVI) [Jr et al. 1974] aplicado rotineiramente na avaliação da vegetação, Índice de Vegetação por Diferença Normalizada na banda do Verde (GNDVI) [Gitelson, Kaufman e Merzlyak 1996], Índice de Água por Diferença Normalizada (NDWI) [Gao 1996], Índice de Umidade por Diferença Normalizada (NDMI) [Klemas e Smart 1983], Índice de Vegetação Aprimorado (EVI2) [Huete et al. 1997] e Índice de Vegetação Ajustado para o Solo (SAVI) [Huete 1988].

Além desses, foram adicionados índices associados à análise de pigmentos e clorofila como o Índice de Clorofila por Diferença Normalizada (NDCI) [Mishra e Mishra 2012], Proporção simples específica do pigmento para clorofila B (PSSRb1), Índice de Pigmento Insensível à Estrutura (SIPI) [Peñuelas et al. 1997], Índice de refletância de antocianina modificado (mARI) [Gitelson, Keydan e Merzlyak 2006] e o Índice de Vegetação de Clorofila Borda Vermelha (CHL-REDEDGE) [Escadafal, Belghith e Ben-Moussa], com propósito verificar a influência de concentrações de pigmentos na diferenciação entre variedades.

**Tabela 5.7:** Índices de vegetação foram utilizados nos estudos para destacar as diferenças entre as variedades de cana-de-açúcar.

<b>VIs</b>	<b>Fórmula</b>	<b>Aplicação / Parâmetro Biológico</b>
CHL-REDEDGE	$\frac{B7^{(-1)}}{B5}$	Vegetation - Clorofila
EVI2	$2.4 * \frac{(B8 - B4)}{(B8 + B4 + 1.0)}$	Vegetação - Biomassa
GNDVI	$\frac{B8 - B3}{B8 + B3}$	Clorofila
mARI	$((\frac{1}{B3}) - (\frac{1}{B5})) * B7$	Clorofila
mCARI	$((B5 - B4) - 0.2(B5 - B3))(\frac{B5}{B4})$	Vegetação - Clorofila
MSI	$\frac{B11}{B8}$	Vegetação - Água
NDCI	$\frac{B5 - B4}{B5 + B4}$	Clorofila
NDMI	$\frac{B8 - B11}{B8 + B11}$	Conteúdo de Água
NDVI	$\frac{B8 - B4}{B8 + B4}$	Vegetação - Biomassa
NDWI	$\frac{B3 - B8}{B3 + B8}$	Conteúdo de Água
PSSRb1	$\frac{B8}{B4}$	Clorofila
SAVI	$\frac{B8 - B4}{B8 + B4 + L}(1 + L)$	Vegetação - Biomassa
SIPI	$\frac{B8 - B1}{B8 - B4}$	Clorofila


Optou-se pela utilização de diversos índices de vegetação devido às diferentes características que a planta apresenta em cada fase de crescimento. Por exemplo, uma amostra de cana-de-açúcar na fase de perfilhamento exibirá um valor de NDVI diferente de uma que esteja na fase de maturação. Essas variações se baseiam nas necessidades específicas da planta em cada ciclo, na absorção e reflexão de luz, e na atividade de clorofila nas folhas.

### 5.1.5 Base de dados

Para selecionar datas distintas para as amostras de entrada nos modelos de classificação e para avaliar cada modelo, os dias foram divididos entre aqueles para

compor a base de dados de treino e validação, e os dias para a base de teste. A separação foi feita com 85% dos dados reservados para treinamento e validação, e 15% dos dados para o conjunto de teste. Em cada base, foi realizada uma divisão aleatória com uma quantidade balanceada de pixels para cada classe. Para a proporção da base de dados, considerou-se 70% para a construção da rede neural e refinamento de hiperparâmetros, e 15% para validação. Dada a diferença de área de alguns locais fornecidos, a quantidade de pixels por classe foi reduzida para manter o banco de dados construído balanceado.

A divisão das amostras de dados resultou em um total de 168.000 exemplos (pixels), dos quais 142.800 pixels pertencentes à base de treino e validação, com 20.400 pixels por variedade. Para a base de teste, foram alocados 25.200 pixels (3.600 por variedade de cana-de-açúcar), considerando dias diferentes por local para os pixels da base de treino em relação à base de teste.



**Figura 5.2:** Gráfico de caixas contendo a distribuição dos valores de reflectância das sete variedades de cana-de-açúcar em diferentes bandas espectrais do Sentinel-2.

Em concordância com a distribuição dos valores de reflectância dos pixels das variedades de cana-de-açúcar, as bandas espectrais no infravermelho próximo (B7 a B8A) são mais altas, com maior dispersão dos dados e presença de outliers, afetando diretamente a reflectância nessa faixa do espectro (Figura 5.2). Além disso, as bandas do espectro visível (B1 a B4) exibem menor variabilidade nos valores de reflectância, indicando resposta espectral mais homogênea nessa região do espectro.

### 5.1.6 Ajuste de Hiperparâmetros

Para ajustar os hiperparâmetros de cada modelo, foi aplicada a otimização bayesiana. Em comparação com outras técnicas existentes, como a busca em grade (*Grid*

*Search*), que testa todas as combinações previamente fixadas, e a busca aleatória (*Random Search*), que define valores dentro de intervalos a serem testados aleatoriamente a cada iteração, a otimização bayesiana permite uma pesquisa de hiperparâmetros mais eficiente, utilizando avaliações anteriores para guiar o processo.

A escolha dos parâmetros dos modelos foi baseada na maior precisão obtida após as execuções para cada configuração de parâmetros. Todos os parâmetros testados estão dispostos na Tabela 5.8.

<b>Classificador</b>	<b>Parâmetro</b>	<b>Valores</b>
kNN	n_vizinhos	1 à 20
	pesos	uniforme, distância
	algoritmo	auto, ball_tree, kd_tree, brute)
	p (distância)	(manhattan, euclidiana)
Floresta Aleatória	n_estimadores	10 à 100
	max_profundidade	2 à 50
	max_características	1 à 13
	min_samples_split	2 à 11
	min_samples_leaf	1 à 11
SVM	kernel	linear, polynomial, sigmoid, rbf
	C	0.01, 0.1, 1, 10, 100, 1
Rede Neural	função de ativação	relu, tanh, elu, selu
	kernel_initializer	glorot_normal, glorot_uniform, he_normal, he_uniform
	neurônios	16, 32, 64, 128
	batch_size	8, 16

**Tabela 5.8:** *Parâmetros dos Classificadores Testados*

Devido ao fato de que a área captada pelo GPS portátil para algumas variedades de cana-de-açúcar ser inferior a 10 m<sup>2</sup>, e considerando o tamanho por pixel do produto Sentinel-2, as Redes Neurais Convolucionais não foram aplicadas ao estudo. Essa decisão foi tomada devido à limitação do tamanho das imagens de entrada no modelo, o que impossibilitou o desenvolvimento de uma rede mais profunda, além da disponibilidade limitada de amostras.

Dentre os classificadores testados, as redes neurais foram analisadas com diferentes números de camadas, verificando a precisão com a adição de camadas através de uma validação cruzada de 5-folds no conjunto de dados de treinamento. Foi definido o número de 1000 épocas para cada rede testada, compondo a camada de saída com sete neurônios, de acordo com o número de classes, com predição do conjunto de teste ao final de cada iteração, para uma avaliação robusta da performance do modelo.

## Resultados

---

Nesta seção, são apresentados os resultados das investigações conduzidas para a classificação de variedades de cana-de-açúcar em fase de crescimento, em locais específicos no estado de Goiás. As coordenadas geográficas dos campos experimentais foram disponibilizadas por parceiros da Rede Interuniversitária para o Desenvolvimento do Setor Sucroenergético (RIDESA), em colaboração com a Faculdade de Agronomia da Universidade Federal de Goiás.

Nas duas investigações iniciais, os conjuntos de dados de treinamento e teste foram formados sem uma separação explícita por datas, ou seja, os pixels foram distribuídos aleatoriamente entre os conjuntos. Isso permitiu uma análise preliminar da capacidade dos modelos em diferenciar as variedades, mas não considerou a variabilidade temporal entre as coletas. Para a última investigação, foi adotada uma abordagem mais ampla na composição dos conjuntos de dados. Pixels utilizados para o treinamento do modelo foram segregados dos pixels destinados ao teste, garantindo que as amostras do conjunto de teste fossem provenientes de datas diferentes daquelas utilizadas no treinamento. Esta separação temporal teve como objetivo reduzir a influência de dados semelhantes entre as bases, promovendo uma avaliação mais robusta e precisa do modelo, evitando problemas de sobreajuste (overfitting) e assegurando a generalização dos resultados.

Os resultados obtidos demonstram a importância de se considerar a variabilidade temporal na formação das bases de dados para a tarefa de classificação. A separação explícita entre conjuntos de treino e teste, conforme implementada na última investigação, forneceu uma medida mais realista da capacidade do modelo em distinguir as variedades de cana-de-açúcar em diferentes condições de desenvolvimento. Além disso, essa abordagem permitiu uma análise mais aprofundada dos fatores que influenciam a acurácia dos modelos de classificação, contribuindo para o aprimoramento das técnicas de monitoramento e manejo agrícola.

## 6.1 Efeitos da Reamostragem na Classificação de Variedades de Cana de Açúcar

O estudo inicial [Kai et al. 2021] investigou a classificação de três variedades de cana-de-açúcar (RB92579, RB966928 e RB988082), considerando quatro datas por polígono, como observado na Tabela 6.1, com imagens entre os meses de maio e junho de 2020, englobando o estágio fenológico de crescimento e maturação. Esses períodos de desenvolvimento do ciclo da cana-de-açúcar foram escolhidos dada a maior concentração de clorofila, permitindo investigar índices voltados a esse pigmento.

### 6.1.1 Preparação da Base de Dados

Foram utilizadas imagens do Sentinel-2, ortorretificadas, abrangendo uma área de 100 m<sup>2</sup>, na projeção UTM/WGS84, com valores de pixels fornecidos em reflectâncias de topo da atmosfera (TOA). Do total de treze bandas, apenas as bandas com resolução de 10 m e 20 m foram investigadas, incluindo assim as bandas do espectro visível (B02 - azul, B03 - verde, B04 - vermelho), banda do infravermelho próximo e banda da borda vermelha (B8A).

**Tabela 6.1:** *Datas obtidas para o estudo de acordo com a variedade, dia, sigla e localidade*

Variedade	Data	Sigla	Localidade
RB92579	02 e 27 de maio de 2020 16 e 31 de julho de 2020	KFF	Goiasa
	10 e 30 de maio de 2020 14 de junho de 2020 19 de julho de 2020	KCE	Serranópolis
RB966928	02 e 27 de maio de 2020 16 e 31 de julho de 2020	KFF	Goiasa
	30 de maio de 2020 24 de junho de 2020 14 e 24 de julho de 2020	KCF	Água Emendada
RB88082	02, 17 e 27 de maio de 2020 16 de junho de 2020	KEF	Denusa
	02, 12 e 27 de maio de 2020 01 de junho de 2020	LGJ	Jalles Machado

Para o processo de reamostragem das imagens foram testados cinco métodos (vizinho mais próximo, bilinear, cúbico, Lanczos e Gauss) para as bandas 5 e 8A do

Sentinel-2, adaptando a resolução espacial de 20 metros para 10 metros, possibilitando assim o cálculo de índices de vegetação. Como resultado, foram geradas dez novas imagens reamostradas, sendo cinco imagens da banda 5 e cinco imagens da banda 8A.

As coordenadas fornecidas por parceiros da Ridesa, em conjunto com a Escola de Agronomia da UFG, relativas aos locais de cultivo das variedades de cana-de-açúcar, inicialmente adquiridas por meio de GPS portátil, foram convertidas em arquivos do tipo *Shapefile* utilizando o software QGIS. Essa conversão teve como objetivo adaptar as coordenadas ao sistema de referência utilizado nas imagens Sentinel-2 (EPSG: 32721). Cada arquivo *shapefile* serviu como máscara para seleção da área de interesse nas imagens. Esta etapa é realizada antes do cálculo dos valores dos índices de vegetação devido ao processamento necessário ser mais rápido que a imagem com tamanho original. A implementação dos códigos para a reamostragem das imagens, a seleção das regiões de interesse (ROI) por *shapefile* e a aplicação dos modelos classificatórios foi realizada na linguagem Python.

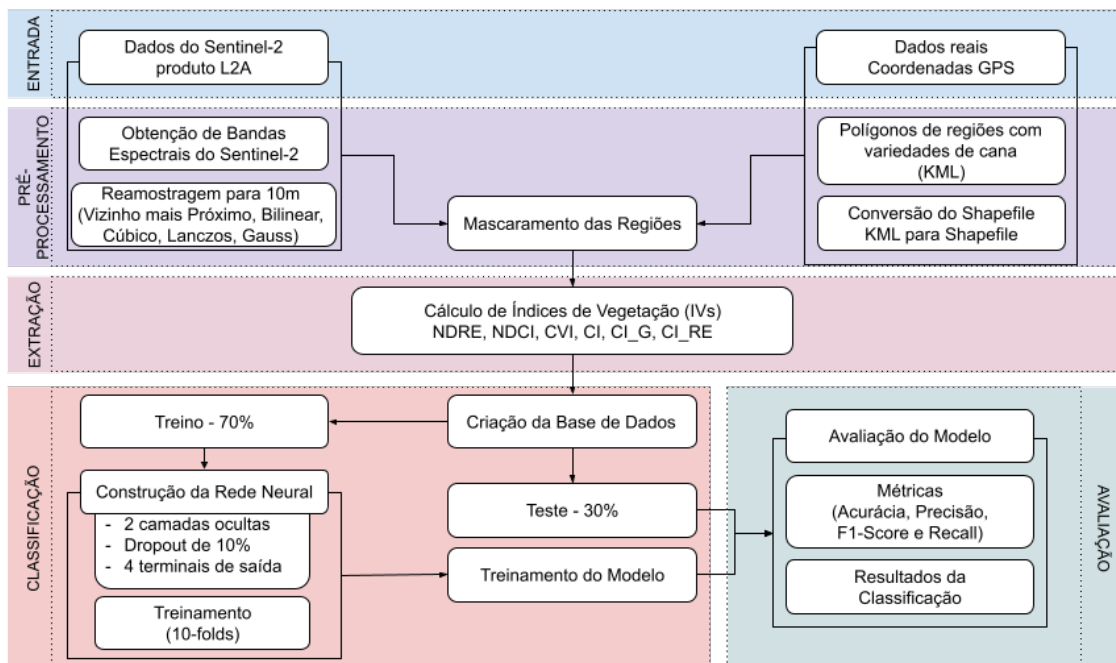
O conjunto de dados incluiu valores de seis índices de vegetação relacionados à clorofila (NDRE, NDCI, MCARI, CVI, CI green e CI red\_edge). Considerando a quantidade de pixels utilizados para os cálculos, suas características formaram uma estrutura de tabela com um total de 12.000 amostras. Cada variedade de cana-de-açúcar contribuiu com 4.000 pixels, provenientes de duas áreas distintas, resultando em 500 pixels de cada imagem (quatro imagens em datas diferentes totalizando 2.000 pixels).

Outras coberturas adicionaram mais 12.000 amostras ao banco de dados para a segunda investigação. Também foi testada a eficiência dos modelos classificatórios utilizando o valor médio de cada pixel, baseado nas quatro datas coletadas, resultando em 1.000 pixels por variedade.

Para a divisão dos dados de treino e teste, os classificadores foram treinados com 70% dos dados e testados com os 30% restantes, com validação cruzada de 10 vezes para avaliação dos modelos de classificação. Entre os classificadores usados foram incluídos o kNN, SVM e Floresta Aleatória. A metodologia utilizada está disponível para fins de visualização na Figura 6.1.

### 6.1.2 Resultados do Estudo

Os resultados demonstraram variação mínima na precisão da classificação entre os diferentes métodos de reamostragem aplicados às imagens do Sentinel-2, indicando pouco impacto na discriminação das variedades de cana-de-açúcar. Para os três métodos testados, a precisão obtida com o classificador kNN e SVM foi superior em todos os métodos, com o modelo de Floresta Aleatória apresentando um desempenho inferior. A Tabela 6.2 traz



**Figura 6.1:** Metodologia para discriminação entre pixels de três variedades de cana-de-açúcar por uso de seis índices de vegetação relacionados à análise de clorofila.

os resultados de cada método de reamostragem aplicado na classificação de três variedades de cana-de-açúcar.

**Tabela 6.2:** Discriminação de cana-de-açúcar por pixel por diferentes métodos de reamostragem.

Classificador	Vizinho mais próximo	Bilinear	Cúbico	Lanczos	Gauss
k-NN	84.5%	86.2%	83.9%	86.9%	<b>87.8%</b>
SVM	86.2%	87.1%	85.0%	85.0%	87.0%
RF	72.0%	71.0%	72.0%	70.0%	71.0%

Utilizando a média de pixels de quatro datas diferentes considerando os meses entre maio a junho, a precisão da classificação aumentou, especialmente para kNN, que alcançou mais de 96% de precisão em todos os métodos de reamostragem, conforme a Tabela 6.3.

A diferenciação entre pixels de cana-de-açúcar e não cana-de-açúcar nessa investigação inicial apresentou resultados superiores para o classificador SVM, com mais de 98% de acurácia consistente em todos os métodos de reamostragem.

**Tabela 6.3:** *Discriminação de cana-de-açúcar pela média dos valores de pixel por diferentes métodos de reamostragem.*

Classificador	Vizinho mais próximo	Bilinear	Cúbico	Lanczos	Gauss
k-NN	98.2%	98.6%	98.6%	98.8%	96.9%
SVM	98.6%	<b>99.1%</b>	98.9%	98.9%	98.1%
RF	87.0%	86.0%	87.0%	88.0%	87.0%

A partir dos resultados, a variação mínima na precisão entre os diferentes métodos de reamostragem sugere que técnicas de reamostragem mais simples podem ser suficientes para a adequação de imagens advindas de sensores para o posterior cálculo de índices de vegetação, reduzindo a complexidade computacional sem comprometer o desempenho.

Dessa maneira, os resultados demonstraram o potencial para a separação de variedades de cana-de-açúcar por meio de modelos tradicionais aplicados ao problema de classificação, propiciando a adição de outros modelos à tarefa, como as redes neurais artificiais, com o objetivo de melhorar a precisão da classificação de variedades de cana-de-açúcar.

## 6.2 Aprendizado Profundo Aplicado na Classificação de Variedades de Cana-de-açúcar

Em outra investigação [Kai, Oliveira e Costa 2022], além das três variedades investigadas anteriormente ((RB92579, RB966928 e RB988082), teve-se a adição de mais uma variedade de cana-de-açúcar no estudo, a variedade RB867515, para avaliar a eficiência dos métodos de classificação, foram aplicados o modelo kNN, Floresta Aleatória, SVM e Redes Neurais Artificiais (RNA).

Assim como no estudo anterior, foram selecionados dois locais para cada variedade de cana-de-açúcar. Para cada polígono, foram adquiridas cinco imagens, totalizando dez imagens por variedade, no período entre 2019 e 2020, abrangendo as fases de crescimento e maturação. A seleção dos dias foi realizada de maneira visual, visando excluir áreas com interferência de nuvens ou sombras. Devido a condições climáticas adversas e ao período de colheita, os dados de algumas variedades foram obtidos em anos diferentes (veja em Figura 6.4).

Nos experimentos, foram utilizadas imagens ortorretificadas do Sentinel-2, nível 2A, com projeção UTM/WGS84, apresentando valores de pixels fornecidos em reflectâncias de superfície (*Bottom of Atmosphere* - BOA). As imagens eram compostas por treze bandas, com resoluções variando entre 10 m e 60 m. As imagens empregadas no estudo foram obtidas por meio da plataforma EOS LandViewer, com os locais selecionados

Variedade	Data	Sigla	Data	Sigla
RB988082	18/03/20, 02/04/20, 27/04/20, 02/05/20, 22/05/20	22KEG/22KEF	08/05/19, 18/03/20, 02/04/20, 12/05/20, 27/05/20	22LGJ
RB867515	06/03/20, 10/04/20, 10/05/20, 30/05/20, 14/06/20	22KCE	02/04/20, 02/05/20, 22/05/20, 01/06/20, 06/07/20	22LGH
RB92579	05/02/19, 26/04/19, 06/05/19, 21/05/19, 20/06/19	22KCE	2/04/20, 27/04/20, 12/05/20, 27/05/20, 16/06/20)	22KFF
RB966928	16/03/20, 31/03/20, 20/04/20, 10/05/20, 30/05/20	22KCF	02/04/20, 12/05/20, 27/05/20, 11/06/20, 16/07/20	22KFF

**Tabela 6.4:** *Datas de coleta das imagens para os experimentos.*

para análise compreendendo quatro variedades de cana-de-açúcar, todas situadas no estado de Goiás.

As coordenadas de cada local foram coletadas com o uso de um dispositivo GPS portátil e, posteriormente, convertidas para um arquivo shapefile utilizando o software QGIS, a fim de alinhar os dados georreferenciados ao sistema de coordenadas das imagens do Sentinel-2. Todas as implementações de código, incluindo a seleção da região de interesse (ROI), bem como o treinamento e teste dos modelos classificatórios, foram realizadas na linguagem Python, utilizando o ambiente de desenvolvimento integrado Spyder.

Cada polígono, englobando apenas as regiões estudadas, foi selecionado manualmente na plataforma online para download, com o objetivo de agilizar o processamento e a extração de dados. Além das bandas do sensor, composições RGB e índices de vegetação foram incluídos como características.

Para os experimentos, foram utilizados os seguintes índices: Índice de Vegetação por Diferença Normalizada (NDVI) [Jr et al. 1974], Índice de Vegetação por Diferença Normalizada do Verde (GNDVI) [Gitelson, Kaufman e Merzlyak 1996], Índice de Água por Diferença Normalizada (NDWI) [Gao 1996], Índice de Clorofila por Diferença Normalizada (NDCI) [Mishra e Mishra 2012], Índice de Umidade por Diferença Normalizada (NDMI) [Klemas e Smart 1983], Índice de Vegetação Aprimorado

(EVI) [Huete 1988], Índice de Borda Vermelha por Diferença Normalizada (NDRE) [Barnes et al. 2000], Índice de Vegetação Ajustado pelo Solo (SAVI) [Huete 1988], Índice de Pigmento Insensível à Estrutura (SIPI) [Peñuelas et al. 1997] e o Índice de Coloração (CI) [Escadafal, Belghith e Ben-Moussa].

Como as bandas derivadas das imagens Sentinel-2 foram consideradas como uma das características de entrada dos pixels, para evitar a repetição de informações associadas a cada pixel, cada combinação RGB adquirida foi convertida em níveis de cinza para obter diferentes tonalidades da região estudada. As combinações contendo 3 bandas foram convertidas em imagens em escala de cinza, considerando a conversão RGB padrão ( $0,2989 * R + 0,5870 * G + 0,1140 * B$ ).

### 6.2.1 Ajuste de Hiperparâmetros

Para ajustar os hiperparâmetros de cada modelo foi aplicada otimização Bayesiana, permitindo uma pesquisa de hiperparâmetros mais rápida, baseada em dados anteriores através de avaliações. O método de pré-treinamento ganancioso (*Greedy Pre-Training*) foi empregado para determinar o número de camadas ocultas, ajustando o modelo a cada camada adicionada e treinando sub-redes rasas. O desempenho da estrutura foi avaliado graficamente com base no número de camadas adicionais. Para cada nova camada oculta, uma quantidade predeterminada de neurônios foi adicionada para verificar a precisão. Especificamente, foi escolhido dez neurônios por camada oculta para entradas formadas apenas por índices de vegetação, onze para combinações RGB, doze para bandas Sentinel-2 e trinta e três para a união de todas as características.

A escolha dos parâmetros para os modelos foi baseada na maior precisão obtida após as execuções para cada parâmetro. Por exemplo, entre os parâmetros avaliados no modelo utilizando k-NN estão o *leaf\_size*, o *n\_neighbours* (número de vizinhos) e o *p* (métrica de distância). O intervalo definido para os valores possíveis de *k* variou entre 1 e 30 vizinhos. Cada parâmetro avaliado pode ser visto na Tabela 6.5.

Modelo	Parâmetro
Rede Neural Artificial	loss (categorical_crossentropy, mean_squared_error) batch_size (5, 15, 30), taxa de aprendizado (0.001, 1)
k-NN	n_vizinhos (1 : 30), p (1, 2)
Floresta Aleatória	n_estimadores (50, 100, 150, 200, 250, 300) max_características (auto, sqrt), max_profundidade (2:9) bootstrap (true, false)
SVM	kernel (linear, polinomial, sigmoide, rbf) C (0.01, 0.1, 1, 10, 100, 1000)

**Tabela 6.5:** Modelos avaliados no estudo e parâmetros testados.

### 6.2.2 Resultados do Estudo

Por meio do pré-treinamento, as amostras pertencentes ao conjunto de treinamento foram aplicadas para determinar o número de camadas ocultas na rede neural destinada à classificação das variedades de cana-de-açúcar, avaliando posteriormente o desempenho da rede em cada camada inserida. O número de iterações realizadas totalizou 11 camadas ocultas, com a execução inicial contendo 2 camadas (1 camada oculta e a camada de saída) e 10 iterações adicionais, resultando em um total de 12 camadas na rede.

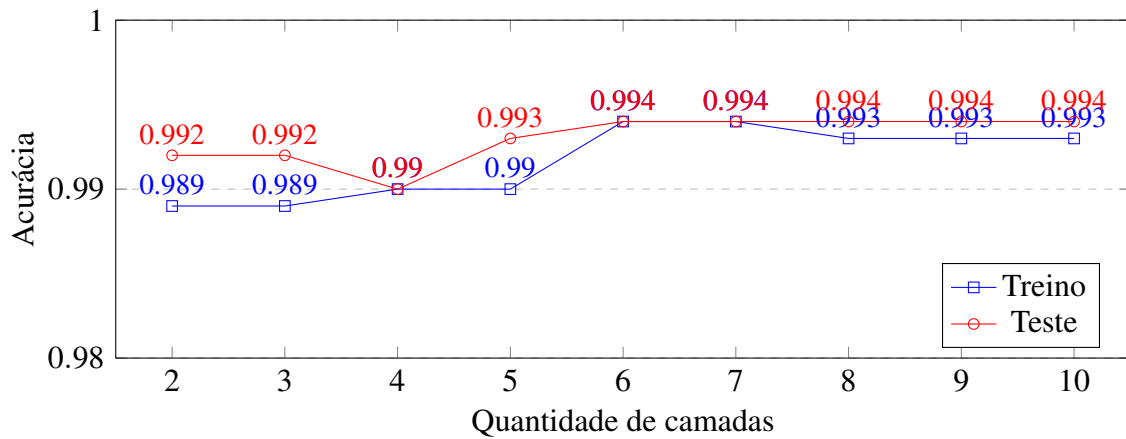
O processo de treinamento consistiu em 500 épocas, utilizando o callback "*EarlyStopping*" com paciência igual a 10 (número de épocas sem melhoria). A precisão média foi obtida através de validação cruzada de 10 vezes. Após selecionar o número ideal de camadas ocultas, os parâmetros relacionados ao número de neurônios em cada camada oculta foram definidos, e o treinamento da rede neural foi otimizado. Diversas configurações estruturais foram testadas para avaliar como o aumento ou diminuição dos neurônios em cada camada influenciava a capacidade do modelo de separar as classes.

A base de dados usada foi formada por bandas do Sentinel-2, índices de vegetação e composições RGB simples, separando cada amostra pelos valores contidos nos pixels, (20000 amostras, com 5000 amostras por variedade). A divisão entre dados de treino e teste foi de 80% para treinamento (16000 pixels) e 20% para teste (4000 pixels). É importante salientar que os pixels pertencentes a dados de treino e testes são distintos, no entanto pixels referentes a uma mesma data podem estar presentes tanto na base de treino quanto na base de testes.

### 6.2.3 Rede Neural Resultante

Com base nos resultados obtidos, a rede neural desenvolvida através do processo de adição de camadas ocultas é composta por um total de sete camadas (seis camadas ocultas e uma camada de saída), uma vez que não houve melhoria no desempenho do modelo após a inclusão da sexta camada oculta, conforme evidenciado na Figura 6.2. Considerando que se trata de um problema não linear e separável, com muitos dados apresentando sobreposição entre amostras, uma rede neural com apenas uma camada oculta não atingiu a mesma eficiência em comparação com outras configurações que possuem um número maior de camadas.

A queda no desempenho do modelo em alguns pontos pode indicar um sobreajuste dos dados devido à inserção de camadas ocultas adicionais e ao aumento da precisão das camadas subsequentes. Por essa razão, a estrutura de rede neural com seis camadas foi selecionada para o ajuste de hiperparâmetros. Camadas adicionais não melhoraram a capacidade do modelo de distinguir entre variedades de cana-de-açúcar. Para ilustrar a disposição dos neurônios em cada camada, consideramos o número de entradas (33



**Figura 6.2:** Acurácia por número de camadas.

entradas, compostas por bandas do Sentinel-2, índices de vegetação e combinações RGB), os neurônios de cada camada oculta e as saídas.

A otimização Bayesiana aplicada ao conjunto de dados com todas as 33 características para definir o número de neurônios nas camadas ocultas não produziu o melhor resultado entre as configurações de neurônios testadas (configuração (33, 63, 11, 7, 64, 64, 4) com taxa de aprendizado = 0,001 e tamanho do lote = 5). Por essa razão, a definição do número de neurônios em cada camada oculta levou em consideração alguns métodos existentes: quantidade de neurônio por camada de acordo com o tamanho das camadas de entrada e saída [Heaton 2008] e número de neurônios com valores múltiplos de 4, com um máximo de 128 neurônios na camada mais próxima da entrada.

Para redes com seis camadas, em que a primeira camada oculta é composta por 64 neurônios, foi observada uma precisão superior a 99,2% para o conjunto de dados de treinamento, além de se destacar como a melhor precisão entre as opções com menos neurônios. A adição de mais neurônios em camadas ocultas não melhorou a precisão do modelo na previsão das variedades de cana-de-açúcar (Tabela 6.6).

Não houve melhorias no desempenho da rede ao aplicar camadas de *dropout* entre as camadas densas, portanto, essa técnica não foi utilizada na predição. Para atualizar os pesos e vieses, foi escolhido o otimizador Adam, com uma taxa de aprendizado definida como 0,001 e utilizando a entropia cruzada categórica como função de perda.

Características	Configuração	Acurácia
Bandas, Índices de Vegetação e Combinações RGB	(33,19,12,8,6,5,4)	98.4 (+- 0.50)
	(33,33,19,12,8,6,4)	99.0 (+- 0.17)
	(33,63,11,7,64,64,4) com BO	96.2 (+- 1.29)
	<b>(33,64,32,16,8,4,4)</b>	<b>99.2 (+- 0.19)</b>
	(33,128,64,32,16,8,4)	99.1 (+- 0.50)
Bandas	(12,8,6,5,4)	96.1 (+- 2.14)
	(12,12,8,6,4)	98.0 (+- 0.74)
	(12,32,16,8,4)	98.9 (+- 0.39)
	(12,64,32,16,4)	98.2 (+- 0.39)
Índices de Vegetação	(10,10,7,6,5,5,5,4)	89.9 (+- 1.16)
	(10,32,16,8,4,4,4,4)	94.6 (+- 1.07)
	(10,64,32,16,8,4,4,4)	96.1 (+- 0.57)
Combinações RGB	(11,11,8,6,4)	94.1 (+- 2.25)
	(11,16,8,4,4)	96.0 (+- 0.62)
	(11,32,16,8,4)	97.3 (+- 0.22)
	(11,64,32,16,4)	98.2 (+- 0.39)

**Tabela 6.6:** Avaliação dos modelos de rede neural para diferentes números de neurônios nas camadas ocultas a partir do conjunto de dados de treinamento.

Apesar de outras configurações não superaram a configuração de maior acurácia, também mostraram bom desempenho, mostrando que o aumento no número de neurônios em camadas ocultas tende a melhorar a acurácia até certo ponto. Mas o aumento excessivo de neurônios não necessariamente resulta em melhorias significativas, sugerindo a existência de um ponto ótimo para o número de neurônios. Além disso, o desempenho das redes utilizando apenas bandas do sensor foi superior aos outros tipos de dados, destacando a importância de seu uso isolado, com impacto positivo na classificação de variedades de cana-de-açúcar.

A separabilidade das variedades de cana-de-açúcar utilizando índices de vegetação apresentou uma precisão inferior em comparação ao uso das informações de pixels das bandas do Sentinel-2. Essa diminuição na precisão pode ser atribuída a vários fatores, como seca, mistura espectral e doenças, que podem comprometer a leitura das condições da vegetação e dificultar a distinção entre as variedades de cana-de-açúcar.

## 6.2.4 Redes Neurais e Modelos Clássicos de Aprendizado de Máquina

Os resultados obtidos para os classificadores revelam nuances no desempenho na tarefa de distinguir entre sete variedades de cana-de-açúcar. A análise geral, o SVM

apresenta a maior acurácia geral (99,55%). A Tabela 6.7 apresenta a acurácia geral, a acurácia do usuário e a acurácia do produtor para cada um dos modelos.

Em termos de métricas específicas, o modelo baseado em SVM e a RNA se sobressaem, indicando um bom equilíbrio entre identificar corretamente as classes e minimizar classificações incorretas. O modelo de floresta aleatório, embora eficiente, não atinge os mesmos níveis de acurácia geral como o SVM e o RNA. O kNN, apesar de ser um bom classificador, tem um desempenho inferior quando comparado aos outros métodos, principalmente na acurácia geral.

Em relação à classificação de variedades individualmente, com exceção do kNN, os outros modelos foram capazes de classificar corretamente todas as amostras da variedade RB988082. A variedade RB92579 apresentou o maior número de previsões incorretas utilizando os modelos kNN e Floresta Aleatória, sendo frequentemente confundida com a variedade RB966928. Esse resultado pode estar associado à mistura espectral da variedade em crescimento com o solo exposto para a data selecionada.

**Tabela 6.7:** Resultados de classificadores com diferentes parâmetros para quatro variedades de cana-de-açúcar.

Classificador	Classe	Acurácia	Precisão	Recall	F1-score	Acurácia Geral
kNN	0	98.55%	99.90%	99.60%	99.75%	98.29%
	1	99.12%	98.54%	99.12%	98.83%	
	2	96.51%	98.58%	96.51%	97.53%	
	3	98.98%	97.19%	98.98%	98.07%	
FA	0	99.70%	100.00%	99.70%	99.85%	99.28%
	1	99.61%	99.32%	99.61%	99.46%	
	2	98.11%	99.49%	98.11%	98.80%	
	3	99.69%	98.28%	99.69%	98.98%	
SVM	0	100.00%	100.00%	100.00%	100.00%	99.55%
	1	99.80%	99.13%	99.80%	99.46%	
	2	98.90%	99.80%	98.90%	99.35%	
	3	99.49%	99.28%	99.49%	99.39%	
RNA	0	99.40%	100.00%	99.40%	99.70%	99.47%
	1	99.80%	99.42%	99.80%	99.61%	
	2	99.30%	99.40%	99.30%	99.35%	
	3	99.39%	99.08%	99.39%	99.23%	

Avaliando a contribuição de cada característica utilizada como entrada na rede neural densa, as bandas do Sentinel-2 foram identificadas como as características mais críticas na diferenciação entre as variedades de cana-de-açúcar, especialmente as bandas B1, B6, B7 e B11. A banda B6 também foi apontada como característica mais significativa para a classificação, principalmente para a variedade RB988082 (Classe 0) no modelo desenvolvido com uso do SVM. A região de borda vermelha apresentou-se como a mais

sensível aos níveis de clorofila nas folhas, com valores distintos para cada variedade e auxiliando na separação das classes.

Apesar da precisão inferior derivada dos índices de vegetação, eles são amplamente aplicados a diversos problemas de identificação e classificação de plantas, indicando que sua aplicação é relevante. No entanto, mais índices precisam ser explorados para encontrar os mais eficientes para a análise do conteúdo bioquímico em plantas de cana-de-açúcar, permitindo a aquisição de informações que possam favorecer a separação entre variedades. Além disso, fatores como a ocorrência de doenças, exposição do solo causando mistura espectral, seca, produtos químicos, entre outros, podem ter influenciado a predição dos modelos.

### **6.3 Rede Cruzada Profunda na Diferenciação de Variedades de Cana-de-Açúcar**

Neste estudo, desenvolveu-se uma arquitetura de rede neural baseada no modelo de Rede Neural Profunda e Cruzada (Deep & Cross Network, DCN), com o objetivo de aprimorar a distinção entre diferentes variedades de cana-de-açúcar. O uso de cruzamento de recursos possibilitou a disponibilização de mais características derivadas para a tarefa de classificação. A base de dados utilizada incluiu um número maior de classes de variedades de cana-de-açúcar em comparação com estudos anteriores, utilizando como entrada características extraídas de comprimentos de onda obtidos a partir dos sensores do produto 2A do Sentinel-2, correspondentes a pixels representativos de cana-de-açúcar. Adicionalmente, foram derivados outros atributos, como índices de vegetação e combinações simples RGB, obtidas pela concatenação de bandas e posterior transformação em níveis de cinza.

As imagens utilizadas foram coletadas por meio da plataforma SentinelHub, a qual permite acesso gratuito mediante cadastro, utilizando a linguagem de programação Python e pacotes específicos para acesso ao banco de imagens. Dias inadequados foram removidos com base em um limite de 0,5 para o Índice de Vegetação por Diferença Normalizada (NDVI). Verificou-se que datas com valores baixos de NDVI coincidem com períodos de pós-colheita, emergência e perfilamento das plantas de cana-de-açúcar, onde há uma mistura espectral entre planta e solo, além da ocorrência de nuvens e sombras. Valores de NDVI acima de 1,0, fora do intervalo esperado para a condição das plantas, também foram eliminados, pois indicavam pixels fortemente influenciados pela presença de nuvens. Dessa forma, esses dados foram removidos para garantir a qualidade e a precisão do conjunto de treinamento.

Para a classificação supervisionada, as informações que compuseram a base de

dados foram balanceadas de modo a garantir uma quantidade uniforme de pixels para cada variedade de cana-de-açúcar incluída. Esse procedimento foi necessário para mitigar o desbalanceamento causado pela menor área cultivada de algumas variedades em relação a outras. A seleção dos pixels foi realizada de forma aleatória, assegurando uma distribuição equitativa tanto para o conjunto de treinamento quanto para o conjunto de validação. Dessa forma, o número de pixels utilizados em diferentes datas foi uniformemente distribuído entre os dois conjuntos, permitindo uma avaliação mais precisa da eficiência dos modelos.

Além disso, as datas das imagens também foram selecionadas de maneira aleatória para garantir a diversidade temporal na análise. Essa abordagem buscou assegurar que os modelos fossem treinados e avaliados de forma robusta, considerando a variação temporal e espectral das imagens.

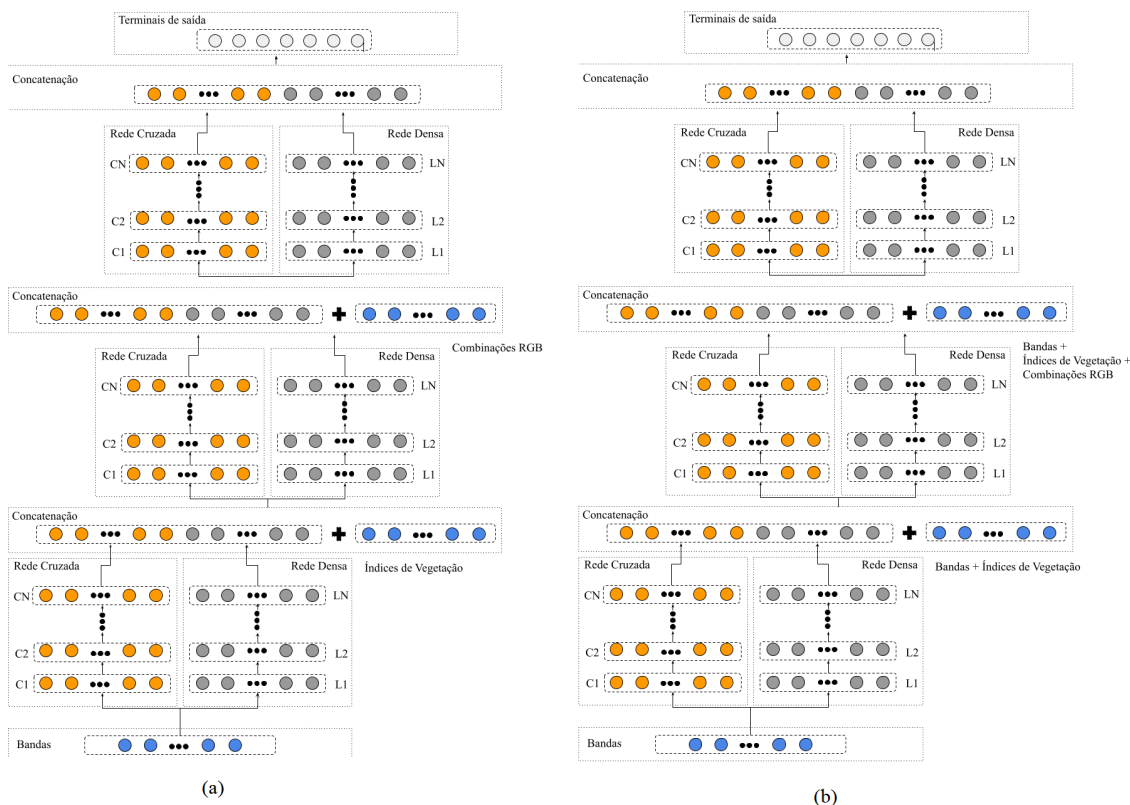
### **6.3.1 Classificação com Separação de Datas por Local**

A quantidade de camadas definidas para cada rede neural testada variou entre quatro e sete camadas, uma vez que a adição de camadas extras não resultou em melhorias significativas na precisão do modelo. Assim, os resultados foram obtidos a partir de modelos de redes neurais profundas (com mais de duas camadas ocultas) e redes neurais profundas cruzadas (Deep & Cross Network, DCN), desenvolvidos com base em três tipos de dados: bandas espectrais, índices de vegetação e combinações RGB.

Técnicas de seleção de características, como a Análise de Componentes Principais (PCA) e a seleção de características baseada em Florestas Aleatórias, foram avaliadas com o objetivo de reduzir a dimensionalidade das entradas. No entanto, os resultados obtidos foram pouco expressivos em comparação ao uso integral das características, motivo pelo qual essas abordagens não foram incorporadas à análise de precisão dos modelos.

A definição da arquitetura da rede cruzada foi realizada a partir de diversas configurações, considerando cada conjunto de características separadamente e integrando-os progressivamente na rede. Essa abordagem incluiu a concatenação de dois ou mais conjuntos de características nas entradas.

Os resultados dos classificadores baseados em redes cruzadas para sete variedades de cana-de-açúcar indicaram que a arquitetura que inicialmente introduziu as 12 bandas do sensor, seguida pela adição de 13 índices de vegetação (IVs) em camadas posteriores, e finalmente a inclusão do conjunto de combinações RGB (C), alcançou uma acurácia de 65,61% e uma precisão de 66,01%, com um total de 111.477 parâmetros. No segundo modelo, a combinação das entradas resultou em uma acurácia de 65,65% e uma precisão de 66,10%, utilizando um total de 107.563 parâmetros. Em ambos os casos, a combinação de camadas cruzadas e densas proporcionou uma leve melhoria no desempenho do modelo.



**Figura 6.3:** Arquiteturas de rede cruzada profunda com quantidade diferente de entradas a cada camada de concatenação.

A distribuição de camadas para cada arquitetura discutida pode ser visualizada na Figura 6.3.

As arquiteturas desenvolvidas com base em apenas um dos conjuntos de dados não apresentaram acurácias superiores às obtidas com redes densas convencionais, motivo pelo qual esses resultados não serão discutidos nas subseções seguintes.

Dada a semelhança nos resultados entre as redes, decidiu-se utilizar, na avaliação do modelo de rede cruzada em comparação com os modelos clássicos, a arquitetura com um menor número de parâmetros e uma quantidade reduzida de dados de entrada. Essa escolha foi feita para evitar a inclusão de informações redundantes, que poderiam resultar da concatenação de saídas ou da fusão com outros conjuntos de entradas. Assim, promove-se uma abordagem mais eficiente e simplificada para a classificação das variedades de cana-de-açúcar.

Para a avaliação de desempenho entre os modelos de rede neural e os modelos clássicos, a Tabela 6.8 resume as métricas calculadas para os modelos de classificação, incluindo acurácia, precisão, F1-score e recall. Inicialmente, as métricas de cada classificador foram obtidas sem a inclusão da etapa de votação, ou seja, sem considerar a saída mais recorrente de uma amostra para uma classe.

Os resultados foram organizados de acordo com os diferentes conjuntos de entrada.

Primeiramente, os modelos de classificação foram avaliados utilizando uma base de amostras composta apenas por dados das bandas do sensor Sentinel-2. Em seguida, a avaliação foi realizada com uma base que combinava características derivadas de índices de vegetação. Por fim, a última avaliação foi conduzida com uma base formada pela junção das bandas do sensor, índices de vegetação e combinações RGB.

**Tabela 6.8:** Resultados de classificadores com diferentes parâmetros para sete variedades de cana-de-açúcar.

Entrada	Classificador	Acurácia	Precisão	F1-Score	Recall
Bandas	RNA - 6 camadas ocultas	0.6098	0.6158	0.6099	0.6098
	RNA - 7 camadas ocultas	0.5913	0.5930	0.5886	0.5913
	kNN	0.5462	0.5470	0.5447	0.5462
	Random Forest	0.5995	0.5994	0.5972	0.5995
	SVM	0.6016	0.6135	0.6023	0.6016
Bandas+IVs	RNA - 6 camadas ocultas	0.5912	0.5944	0.5892	0.5912
	RNA - 7 camadas ocultas	0.5910	0.5935	0.5885	0.5910
	kNN	0.5559	0.5548	0.5544	0.5559
	Random Forest	0.6114	0.6094	0.6090	0.6114
	SVM	0.6042	0.6211	0.6089	0.6042
Bandas+IVs+C	RNA - 6 camadas ocultas	0.5953	0.6008	0.5947	0.5953
	RNA - 7 camadas ocultas	0.5976	0.6090	0.5973	0.5976
	kNN	0.5463	0.5443	0.5444	0.5463
	Random Forest	0.6088	0.6063	0.6062	0.6088
	SVM	0.5983	0.6197	0.6044	0.5983
	DCN-S	<b>0.6188</b>	<b>0.6236</b>	<b>0.6184</b>	<b>0.6188</b>

De acordo com o desempenho apresentado pelo classificadores, o modelo desenvolvido denominado de DCN-S destacou-se como o melhor desempenho geral em comparação aos outros modelos testados, mesmo sem o processo adicional de votação. Em particular, a combinação de todas as características coletadas (bandas, índices de vegetação e combinações RGB) como entrada no modelo da DCN resultou em uma acurácia de 61.88% e precisão de 62.36%. Além desse resultado, as redes neurais com números variáveis de camadas ocultas também apresentaram bons resultados.

O segundo melhor modelo derivou-se de uma rede neural com 6 camadas ocultas, considerando como entrada apenas bandas espectrais. Esse resultado corrobora com o estudo anterior [Kai, Oliveira e Costa 2022], demonstrando a eficiência das bandas como informações de entrada para modelos de classificação. Já a RNA com 7 camadas ocultas teve uma performance ligeiramente inferior, sugerindo que um maior número de camadas em uma rede neural não necessariamente resulta em melhor desempenho para o problema envolvendo classificação de variedades de cana-de-açúcar.

No caso dos outros classificadores, o classificador kNN apresentou resultados inferiores em todos os teste em comparação aos outros modelos, com a acurácia variando


entre 54.62% e 56.28% de acordo com a entrada aplicada. Os modelos SVM e Floresta Aleatória derivaram resultados intermediários, com acurácia entre 59.83% e 60.16% para o SVM e no caso da Floresta aleatória, acurácia de 59.95% a 61.84%, com desempenho melhorado pela adição de índices de vegetação aos dados do sensor como entrada. Desse modo, para o modelo de maior precisão, o DCN-S, a inclusão de diferentes combinações de dados de entrada teve um impacto nos resultados, destacando a importância de diversificar dados para a classificação de variedades de cana-de-açúcar.

**Tabela 6.9:** Resultados de classificadores com processo de votação com diferentes parâmetros para sete variedades de cana-de-açúcar.

Entrada	Classificador	Acurácia	Precisão	F1-Score	Recall
Bandas	RNA - 6 camadas ocultas	0.6513	0.6564	0.6513	0.6513
	RNA - 7 camadas ocultas	0.6292	0.6391	0.6319	0.6292
	kNN	0.5496	0.5562	0.5509	0.5496
	Random Forest	0.6054	0.6149	0.6076	0.6054
	SVM	0.6115	0.6239	0.6122	0.6115
Bandas+IVs	RNA - 6 camadas ocultas	0.6242	0.6319	0.6258	0.6242
	RNA - 7 camadas ocultas	0.6281	0.6393	0.6302	0.6281
	kNN	0.5628	0.5680	0.5642	0.5628
	Random Forest	0.6184	0.6264	0.6208	0.6184
	SVM	0.6129	0.6294	0.6174	0.6129
Bandas+IVs+C	RNA - 6 camadas ocultas	0.6375	0.6408	0.6380	0.6375
	RNA - 7 camadas ocultas	0.6352	0.6418	0.6346	0.6352
	kNN	0.5528	0.5588	0.5547	0.5528
	Random Forest	0.6162	0.6246	0.6188	0.6162
	SVM	0.6057	0.6269	0.6116	0.6057
	DCN-S	<b>0.6561</b>	<b>0.6601</b>	<b>0.6560</b>	<b>0.6561</b>

Ao considerar o processo de votação para a obtenção das métricas dos modelos de classificação, observou-se uma melhora na acurácia para todos os modelos de redes neurais, em especial para a rede neural com seis camadas ocultas, com acréscimo acima de 4% (Tabela 6.9). O modelo DCN-S manteve-se com a melhor acurácia, considerando a base com todas as 35 características (bandas, índices de vegetação e combinações RGB), com acurácia de 65.61% e precisão de 66.01%, uma melhora acima de 3% considerando a votação.

Analisando os resultados dos classificadores aplicados a sete variedades de cana-de-açúcar temos que o desempenho geral dos classificadores demonstra que o modelo com arquitetura baseada em uma rede neural DCN apresentou-se como o mais eficaz, alcançando a melhor acurácia e precisão no conjunto de dados com todas as características (Bandas, IVs e combinações RGB). Isso sugere que o DCN-S é particularmente eficiente ao lidar com conjunto de dados mais diverso em características, destacando a importância de utilizar classificadores mais complexos e de incluir o máximo de características relevantes



**Figura 6.4:** Comparação da acurácia observada entre os modelos testados na classificação de variedades de cana-de-açúcar sem votação e com inclusão.

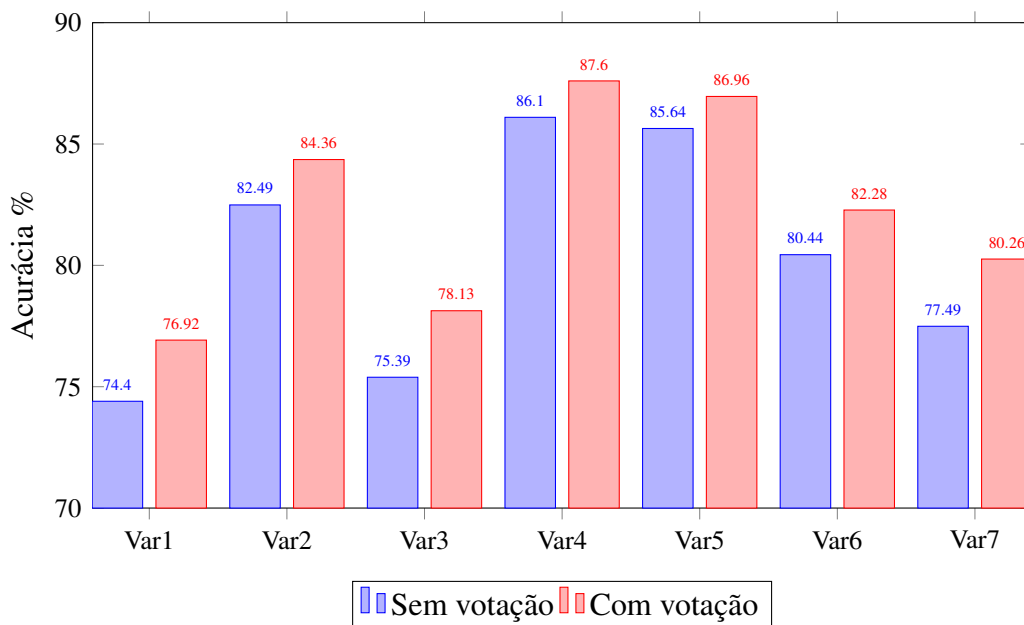
possíveis. Essa tendência indica que a inclusão de características adicionais pode fornecer informações valiosas que melhor a capacidade de previsão do classificador.

Sem considerar o processo de votação, ao comparar os diferentes conjuntos de dados, observa-se que o desempenho do modelo com cruzamento de atributos tende a melhorar à medida que mais características são incluídas, principalmente ao agregarmos IVs à bandas espectrais. Como exemplo, a acurácia do classificador de Floresta Aleatória aumentou de 59.95% por uso somente de bandas do sensor do Sentinel-2, para 61.14% com a junção dos IVs, resultado que também pode ser observado para o kNN. No entanto, dado o desempenho inferior em termos de acurácia em todos os conjuntos de dados, podemos concluir que o kNN não seja adequado para a tarefa de separar diferentes variedades de cana-de-açúcar.

No contexto das redes neurais profundas, se compararmos a precisão adquirida entre as arquitetura entre seis e sete camadas, o modelo de seis camadas ocultas geralmente supera as outras arquiteturas, embora a diferença não seja muito significativa. Além disso, pode-se observar que as bandas do sensor do Sentinel-2 são significativamente mais relevantes na diferenciação em comparação a outras características, propiciando diferenças entre as variedades de cana-de-açúcar em diferentes comprimentos de onda.

### 6.3.2 Análise por variedade de cana-de-açúcar

Outra análise realizada envolveu o treinamento do classificador utilizando o conjunto de dados considerando apenas duas classes. A primeira classe consistiu em uma das sete variedades de cana-de-açúcar, enquanto a segunda classe foi composta por uma



**Figura 6.5:** Classificação binária por variedade por uso do modelo DCN-S

mistura das demais variedades, com amostras selecionadas aleatoriamente. A Figura 6.5 apresenta um gráfico de barras que compara a acurácia do modelo de rede neural profunda DCN-S para diferentes variedades de cana-de-açúcar, tanto com quanto sem o uso do processo de votação.

Confirmando os resultados obtidos no cenário com sete classes de saída, a acurácia geral foi superior quando o mecanismo de votação foi aplicado em todas as variedades. Entre as variedades mais distinguíveis, Var4 e Var5 apresentaram as maiores taxas de acurácia, com valores superiores a 85%, atingindo 87,6% e 86,9%, respectivamente, ao aplicar o mecanismo de votação. Por outro lado, as variedades com os menores índices de acurácia foram Var1 e Var3, com valores de 74,40% e 75,39%, respectivamente, na ausência do processo de votação.

A aplicação da votação no modelo DCN-S mostrou-se eficaz em melhorar a acurácia para todas as variedades testadas, embora o impacto tenha sido mais expressivo em algumas variedades. Esses resultados reforçam a robustez do método e sua capacidade de aprimorar o desempenho do classificador, especialmente em variedades mais difíceis de distinguir. Portanto, o uso do processo de votação se apresenta como uma estratégia promissora para otimizar a acurácia em classificações complexas.

### 6.3.3 Classificação sem Separação de Datas por Local

A Tabela 6.10 apresenta os resultados de diferentes modelos de classificação, detalhando seus parâmetros específicos e a acurácia obtida utilizando o conjunto de dados

sem separação por datas para treino e teste, empregando o método de validação cruzada k-fold com 5 divisões. De acordo com os resultados, o modelo SVM obteve a melhor acurácia (87,30%) entre os modelos testados, sugerindo uma maior capacidade de generalização e separação entre as classes. Os demais modelos, incluindo kNN, Floresta Aleatória e DCN-S, também apresentaram um desempenho relativamente satisfatório, com acurácias variando entre 81,89% e 83,71%.

**Tabela 6.10:** Métricas e parâmetros de modelos por uso de base de dados sem separação de datas para treino e teste.

Modelo	Parâmetros	Acurácia
kNN	algoritmo kdtree, n_vizinhos 4, distan- cia manhattan, peso: distância	81.89%
Floresta Aleatória	max_depth 29, max_features 13, min_samples_leaf 1, min_samples_split 3, n_estimators 64	83.71%
SVM	C 10, gamma 1.0, kernel rbf	87.30%
DCN-S	kernel_initializer glo- rot_normal, activation elu, batch_size 8	82.10%

Essa diferença de desempenho pode ser atribuída ao aumento da acurácia proporcionado pela validação cruzada, em comparação com o uso de um conjunto de teste isolado, sem separação por datas. Isso ocorre devido à similaridade entre os valores de pixels presentes nos conjuntos de treino e teste, considerando que processos de reamostragem de pixels podem gerar valores semelhantes ao redimensionar imagens para uma resolução espacial maior.

A análise dos resultados sugere que a utilização da validação cruzada k-fold com 5 divisões proporcionou uma avaliação mais robusta dos modelos de classificação, quando comparada à abordagem de separação dos dados por datas. Essa metodologia permitiu o uso mais eficiente de toda a base de dados, garantindo que cada amostra fosse empregada tanto para treino quanto para teste em diferentes iterações, minimizando assim vieses associados a variações temporais.

O modelo SVM destacou-se por atingir a maior acurácia (87,30%), demonstrando sua eficácia na generalização e distinção entre diferentes classes de dados. A superioridade do SVM pode ser atribuída à sua capacidade de encontrar hiperplanos ótimos que separam as classes, o que é particularmente vantajoso em conjuntos de dados com estruturas complexas.

Os demais modelos, como kNN, Floresta Aleatória e DCN-S, também apresentaram bons desempenhos, embora ligeiramente inferiores ao SVM, com acurácias variando entre 81,89% e 83,71%. Essa diferença de desempenho pode ser relevante, especialmente em aplicações práticas onde a precisão na classificação é um fator crítico.

Assim, a separação dos dados de treino e teste por datas distintas oferece benefícios importantes, especialmente em cenários onde a variação temporal pode influenciar o comportamento do modelo. Essa abordagem simula um ambiente mais realista, onde o modelo é treinado em dados históricos e avaliado em dados futuros, o que permite testar sua capacidade de generalização para novos padrões que podem surgir ao longo do tempo. Além disso, ao considerar a separação temporal, evita-se o risco de sobreajuste causado pela similaridade entre os dados de treino e teste, assegurando que o modelo não aprenda apenas padrões específicos do conjunto de treino.

Dessa forma, a validação com separação temporal pode oferecer uma maneira mais robusta e confiável de avaliar o desempenho do modelo em condições práticas, tornando-o mais preparado para lidar com uma maior variabilidade dos dados.

---

## Conclusão

---

Este estudo apresentou uma nova abordagem para a classificação de sete variedades brasileiras de cana-de-açúcar cultivadas em regiões do estado de Goiás, utilizando metodologias baseadas em redes neurais profundas e cruzadas. Os modelos de classificação foram alimentados com doze bandas espectrais do produto 2A do sensoriamento remoto Sentinel-2, abrangendo diferentes comprimentos de onda, além de dez combinações RGB e treze índices de vegetação. O objetivo foi investigar o potencial de separação entre as variedades de cana-de-açúcar por meio da utilização de uma ampla gama de características espectrais e índices vegetativos.

A tarefa de classificar variedades distintas de uma mesma cultura revelou-se desafiadora, principalmente devido à similaridade das informações coletadas pelas bandas do Sentinel-2. As características espectrais das diferentes variedades de cana-de-açúcar são próximas, assim como os valores dos índices de vegetação, refletindo características biológicas semelhantes entre as plantas. Essa semelhança pode dificultar a discriminação eficaz entre as variedades, evidenciando a necessidade de abordagens mais sofisticadas para a classificação.

Os resultados obtidos indicam que o modelo de Rede Neural Cruzada Profunda (DCN-S) proporcionou melhorias significativas no desempenho de classificação, superando outros modelos testados, como kNN, Floresta Aleatória e SVM. Essa performance evidencia a eficácia do DCN-S em capturar variações intrínsecas entre diferentes variedades de cana-de-açúcar, especialmente quando é utilizado um conjunto mais amplo de características. Os resultados também demonstraram que o modelo apresenta acurácia superior em relação a modelos clássicos ao considerar variações temporais, com datas independentes entre amostras de treino e teste. Além disso, o DCN-S foi capaz de classificar variedades sem a necessidade de segmentação das fases de desenvolvimento, com desempenho aprimorado pela aplicação de um processo de votação.

Entretanto, a acurácia alcançada sugere que ainda há espaço para melhorias na modelagem e na seleção de características, especialmente considerando a necessidade de maior precisão em aplicações práticas. Além disso, a similaridade observada nos valores de pixels entre os conjuntos de treino e teste, resultante de processos de reamostragem

para adequação a resoluções espaciais maiores, parece ter contribuído para o aumento da acurácia dos modelos, indicando um reconhecimento facilitado de padrões. Essa observação reforça a importância de empregar técnicas adicionais para garantir a variabilidade e a representatividade dos conjuntos de dados, promovendo uma avaliação mais robusta e realista da capacidade de generalização dos modelos.

Portanto, futuros estudos devem concentrar-se na diversificação dos dados de treino e teste, visando aprimorar a avaliação de desempenho e a aplicação prática de redes neurais profundas na classificação de culturas agrícolas.

### **7.0.1 Trabalhos futuros**

Com base nos resultados e conclusões deste estudo, diversas abordagens podem ser exploradas para aprimorar a classificação de variedades de cana-de-açúcar utilizando técnicas de aprendizado de máquina e sensoriamento remoto. Uma estratégia promissora é a implementação de métodos de aumento de dados e fusão de imagens, visando aumentar a precisão dos modelos. A fusão de dados provenientes de diferentes fontes pode proporcionar informações mais detalhadas e diversificadas sobre as variedades de cana-de-açúcar, melhorando a discriminação entre elas. Além disso, o uso de séries temporais se apresenta como uma alternativa viável, oferecendo uma perspectiva mais ampla sobre o desenvolvimento das plantas e suas variedades ao longo do tempo.

Outra direção a ser considerada envolve a otimização e adaptação das arquiteturas de redes neurais profundas utilizadas neste estudo. A exploração de redes neurais convolucionais (CNNs) para regiões com uma maior área de cultivo de cana-de-açúcar pode levar a melhorias significativas na capacidade de reconhecimento de padrões complexos nos dados. Ademais, a realização de experimentos com uma maior variedade de amostras de cana-de-açúcar e a utilização de diferentes tipos de imagens permitirá uma abordagem mais abrangente na exploração do problema, contribuindo para um entendimento mais profundo das características que distinguem as variedades.

---

## Referências Bibliográficas

---

- [Aggarwal et al. 2015]AGGARWAL, C. C. et al. *Data mining: the textbook*. [S.l.]: Springer, 2015.
- [Aggarwal et al. 2018]AGGARWAL, C. C. et al. *Neural networks and deep learning*. [S.l.]: Springer, 2018.
- [Analytics 2023]ANALYTICS, E. D. *NDVI FAQ: All You Need to Know About NDVI*. 2023. Acesso em: 18 de maio de 2024. Disponível em: <<https://eos.com/blog/ndvi-faq-all-you-need-to-know-about-ndvi/>>.
- [Analytics 2024]ANALYTICS, E. D. *Multispectral Vs. Hyperspectral: Choose The Right Tech*. 2024. Acessado em: 8 novembro de 2024. Disponível em: <<https://eos.com/pt/blog/imagens-hiperespectrais-e-multiespectrais/>>.
- [Apan et al. 2004]APAN, A. et al. Detecting sugarcane ‘orange rust’disease using eo-1 hyperion hyperspectral imagery. *International journal of remote sensing*, Taylor & Francis, v. 25, n. 2, p. 489–498, 2004.
- [Apan et al. 2004]APAN, A. et al. Spectral discrimination and classification of sugarcane varieties using eo-1 hyperion hyperspectral imagery. In: ASIAN ASSOCIATION ON REMOTE SENSING. *Proceedings of the 25th Asian Conference on Remote Sensing (ACRS 2004)*. [S.l.], 2004. p. 1–5.
- [Arnold 2006]ARNOLD, L. S. G. A. R. F. . D. A. T. D. The influence of spectral resolution on discriminating brazilian sugarcane varieties. *International Journal of Remote Sensing*, Taylor & Francis, v. 27, n. 4, p. 769–777, 2006.
- [Barbosa 2021]BARBOSA, E. D. R. A. O. G. V. S. 50 anos de variedades rb de cana-de-açúcar: 30 anos de ridesa. *Graciosa, Curitiba, 156p*, p. 30–52, 2021.
- [Barnes et al. 2000]BARNES, E. et al. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In: *Proceedings of the fifth international conference on precision agriculture, Bloomington, MN, USA*. [S.l.: s.n.], 2000. v. 1619, n. 6.

- [Bernardi et al. 2014]BERNARDI, A. D. C. et al. Agricultura de precisão: resultados de um novo olhar. Brasília, DF: Embrapa, 2014. 596 p., 2014.
- [Biradar 2019]BIRADAR, W. C. I. M. C. Phenology-based discrimination of maize (zea mays l.) varieties using multitemporal hyperspectral data. *Journal of Applied Remote Sensing*, International Society for Optics and Photonics, v. 13, n. 1, p. 017504, 2019.
- [Bramer 2007]BRAMER, M. *Principles of data mining*. [S.l.]: Springer, 2007.
- [BRASIL 1997]BRASIL. *Lei nº 9.456, de 25 de abril de 1997: Institui a Lei de Proteção de Cultivares e dá outras providências*. 1997. 8249–8249 p.
- [Camenzind e Yu 2024]CAMENZIND, M. P.; YU, K. Multi temporal multispectral uav remote sensing allows for yield assessment across european wheat varieties already before flowering. *Frontiers in Plant Science*, Frontiers Media SA, v. 14, p. 1214931, 2024.
- [Campbell e Wynne 2011]CAMPBELL, J. B.; WYNNE, R. H. *Introduction to remote sensing*. [S.l.]: Guilford Press, 2011.
- [Cemin e Ducati 2011]CEMIN, G.; DUCATI, J. R. Spectral discrimination of grape varieties and a search for terroir effects using remote sensing. *Journal of wine research*, Taylor & Francis, v. 22, n. 1, p. 57–78, 2011.
- [Chen et al. 2019]CHEN, Y. et al. Application of image-based phenotyping tools to identify qtl for in-field winter survival of winter wheat (triticum aestivum l.). *Theoretical and Applied Genetics*, Springer, v. 132, p. 2591–2604, 2019.
- [Chipman 2015]CHIPMAN, T. L. R. W. K. J. *Remote sensing and image interpretation*. [S.l.]: John Wiley & Sons, 2015.
- [Cipta, Jaelani e Sanjaya 2022]CIPTA, I. M.; JAELANI, L. M.; SANJAYA, H. Identification of paddy varieties from landsat 8 satellite image data using spectral unmixing method in indramayu regency, indonesia. *ISPRS International Journal of Geo-Information*, MDPI, v. 11, n. 10, p. 510, 2022.
- [Cipta, Jaelani e Sanjaya 2024]CIPTA, I. M.; JAELANI, L. M.; SANJAYA, H. A phenology-based linear spectral unmixing method for rice varieties identification from landsat 8 satellite image in ngawi district, east java, indonesia. *Biodiversitas Journal of Biological Diversity*, v. 25, n. 4, 2024.
- [Conab 2023]CONAB, C. N. de A. comp. safra brasileira de cana-de-açúcar, Brasília, v.11 – safra 2023/24, n.3 - terceiro levantamento,. *Ministério da Agricultura*, p. 1–56, 2023.

- [Conab 2024]CONAB, C. N. de A. Produção de cana-de-açúcar é estimada em 689,8 milhões de toneladas na safra 2024/2025. Agosto 2024. Acesso em: 15 de novembro de 2024. Disponível em: <<https://www.conab.gov.br/ultimas-noticias/5685-producao-de-cana-de-acucar-e-estimada-em-689-8-milhoes-de-toneladas-na-safra-2024-2025>>.
- [Darvishsefat, Abbasi e Schaepman 2011]DARVISHSEFAT, A.; ABBASI, M.; SCHAEPMAN, M. E. Evaluation of spectral reflectance of seven iranian rice varieties canopies. *Journal of Agricultural Science and Technology (JAST)*, University of Tarbiat Modares, v. 13, p. 1091–1104, 2011.
- [Daughtry et al. 2000]DAUGHTRY, C. S. et al. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote sensing of Environment*, Elsevier, v. 74, n. 2, p. 229–239, 2000.
- [Demattê 2006]DEMATTÊ, C. F. J. A. M. Discrimination of sugarcane varieties using landsat 7 etm+ spectral data. *International Journal of Remote Sensing*, Taylor & Francis, v. 27, n. 7, p. 1395–1412, 2006.
- [Domínguez-Cid et al. 2023]DOMÍNGUEZ-CID, S. et al. In-field hyperspectral imaging dataset of manzanilla and gordal olive varieties throughout the season. *Data in Brief*, Elsevier, v. 46, p. 108812, 2023.
- [EMBRAPA 2024]EMBRAPA. *Diferentes variedades de cana-de-açúcar*. 2024. Acesso em: 25 agosto de 2024. Fonte: Embrapa e foto por Raffaella Rossetto. Disponível em: <<https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/cana/pre-producao/caracteristicas/variedades>>.
- [ESA 2015]ESA, E. S. A. *Sentinel-2 User Handbook*. [S.l.], July 2015. Accessed: 2024-05-02. Disponível em: <<https://sentinel.esa.int/documents/247904/685211/Sentinel-2UserHandbook>>.
- [Escadafal, Belghith e Ben-Moussa]ESCADAFAL, R.; BELGHITH, A.; BEN-MOUSSA, H. Indices spectraux pour la dégradation des milieux naturels en tunisie aride. In: *Proceedings of the 6ème Symposium International sur les mesures physiques et signatures en télédétection*. Val d'Isère, France: [s.n.]. p. 253–259.
- [Everingham et al. 2007]EVERINGHAM, Y. et al. Advanced satellite imagery to classify sugarcane crop characteristics. *Agronomy for sustainable development*, Springer, v. 27, n. 2, p. 111–117, 2007.
- [Falcioni et al. 2022]FALCIONI, R. et al. Vis-nir-swir hyperspectroscopy combined with data mining and machine learning for classification of predicted chemometrics of green lettuce. *Remote Sensing*, MDPI, v. 14, n. 24, p. 6330, 2022.

- [Feng et al. 2020]FENG, X. et al. Hyperspectral and multispectral remote sensing image fusion based on endmember spatial information. *Remote Sensing*, MDPI, v. 12, n. 6, p. 1009, 2020.
- [Ferreiro-Arman et al. 2007]FERREIRO-ARMAN, M. et al. Vine variety discrimination with airborne imaging spectroscopy. In: SPIE. *Remote Sensing and Modeling of Ecosystems for Sustainability IV*. [S.l.], 2007. v. 6679, p. 73–82.
- [Fiorio 2019]FIORIO, D. G. D. A. C. S. L. P. R. Sentinel-2b and random forest algorithm potential for sugarcane varieties identification. In: *GEOINFO*. [S.l.: s.n.], 2019. p. 188–193.
- [Furlanetto et al. 2020]FURLANETTO, R. H. et al. Hyperspectral reflectance imaging to classify lettuce varieties by optimum selected wavelengths and linear discriminant analysis. *Remote Sensing Applications: Society and Environment*, Elsevier, v. 20, p. 100400, 2020.
- [Gao 1996]GAO, B.-C. Ndw<sub>i</sub>—a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of environment*, Elsevier, v. 58, n. 3, p. 257–266, 1996.
- [Gitelson, Kaufman e Merzlyak 1996]GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from eos-modis. *Remote sensing of Environment*, Elsevier, v. 58, n. 3, p. 289–298, 1996.
- [Gitelson, Keydan e Merzlyak 2006]GITELSON, A. A.; KEYDAN, G. P.; MERZLYAK, M. N. Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher plant leaves. *Geophysical research letters*, Wiley Online Library, v. 33, n. 11, 2006.
- [Gold et al. 2020]GOLD, K. M. et al. Investigating potato late blight physiological differences across potato cultivars with spectroscopy and machine learning. *Plant Science*, Elsevier, v. 295, p. 110316, 2020.
- [Gomes et al. 2020]GOMES, L. et al. Hyperspectral reflectance as a basis to discriminate olive varieties—a tool for sustainable crop management. *Sustainability*, MDPI, v. 12, n. 7, p. 3059, 2020.
- [Goodfellow 2016]GOODFELLOW, I. *Deep learning*. [S.l.]: MIT press, 2016.
- [Guo, Jia e Paull 2018]GUO, Y.; JIA, X.; PAULL, D. Mapping of rice varieties with sentinel-2 data via deep cnn learning in spectral and time domains. In: IEEE. *2018 Digital Image Computing: Techniques and Applications (DICTA)*. [S.l.], 2018. p. 1–7.

- [Gutiérrez et al. 2018]GUTIÉRREZ, S. et al. On-the-go hyperspectral imaging under field conditions and machine learning for the classification of grapevine varieties. *Frontiers in Plant Science*, Frontiers, v. 9, p. 1102, 2018.
- [Hastie et al. 2009]HASTIE, T. et al. *The elements of statistical learning: data mining, inference, and prediction*. [S.I.]: Springer, 2009.
- [Heaton 2008]HEATON, J. *Introduction to neural networks with Java*. [S.I.]: Heaton Research, Inc., 2008.
- [Hoekman, Vissers e Tran 2010]HOEKMAN, D. H.; VISSERS, M. A.; TRAN, T. N. Unsupervised full-polarimetric sar data segmentation as a tool for classification of agricultural areas. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, IEEE, v. 4, n. 2, p. 402–411, 2010.
- [Huang et al. 2006]HUANG, W. et al. Identifying crop leaf angle distribution based on two-temporal and bidirectional canopy reflectance. *IEEE Transactions on Geoscience and Remote Sensing*, IEEE, v. 44, n. 12, p. 3601–3609, 2006.
- [Huang et al. 2010]HUANG, W. et al. Estimating leaf area index considering the crop geometry effect. In: SPIE. *Remote Sensing for Agriculture, Ecosystems, and Hydrology XII*. [S.I.], 2010. v. 7824, p. 204–210.
- [Huete 1988]HUETE, A. Huete, ar a soil-adjusted vegetation index (savi). remote sensing of environment. *Remote sensing of environment*, v. 25, p. 295–309, 1988.
- [Huete et al. 1997]HUETE, A. et al. A comparison of vegetation indices over a global set of tm images for eos-modis. *Remote sensing of environment*, Elsevier, v. 59, n. 3, p. 440–451, 1997.
- [Jamil et al. 2023]JAMIL, M. et al. The use of multispectral radio-meter (msr5) data for wheat crop genotypes identification using machine learning models. *Scientific Reports*, Nature Publishing Group UK London, v. 13, n. 1, p. 19867, 2023.
- [Jensen e Epiphanyo 2009]JENSEN, J. R.; EPIPHANIO, J. C. N. Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres. Parêntese Editora São José dos Campos, 2009.
- [Jr et al. 1974]JR, J. R. et al. *Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation*. [S.I.], 1974.

- [Junior et al. 2023]JUNIOR, R. L. d. C. B. et al. *Censo varietal IAC de cana-de-açúcar no Brasil - Safra 2021/22*. Campinas: Instituto Agrônômico, 2023. 56 p. (Série Tecnologia APTA. Boletim Técnico IAC, 230). ISSN 1809-7936. Disponível em: <<https://www.iac.sp.gov.br/media/publicacoes/iacbt230.pdf>>.
- [Kai et al. 2021]KAI, P. et al. Effects of resampling image methods in sugarcane classification and the potential use of vegetation indices related to chlorophyll. In: IEEE. *2021 IEEE 45th Annual Computers, Software, and Applications Conference (COMPSAC)*. [S.l.], 2021. p. 1526–1531.
- [Kai et al. 2020]KAI, P. M. et al. Discrimination of sugarcane varieties by remote sensing: A review of literature. In: IEEE. *2020 IEEE 44th Annual Computers, Software, and Applications Conference (COMPSAC)*. [S.l.], 2020. p. 1212–1217.
- [Kai, Oliveira e Costa 2022]KAI, P. M.; OLIVEIRA, B. M. de; COSTA, R. M. da. Deep learning-based method for classification of sugarcane varieties. *Agronomy*, MDPI, v. 12, n. 11, p. 2722, 2022.
- [Karakizi, Oikonomou e Karantzalos 2015]KARAKIZI, C.; OIKONOMOU, M.; KARANTZALOS, K. Spectral discrimination and reflectance properties of various vine varieties from satellite, uav and proximate sensors. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, Citeseer, 2015.
- [Karakizi, Oikonomou e Karantzalos 2016]KARAKIZI, C.; OIKONOMOU, M.; KARANTZALOS, K. Vineyard detection and vine variety discrimination from very high resolution satellite data. *Remote Sensing*, MDPI, v. 8, n. 3, p. 235, 2016.
- [Klemas e Smart 1983]KLEMAS, V.; SMART, R. The influence of soil salinity, growth form, and leaf moisture on-the spectral radiance of. *Photogramm. Eng. Remote Sens*, v. 49, p. 77–83, 1983.
- [Liang et al. 2021]LIANG, T. et al. Identification of high nitrogen use efficiency phenotype in rice (*oryza sativa* l.) through entire growth duration by unmanned aerial vehicle multispectral imagery. *Frontiers in plant science*, Frontiers Media SA, v. 12, 2021.
- [Manickavasagan e Jayasuriya 2014]MANICKAVASAGAN, A.; JAYASURIYA, H. *Imaging with electromagnetic spectrum: applications in food and agriculture*. [S.l.]: Springer, 2014.
- [Marafon 2012]MARAFON, A. Análise quantitativa de crescimento em cana-de-açúcar: uma introdução ao procedimento prático. Aracaju: Embrapa Tabuleiros Costeiros, 2012., 2012.

- [Marin]MARIN, F. R. *Variedades*. Accessed: 01.12.2023. Disponível em: <<https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/cana/pre-producao/caracteristicas/variedades>>.
- [Mirzaei et al. 2019]MIRZAEI, M. et al. Scenario-based discrimination of common grapevine varieties using in-field hyperspectral data in the western of iran. *International Journal of Applied Earth Observation and Geoinformation*, Elsevier, v. 80, p. 26–37, 2019.
- [Mishra e Mishra 2012]MISHRA, S.; MISHRA, D. R. Normalized difference chlorophyll index: A novel model for remote estimation of chlorophyll-a concentration in turbid productive waters. *Remote Sensing of Environment*, Elsevier, v. 117, p. 394–406, 2012.
- [Navarro et al. 2021]NAVARRO, P. J. et al. 3deepm: An ad hoc architecture based on deep learning methods for multispectral image classification. *Remote Sensing*, Multidisciplinary Digital Publishing Institute, v. 13, n. 4, p. 729, 2021.
- [Neto et al. 2018]NETO, A. S. et al. Classification of sugarcane varieties using visible/near infrared spectral reflectance of stalks and multivariate methods. *The Journal of Agricultural Science*, Cambridge University Press, v. 156, n. 4, p. 537–546, 2018.
- [Nidamanuri 2014]NIDAMANURI, R. R. Spectral discrimination of tea plant varieties by statistical, machine learning and spectral similarity methods. In: IEEE. *2014 6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*. [S.l.], 2014. p. 1–4.
- [Nidamanuri 2020]NIDAMANURI, R. R. Hyperspectral discrimination of tea plant varieties using machine learning, and spectral matching methods. *Remote Sensing Applications: Society and Environment*, Elsevier, v. 19, p. 100350, 2020.
- [Niedzielko et al. 2024]NIEDZIELKO, J. et al. Airborne data and machine learning for urban tree species mapping: Enhancing the legend design to improve the map applicability for city greenery management. *International Journal of Applied Earth Observation and Geoinformation*, Elsevier, v. 128, p. 103719, 2024.
- [Nurhuda, Wibowo et al. 2022]NURHUDA, A.; WIBOWO, A. et al. Spatial-temporal of the growth phase and rice varieties using sentinel-1a radar imagery in ciasem district, subang regency. In: IOP PUBLISHING. *IOP Conference Series: Earth and Environmental Science*. [S.l.], 2022. v. 1089, n. 1, p. 012038.
- [Oliveira 2018]OLIVEIRA, R. F. d. *Inteligência Artificial*. Londrina: Editora e Distribuidora Educacional S.A., 2018.

- [Peñuelas et al. 1994]PEÑUELAS, J. et al. Reflectance indices associated with physiological changes in nitrogen-and water-limited sunflower leaves. *Remote sensing of Environment*, Elsevier, v. 48, n. 2, p. 135–146, 1994.
- [Peñuelas et al. 1997]PEÑUELAS, J. et al. Estimation of plant water concentration by the reflectance water index  $w_i$  ( $r_{900}/r_{970}$ ). *International journal of remote sensing*, Taylor & Francis, v. 18, n. 13, p. 2869–2875, 1997.
- [Purwar et al. 2019]PURWAR, P. et al. A reliable approach for pixel-level classification of land usage from spatio-temporal images. In: IEEE. *2019 6th swiss conference on data science (SDS)*. [S.l.], 2019. p. 93–94.
- [Rao 2008]RAO, N. R. Development of a crop-specific spectral library and discrimination of various agricultural crop varieties using hyperspectral imagery. *International Journal of Remote Sensing*, Taylor & Francis, v. 29, n. 1, p. 131–144, 2008.
- [Rauf et al. 2022]RAUF, U. et al. A new method for pixel classification for rice variety identification using spectral and time series data from sentinel-2 satellite imagery. *Computers and Electronics in Agriculture*, Elsevier, v. 193, p. 106731, 2022.
- [Richards, Richards et al. 2022]RICHARDS, J. A.; RICHARDS, J. A. et al. *Remote sensing digital image analysis*. [S.l.]: Springer, 2022.
- [Rossetto e D. 2022]ROSSETTO, R.; D., S. A. *Plantio*. 2022. Disponível em: <<https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/cana/producao/manejo/plantio>>.
- [Sandoval, Gonzalez e Osorio 2011]SANDOVAL, M.; GONZALEZ, C.; OSORIO, M. Evaluation of landsat 7 etm+ data for spectral discrimination and classification of sugarcane varieties in colombia. *J. Agric. Sci. Technol.*, v. 5, p. 101–107, 2011.
- [Sankaran et al. 2019]SANKARAN, S. et al. High-throughput field phenotyping to assess irrigation treatment effects in quinoa. *Agrosystems, Geosciences & Environment*, Wiley Online Library, v. 2, n. 1, p. 1–7, 2019.
- [Schmidt et al. 2000]SCHMIDT, E. et al. Application of remote sensing technology in the sugar industry—a review of recent research findings. In: CITESEER. *Proceedings South African Sugar Technologists Association*. [S.l.], 2000. v. 74, p. 192–201.
- [Sedighi et al. 2023]SEDIGHI, A. et al. Comparative analysis of multispectral and hyperspectral imagery for mapping sugarcane varieties. *PFG—Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, Springer, v. 91, n. 6, p. 453–470, 2023.

- [Sencaki et al. 2019]SENC AKI, D. B. et al. Discrimination analysis of corn species using field hyperspectral data. In: IEEE. *2019 IEEE Asia-Pacific Conference on Geoscience, Electronics and Remote Sensing Technology (AGERS)*. [S.l.], 2019. p. 37–42.
- [Shao et al. 2001]SHAO, Y. et al. Rice monitoring and production estimation using multitemporal radarsat. *Remote sensing of Environment*, Elsevier, v. 76, n. 3, p. 310–325, 2001.
- [Sharma 2020]SHARMA, E. P. D. S. A. K. Exploring the possibility of assessing biochemical variables in sugarcane crop with sentinel-2 data. In: IEEE. *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*. [S.l.], 2020. p. 3712–3715.
- [Shih 1983]SHIH, G. G. S. Sugarcane. *Crop water relations*, John Wiley & Sons New York, p. 445–479, 1983.
- [SILVA et al. 2017]SILVA, S. d. A. et al. Sistema de produção de cana-de-açúcar para agricultura familiar. In: WOLFF, LF; MEDEIROS, CAB (Ed.). *Alternativas para a diversificação da ...*, 2017.
- [SILVA et al. 2016]SILVA, S. d. A. et al. Variedades de cana-de-açúcar recomendadas para o rio grande do sul. In: SILVA, SD dos A. e; MONTERO, CRS; SANTOS, RC dos.; NAVA, DE; GOMES, CB ... , 2016.
- [Singh, Patel e Danodia 2022]SINGH, R.; PATEL, N.; DANODIA, A. Deriving phenological metrics from landsat-oli for sugarcane crop type mapping: a case study in north india. *Journal of the Indian Society of Remote Sensing*, Springer, v. 50, n. 6, p. 1021–1030, 2022.
- [Sinha et al. 2020]SINHA, P. et al. The potential of in-situ hyperspectral remote sensing for differentiating 12 banana genotypes grown in uganda. *ISPRS Journal of Photogrammetry and Remote Sensing*, Elsevier, v. 167, p. 85–103, 2020.
- [Snoek, Larochelle e Adams 2012]SNOEK, J.; LAROCHELLE, H.; ADAMS, R. P. Practical bayesian optimization of machine learning algorithms. *Advances in neural information processing systems*, v. 25, 2012.
- [Sun et al. 2023]SUN, B. et al. Integrating vegetation phenological characteristics and polarization features with object-oriented techniques for grassland type identification. *Geo-spatial Information Science*, Taylor & Francis, p. 1–17, 2023.
- [Székely et al. 2023]SZÉKELY, Á. et al. Temporal changes of leaf spectral properties and rapid chlorophyll—a fluorescence under natural cold stress in rice seedlings. *Plants*, MDPI, v. 12, n. 13, p. 2415, 2023.

- [Szeliski 2010]SZELISKI, R. *Computer vision: algorithms and applications*. [S.l.]: Springer Science & Business Media, 2010.
- [Tisot 2005]TISOT, L. S. G. A. R. F. . D. A. Discrimination of sugarcane varieties in southeastern brazil with eo-1 hyperion data. *Remote sensing of Environment*, Elsevier, v. 94, n. 4, p. 523–534, 2005.
- [Verma et al. 2022]VERMA, D. et al. Varietal discrimination, acreage estimation and yield prediction of basmati aromatic rice in north-western india using satellite data. In: *Remote Sensing of Agriculture and Land Cover/Land Use Changes in South and Southeast Asian Countries*. [S.l.]: Springer, 2022. p. 163–186.
- [Wang et al. 2017]WANG, R. et al. Deep & cross network for ad click predictions. In: *Proceedings of the ADKDD'17*. [S.l.: s.n.], 2017. p. 1–7.
- [Wijayanto et al. 2023]WIJAYANTO, A. K. et al. Machine learning for precise rice variety classification in tropical environments using uav-based multispectral sensing. *AgriEngineering*, MDPI, v. 5, n. 4, p. 2000–2019, 2023.
- [Xu 2006]XU, H. Modification of normalised difference water index (ndwi) to enhance open water features in remotely sensed imagery. *International journal of remote sensing*, Taylor & Francis, v. 27, n. 14, p. 3025–3033, 2006.
- [Youngentob et al. 2011]YOUNGENTOB, K. N. et al. Mapping two eucalyptus subgenera using multiple endmember spectral mixture analysis and continuum-removed imaging spectrometry data. *Remote Sensing of Environment*, Elsevier, v. 115, n. 5, p. 1115–1128, 2011.
- [Zhang et al. 2023]ZHANG, W. et al. Gacnet: Generate adversarial-driven cross-aware network for hyperspectral wheat variety identification. *IEEE Transactions on Geoscience and Remote Sensing*, IEEE, 2023.
- [Zhang et al. 2022]ZHANG, W. et al. Sstnet: Spatial, spectral, and texture aware attention network using hyperspectral image for corn variety identification. *IEEE Geoscience and Remote Sensing Letters*, IEEE, v. 19, p. 1–5, 2022.
- [Zimba 2008]ZIMBA, R. M. J. R. P. V. J. C. V. E. P. R. J. P. V. Discrimination of sugarcane varieties with pigment profiles and high resolution, hyperspectral leaf reflectance data. 2008.