

**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

Análise comparativa de redes neurais convolucionais na predição do teor de nitrogênio foliar em cultivos de morango através de imagens RGB

Jamile Raquel Regazzo

Dissertação apresentada para obtenção do título de
Mestra em Ciências. Área de concentração: Engenharia
de Sistemas Agrícolas

**Piracicaba
2023**

Jamile Raquel Regazzo
Engenheira de Biosistemas

**Análise comparativa de redes neurais convolucionais na predição do teor de
nitrogênio foliar em cultivos de morango através de imagens RGB**

versão revisada de acordo com a Resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **MURILO MESQUITA BAESSO**

Dissertação apresentada para obtenção do título de
Mestra em Ciências. Área de concentração: Engenharia
de Sistemas Agrícolas

Piracicaba
2023

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP

Regazzo, Jamile Raquel

Análise comparativa de redes neurais convolucionais na predição do teor de nitrogênio foliar em cultivos de morango através de imagens RGB / Jamile Raquel Regazzo. - - versão revisada de acordo com a Resolução CoPGr 6018 de 2011. Piracicaba, 2023.

68 p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura “Luiz de Queiroz”.

1. Adubação nitrogenada 2. Aprendizado de máquina 3. Resnet -50 I. Título

DEDICATÓRIA

Dedico este trabalho aos meus pais Edina e Márcio, a minha irmã Carolina, aos meus avós Sônia e Decino. Uma pequena homenagem a todos vocês que estiveram ao meu lado, me apoiando e acreditando em meu potencial. Ao longo da minha jornada, cada um de vocês desempenhou um papel fundamental, me incentivando a perseguir meus sonhos. Obrigada por ser minha família, por estarem sempre presentes e por acreditarem em mim. O amor e apoio incondicionais são tesouros que levarei comigo para sempre.

AGRADECIMENTOS

Agradeço a Deus, que tem sido minha luz e guia durante toda minha jornada, por ter me concedido sabedoria, força e determinação para trilhar meu caminho.

Ao professor Murilo, por toda paciência, ensinamentos e confiança durante o período do mestrado.

À Professora Tamara e à Caroline pela parceria no experimento da cultura do morango.

A todos os professores do curso por generosamente compartilharem seu conhecimento, o qual foi fundamental para o desenvolvimento teórico necessário para a elaboração desta dissertação.

Aos funcionários do Departamento de Engenharia de Biosistemas FZEA USP, em especial, aos técnicos de laboratórios Carlos, Edson, e Ana, sempre de prontidão em auxiliar nas atividades que surgiram durante o mestrado.

Aos amigos e colegas do Laboratório de Máquinas Agrícolas e Agricultura de Precisão (LAMAP FZEA-USP), em especial ao Thiago e Marcos, agradeço pela oportunidade de aprendizado e pela jornada compartilhada na pós-graduação.

A todos os amigos da pós-graduação, em especial a Lilian, Anésia, Alex, Gabriel, Juliana, Camila, vocês estiveram ao meu lado durante toda essa fase, compartilhando alegrias e desafios.

À Universidade de São Paulo por fornecer o ambiente acadêmico propício para o desenvolvimento do meu mestrado.

Ao apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico - Código de Financiamento 001.

A todos que contribuíram de forma direta ou indireta na realização do meu mestrado.

Muito obrigada!

EPÍGRAFE

*“Sede nosso auxílio em cada manhã e nosso
socorro no tempo da tribulação.”*

Is.33, 2-10

SUMÁRIO

RESUMO	8
ABSTRACT	9
LISTA DE FIGURAS	10
LISTA DE TABELAS	12
LISTA DE ABREVIATURAS E SIGLAS	13
LISTA DE SÍMBOLOS	14
1 INTRODUÇÃO	15
2 REVISÃO BIBLIOGRÁFICA	17
2.1. A agricultura no Brasil.....	17
2.2. Importância do nitrogênio para morangos	18
2.3. Imagem digital	19
2.4. Visão computacional	20
2.5. Inteligência Artificial.....	21
2.5.1. Aprendizado de Máquina.....	21
2.5.2. Redes neurais artificiais	22
2.5.3. Aprendizado profundo	23
2.5.4. Rede neural convulocional – CNN.....	24
2.5.5. Rede neural residual – Resnet 50.....	26
2.6. Métricas de avaliação	27
3 MATERIAL E METÓDOS	33
3.1. Caracterização do experimento para aquisição das imagens	33
3.2. Pré-processamento das imagens	35
3.3. Construção dos modelos computacionais	36
4 RESULTADOS E DISCUSSÕES	41
4.1. Análise química foliar.....	41
4.2. Coleta 1	43

4.2.1.	CNN própria	43
4.2.2.	Resnet-50	45
4.3.	Coleta 2	48
4.3.1.	CNN própria	48
4.3.2.	Resnet-50	51
4.4.	Coleta 3	54
4.4.1.	CNN própria	54
4.4.2.	Resnet-50	56
5	CONCLUSÃO	61
	REFERÊNCIAS	62

RESUMO

Análise comparativa de redes neurais convolucionais na predição do teor de nitrogênio foliar em cultivos de morango através de imagens RGB

A produção de morango no Brasil tem experimentado um crescimento significativo nos últimos anos, impulsionado pela demanda em constante expansão tanto no mercado interno quanto nas exportações. Nesse contexto, é crucial assegurar uma condição nutricional adequada para garantir altos níveis de produtividade, otimizar o uso de fertilizantes, aumentar a eficiência dos sistemas operacionais e promover a sustentabilidade no uso dos recursos naturais. Para atender a essa demanda, torna-se indispensável o uso de ferramentas tecnológicas capazes de determinar o estado nutricional por meio da extração de características de imagens digitais e aplicação de algoritmos. Essas abordagens não apenas reduzem significativamente o tempo necessário em comparação com as análises convencionais, mas também aprimoram a eficiência na aplicação de fertilizantes. Dentre os algoritmos de aprendizado de máquina utilizados para extrair características de imagens, destaca-se a rede neural convolucional (CNN), que tem sido amplamente estudada para classificação, detecção e segmentação de dados de interesse através de camadas convolucionais que fornecem informações mais eficientes e robustas. Assim, a CNN surge como uma alternativa viável para a determinação da condição nutricional das plantas. O objetivo deste estudo foi avaliar e comparar o desempenho de duas redes neurais convolucionais na predição de nitrogênio foliar na cultura do morango a partir de imagens RGB, analisando a acurácia e o erro de predição dos modelos. O delineamento experimental adotado foi de blocos casualizados, com três tratamentos e cinco repetições. A parcela experimental foi composta por dois vasos, contendo uma planta de morangueiro cada, com capacidade de 3 L (área de 0,02298 m² e diâmetro de 0,17 m), totalizando 30 vasos. Os tratamentos consistiram em 3 doses de adubação e foram nomeados de T1: 50% da adubação recomendada, para nitrogênio, T2: 100% da adubação controle e T3: 150% da adubação controle. A utilização da arquitetura Resnet-50 resultou em um desempenho superior em comparação com a rede neural própria, apresentando uma acurácia de 96% e 76%, respectivamente.

Palavras-chave: Adubação nitrogenada, Aprendizado de máquina, Resnet-50

ABSTRACT

Comparative analysis of convolutional neural networks in the prediction of leaf nitrogen content in strawberry crops through RGB images

Strawberry production in Brazil has experienced significant growth in recent years, driven by ever-expanding demand both in the domestic market and in exports. In this context, it is crucial to ensure an adequate nutritional condition to guarantee high levels of productivity, optimize the use of fertilizers, increase the efficiency of operational systems and promote sustainable use of natural resources. To meet this demand, the use of technological tools capable of determining nutritional status by extracting features from digital images and applying algorithms is essential. These approaches not only significantly reduce the time required compared to conventional analyses, but also improve the efficiency of fertilizer application. Among the machine learning algorithms used to extract image features, the convolutional neural network (CNN) stands out, which has been widely studied for classification, detection and segmentation of data of interest through convolutional layers that provide more efficient and accurate information. Thus, CNN emerges as a viable alternative for determining the nutritional status of plants. The aim of this study was to evaluate and compare the performance of two convolutional neural networks in accurately estimating different nitrogen doses in strawberry crops, analyzing the accuracy and prediction error of the models. The experimental design adopted was randomized blocks, with three treatments and five replications. The experimental plot consisted of two pots, containing one strawberry plant each, with a capacity of 3 L (area of 0.02298 m² and diameter of 0.17 m), totaling 30 pots. The treatments consisted of 3 doses of fertilization and were named T1: 50% of the fertilization recommended, for nitrogen, T2: 100% of the control fertilization and T3: 150% of the control fertilization. The use of the Resnet-50 architecture resulted in superior performance compared to the proprietary neural network, with an accuracy of 96% and 76%, respectively.

Keywords: Nitrogen fertilization, Machine learning, Resnet-50

LISTA DE FIGURAS

Figura 1. Representação do neurônio artificial	22
Figura 2. Estrutura básica de uma rede neural de convolução.	25
Figura 3. Estrutura da Resnet 50.....	26
Figura 4. Curvas características de operação do receptor com sensibilidade e especificidade variáveis.....	30
Figura 5. Valores de umidade e temperatura durante o período de execução do estudo	33
Figura 6. Croqui do experimento.	34
Figura 7. Folíolo do morango digitalizada com 1200 DPI.	34
Figura 8. Exemplo do banco de imagens formado pelos blocos da segmentação da folha do morango.	35
Figura 9. Fluxograma da segmentação das imagens do morango.	36
Figura 10. Processo de 5 vezes validação cruzada.	38
Figura 11. Fluxograma da visão geral do sistema proposto de aprendizagem profunda.	39
Figura 12. Exemplo do progresso do treinamento.	40
Figura 13. Gráfico de acurácia e perda da CNN própria da coleta 1.	43
Figura 14. Matriz de confusão da CNN própria para coleta 1.	44
Figura 15. Gráfico AUC dos tratamentos utilizados da coleta 1 usando a CNN própria.	45
Figura 16. Gráfico de acurácia e perda da Resnet 50 da coleta 1.	46
Figura 17. Matriz de confusão da Resnet 50 para coleta 1.	46
Figura 18. Gráfico AUC dos tratamentos utilizados da coleta 1 usando Resnet 50.	47
Figura 19. Gráfico de acurácia e perda da CNN própria da coleta 2.	49
Figura 20. Matriz de confusão da CNN própria para coleta 2.	50
Figura 21. Gráfico AUC dos tratamentos utilizados da coleta 2 usando a CNN própria.	50
Figura 22. Gráfico de acurácia e perda da Resnet 50 da coleta 2.	51
Figura 23. Matriz de confusão da Resnet 50 para coleta 2.	52
Figura 24. Gráfico AUC dos tratamentos utilizados da coleta 2 usando Resnet 50.	53
Figura 25. Gráfico de acurácia e perda da CNN própria da coleta 3.	54

Figura 26. Matriz de confusão da CNN própria para coleta 3.	55
Figura 27. Gráfico AUC dos tratamentos utilizados da coleta 3 usando a CNN própria.	55
Figura 29. Gráfico de acurácia e perda da Resnet 50 da coleta 3.	56
Figura 30. Matriz de confusão da Resnet 50 para coleta 3.	56
Figura 31. Gráfico AUC dos tratamentos utilizados da coleta 3 usando Resnet 50.	57

LISTA DE TABELAS

Tabela 1. Descrição dos componentes de um neurônio artificial.	23
Tabela 2. Exemplo de matriz de confusão, simulando 10 vetores de entrada de cada tratamento.	27
Tabela 3. Descrição das métricas de avaliação de desempenho.	30
Tabela 4. Classificação dos valores da AUC.	31
Tabela 5. Coletas das folhas para realização da digitalização.	34
Tabela 7. Opções de treinamento utilizadas no modelo convolucional.	39
Tabela 8. Resultado da análise de variância com as médias para os elementos considerados para análise foliar.	41
Tabela 9. Resultados obtidos ao utilizar diferentes métricas de avaliação para as folhas do morango.	48
Tabela 10. Resultados obtidos ao utilizar diferentes métricas de avaliação para as folhas do morango.	53
Tabela 11. Resultados obtidos ao utilizar diferentes métricas de avaliação para as folhas do morango.	57
Tabela 12. Resumo das acurácia geral para cada coleta.	58
Tabela 13. AUC para os tratamentos em diferentes coletas.	59

LISTA DE ABREVIATURAS E SIGLAS

ACC	Acurácia
AUC	Area Under the Curve
B	Boro
Ca	Cálcio
CNN	Rede Neural Convolucional
Cu	Cobre
DPI	Dot Per Inch
Fe	Ferro
FN	Falso Negativo
FP	Falso Positivo
K	Potássio
Mg	Magnésio
Mn	Manganês
Mo	Molibdênio
N	Nitrogênio
N	Nitrogênio
Na	Sódio
P	Fosfóro
PIB	Produto Interno Bruto
PRE	Precisão
RBB	Residual Building Block
ReLU	Rectified Linear Unit
Resnet	Rede Neural Residual
ROC	Receiver Operating Characteristic
S	Enxofre
SE	Sensibilidade
Si	Silício
TN	Verdadeiro Negativo
TP	Verdadeiro Positivo
Zn	Zinco

LISTA DE SÍMBOLOS

°C	Grau Celsius
L	Litros
M	Metro
m ²	Metro quadrado
mm	Milímetro

1 INTRODUÇÃO

O setor agrícola brasileiro desempenha um papel significativo na geração de empregos e renda, tanto no meio rural quanto nas áreas urbanas relacionadas ao agronegócio (EMBRAPA, 2020). Segundo IPEA (2023), as exportações brasileiras registraram um marco histórico, atingindo o valor de US\$ 10,22 bilhões, representando um aumento de 16,4% em relação ao mesmo período do ano anterior. Paralelamente, as importações também apresentaram um crescimento significativo, com um aumento de 37,1%, totalizando US\$ 1,53 bilhão.

Dentre as diversas culturas cultivadas no Brasil, o morango se destaca como uma cultura de grande relevância econômica e social. Nos últimos tempos, tem sido observado um aumento constante na produção de morangos no Brasil. Atualmente, essa cultura ocupa uma parcela significativa da área de produção de frutas na América do Sul, correspondendo a cerca de 40% do total, o que equivale a aproximadamente 3.500 hectares (ANTUNES et al., 2016). Para atender a essa demanda, têm sido realizados investimentos em tecnologia e pesquisa, visando o desenvolvimento de variedades adaptadas às condições climáticas do Brasil.

Um manejo nutricional adequado desempenha um papel crucial no crescimento saudável do morangueiro e na obtenção de uma produção de alta qualidade. A disponibilidade adequada de nutrientes, como nitrogênio, fósforo, potássio e micronutrientes, tem um impacto direto no desenvolvimento das plantas, na formação de flores e frutos, na resistência a doenças e pragas, bem como na qualidade sensorial dos morangos colhidos (VIGNOLO et al., 2011).

A fim de assegurar o contínuo crescimento expressivo na produção de morangos, é crucial implementar uma abordagem precisa em seu manejo nutricional, atendendo às exigências específicas da cultura e fornecendo os nutrientes necessários no momento exato. Isso favorecerá que as fases de crescimento e reprodução não sejam prejudicadas, o que poderia levar a uma redução da produtividade. De acordo com Romualdo et al. (2014), a determinação do momento oportuno para aplicação de nutrientes pode corrigir eventuais deficiências que possam ocorrer no decorrer do desenvolvimento das plantas, evitando falhas na produção, bem como economizando na aplicação de fertilizantes e otimizando seu uso e práticas operacionais.

As abordagens convencionais para avaliar o estado nutricional das plantas são, em geral, destrutivas, trabalhosas e requerem equipamentos e insumos específicos. Segundo Cheng et al. (2017), essas análises são complexas, demandam mais tempo e a presença de

especialistas, além do uso de reagentes químicos. Devido à importância da cultura do morango e à necessidade de métodos mais acessíveis, rápidos e eficientes para determinar seu estado nutricional, o desenvolvimento de métodos de detecção eficazes é de grande interesse (LIU et al., 2021).

Nesse sentido, os métodos de aprendizado computacional profundo para extração de características de imagens surgem como uma alternativa viável para resolver esse problema. Conforme Pouladzadeh et.al (2017), o aprendizado profundo tem sido amplamente utilizado para resolver problemas complexos na área agrícola. Entre os algoritmos de aprendizado profundo, a rede neural convolucional (CNN) é amplamente empregada para extrair características de imagens (Teng et al., 2019). Subeesh et al. (2022) mencionam que a rede neural convolucional profunda é um tipo de inteligência artificial que vai além das limitações do processamento de imagem convencional, sendo capaz de processar grandes quantidades de dados com resultados satisfatórios em relação aos limites computacionais.

Durante o processamento e análise de imagens por meio de redes neurais convolucionais (CNN), é possível extrair várias características que auxiliam na obtenção de informações relevantes para fins nutricionais. Especificamente, essas características relacionando-se aos índices baseados em cor. Shin et al. (2021) estudaram uma abordagem de aprendizado profundo para detecção de doença de oídio baseada em imagem RGB em folhas de morango. Os resultados experimentais mostraram que as técnicas de CNN são uma ferramenta promissora para o desenvolvimento de uma estratégia implantável em campo para detecção de doença de oídio em folhas de morangueiro.

Durante o processamento e análise de imagens utilizando CNN, é possível identificar e extrair diversas características que são úteis para obter informações relevantes no contexto nutricional. Essa abordagem oferece uma maneira eficaz de analisar e interpretar os aspectos visuais das imagens, contribuindo para uma avaliação mais precisa das necessidades nutricionais das culturas.

Com isso, o objetivo deste estudo foi avaliar e comparar o desempenho de duas redes neurais convolucionais na predição de nitrogênio foliar na cultura do morango a partir de imagens RGB, analisando a acurácia e o erro de predição dos modelos.

2 REVISÃO BIBLIOGRÁFICA

2.1. A agricultura no Brasil

A agricultura no Brasil é amplamente reconhecida por sua competitividade e seu papel crucial na geração de empregos, riquezas, alimentos, fibras e bioenergia tanto para o país como para outras nações. É um dos setores que mais contribuem para o crescimento do Produto Interno Bruto (PIB) nacional, representando aproximadamente 21% do valor total das riquezas produzidas. Além disso, a agricultura responde por cerca de um quinto de todos os empregos no país e contribui significativamente para as exportações brasileiras, totalizando US\$ 96,7 bilhões em 2019, ou seja, cerca de 43,2% do valor total exportado (MAPA, 2020).

A horticultura desempenha um papel de extrema importância no contexto agrícola brasileiro, contribuindo para a segurança alimentar, o desenvolvimento econômico e a geração de empregos. Além disso, a horticultura tem um impacto significativo na economia do país, uma vez que gera empregos em toda a cadeia produtiva, desde a produção até a comercialização. De acordo com dados IBGE (2017), a produção de hortaliças e frutas no Brasil registrou crescimento constante nos últimos anos, destacando-se como um setor promissor e com grande potencial de expansão.

Assim, dentre as hortaliças, o morango desempenha um papel significativo na agricultura brasileira, sendo uma cultura de grande importância econômica e social. A cultura do morangueiro (*Fragaria × ananassa*) é amplamente cultivada em todo o mundo e sua área de produção continua a crescer a cada ano, impulsionada pela apreciação dos consumidores pela sua cor, aroma e sabor (PALENCIA et al., 2010). Além disso, o morango é reconhecido como uma fonte de vitaminas e minerais, o que aumenta ainda mais seu valor nutricional (SINGH et al., 2010).

Na região sul de Minas Gerais, Brasil, destaca-se como a principal produtora de morangos, sendo responsável por cerca de 95% da produção estadual, o que equivale a aproximadamente 120 mil toneladas de morangos cultivados anualmente (ANTUNES et al., 2021). Essa região se sobressai na produção da hortaliça devido ao seu clima favorável ao cultivo e à localização estratégica para escoamento do produto para grandes centros comerciais. Ao longo dos últimos anos, o Brasil tem testemunhado um crescimento notável na área cultivada e na produção de morangos, especialmente em pequenas propriedades (RICHTER et al., 2018). Em 2021, o país colheu cerca de 165.440 toneladas de frutas, com Minas Gerais destacando-se como um dos principais estados produtores, contribuindo significativamente para a produção nacional (SOUZA, 2022).

2.2. Importância do nitrogênio para morangos

A folha pode ser considerada como órgão que apresenta de forma mais explícita os distúrbios fisiológicos (PRÁ, 2020). Na ciência das plantas, a folha da planta tem sido utilizada amplamente como um parâmetro de saúde (AZADNIA; KHEIRALIPOUR, 2021). Também conhecida como uma parte fundamental e importante para a tarefa de identificação de plantas, já que são acessíveis e visíveis durante todo o ano. Vários atributos da folha têm sido utilizados para o reconhecimento da planta, como forma, cor e textura.

O princípio da diagnose foliar é a relação entre o suprimento de nutrientes e os índices dos elementos nas folhas. Desta forma, de acordo com os níveis presentes, as características se modificam. Há fatores que influencia os níveis dos nutrientes nas folhas, como a área a ser analisada, a idade, existe a tendência de maior concentração de nutrientes nos tecidos mais novos (PRÁ, 2020).

O nitrogênio (N) é um dos macronutrientes mais essenciais para as plantas, desempenhando um papel crucial como base para a formação de compostos essenciais, principalmente na estrutura de nucleotídeos e proteínas. Além disso, ele faz parte da molécula de clorofila, fundamental para a fotossíntese, que, por sua vez, é essencial para a vida vegetal. Por essa razão, o nitrogênio limita o crescimento e desenvolvimento das plantas de forma crítica. No entanto, a aplicação desse nutriente em sistemas agrícolas deve ser feita de maneira racional, com critérios técnicos e diagnósticos rápidos e precisos do estado nutricional atual, uma vez que sua adição acarreta custos energéticos e ambientais elevados (XIE et al., 2022).

Embora as plantas normalmente absorvam nitrogênio do solo na forma de amônio (NH_4^+) e nitrato (NO_3^-), é essencial identificar o estado nutricional da cultura para estabelecer aplicações mais precisas de fertilizantes nitrogenados, a fim de atender à demanda de crescimento rápido e aumento de produtividade. Isso contribui para alcançar a sustentabilidade e a rentabilidade desejadas nas propriedades agrícolas. A determinação desse estado nutricional auxilia nas técnicas de aplicação variável, como a agricultura de precisão, que se baseia na variabilidade espacial e temporal dos nutrientes, como a porcentagem de nitrogênio, para determinar a dosagem exata de fertilizante (PULLANAGARI et al., 2021).

O nitrogênio tem sido identificado como um fator crítico que limita a produtividade do morango. A cultura do morango é uma das mais sensíveis na produção hortícola e o manejo de nutrientes é um fator chave para garantir altos rendimentos e qualidade dos frutos.

Sendo assim, a compreensão da resposta do morango ao nitrogênio é crucial para tomar decisões de manejo adequadas, considerando que o nitrogênio é um insumo caro e representa um risco ambiental quando aplicado em excesso (DURNER, 2019). Em condições de baixa disponibilidade, o nitrogênio influencia negativamente a biomassa total, reduz o tamanho dos frutos e limita a produtividade da cultura do morango (DENG et. al, 2002). Portanto, a detecção precoce de deficiências nutricionais no morangueiro e a implementação de medidas correspondentes são de extrema importância para a produção agrícola.

O estado nutricional da planta tem um impacto direto no desempenho produtivo de uma cultura. Para garantir melhores resultados, é fundamental monitorar com precisão a aplicação de nitrogênio nas culturas e desenvolver ferramentas operacionais que auxiliem na determinação das doses ideais e nos momentos adequados para essa aplicação. Essas ferramentas devem processar informações e estimar com a maior precisão possível a real necessidade de nitrogênio. A falta desse nutriente na cultura resulta em redução do crescimento vegetativo e da produtividade, devido à sua alta importância (PEREIRA et al., 2022).

Mundialmente, estima-se que doenças, insetos e plantas invasoras possam reduzir a produção de, em média, 30 a 40% de todas as culturas. Essas perdas são frequentemente menores nos países desenvolvidos e mais alta nos países em desenvolvimento. E a partir desse percentual, cerca de 15% estão relacionados com doenças de planta, a somatória anual das perdas no mundo todo provocadas por doenças nas culturas pode chegar a aproximadamente 200 bilhões de dólares. Assim sendo, a detecção de doenças e deficiências de plantas demanda diagnóstico no campo em um tempo estipulado para preservar a cultura (GARRIDO et. al, 2017).

Em via de regra, a forma mais usual na identificação de doenças em folhas de morangueiro é por meio da estimativa visual (Sankaran et al., 2010). Normalmente, os agricultores estimam visualmente sua presença no campo; contudo, é laborioso determinar se as folhas de morango estão doentes nos estágios iniciais. Com isso, a cada dia surgem novas pesquisas a fim de estimar o nível de deficiência nutricional das culturas, utilizando suas características espectrais.

2.3. Imagem digital

As imagens digitais são representações bidimensionais de imagens tridimensionais, capturadas por dispositivos como câmeras digitais, scanners e aparelhos de raio-X. De acordo com Conci et al. (2008), essas imagens podem ser monocromáticas, multibandas ou coloridas,

sendo armazenadas como uma sequência de dígitos binários, com valores de 0 (zero) e 1 (um). Esses dígitos são organizados em uma matriz de bits binários, formando os pixels, que representam a intensidade de luz e a tonalidade de cores da imagem e ao agrupar os pixels, a imagem é formada (MACHADO et. al, 2004).

No contexto das plantas, a radiação solar que atinge as folhas ou a cobertura vegetal é composta por uma variedade de comprimentos de onda. No entanto, no espectro visível da luz, as folhas absorvem, refletem e transmitem seletivamente diferentes comprimentos de onda. A porção da radiação que é refletida de volta é conhecida como radiação refletida e contém informações espectrais específicas da cultura em estudo (BERTOLINI et al., 2021). Analisar a radiação refletida em diferentes comprimentos de onda oferece valiosas informações sobre o estado de hidratação, nutricional e outros parâmetros de interesse, permitindo monitorar o desempenho das plantas (FU et al., 2021).

Existe uma forte relação entre o teor de clorofila das folhas, a refletância espectral na faixa do espectro visível e o teor de nitrogênio nas plantas. Devido a essa correlação significativa, a refletância em comprimentos de onda específicos, bem como os índices de vegetação calculados a partir desses comprimentos de onda, têm sido amplamente utilizados como parâmetros na análise de imagens para determinar o estado de nitrogênio das plantas (WANG et al., 2020).

2.4. Visão computacional

A visão computacional é uma área da inteligência artificial que se concentra na capacidade dos sistemas de computador de adquirir, processar e interpretar informações visuais de maneira semelhante ao ser humano. Ela envolve o desenvolvimento de algoritmos e técnicas que permitem aos computadores entender e analisar imagens e vídeos para extrair informações úteis, como reconhecimento de padrões (BACKES et al., 2016).

Podendo ser compreendida como um campo emergente da ciência que se dedica a fornecer habilidades de "visão" a máquinas e robôs. Seu objetivo é desenvolver teorias e métodos para extrair informações significativas de imagens ou do ambiente ao redor, permitindo o reconhecimento, manipulação e análise dos objetos presentes nesse meio. Por meio da utilização de câmeras, vídeos, sensores e outros dispositivos, ela é capaz de extrair informações relevantes para automatizar a tomada de decisões em um sistema (BORTH et al., 2014).

A visão computacional tem como entrada de dados uma imagem e sua saída é a interpretação parcial ou total dessa imagem. Tem também como finalidade de reproduzir a

capacidade humana de reconhecimento de imagens, utilizando diversas técnicas computacionais que vão desde o processamento de imagens até a construção de modelos matemáticos. Pesquisadores desenvolveram técnicas para aprimorar as imagens capturadas e geradas, buscando recuperar informações tridimensionais e a aparência dos objetos presentes nas imagens (GALVÃO et al., 2018).

Essa área de pesquisa abrange diferentes etapas, incluindo aquisição de imagens, pré-processamento, segmentação, extração de características e reconhecimento de padrões (GALVÃO et al., 2018). O objetivo é criar sistemas que possam compreender e interpretar as informações visuais de forma similar ao ser humano.

2.5. Inteligência Artificial

2.5.1. Aprendizado de Máquina

Há várias décadas existem técnicas de aprendizado de máquina e com a evolução do hardware e software, essas técnicas foram aprimoradas permitindo o uso de ferramentas com processamento intensivo. O aprendizado de máquina é uma ferramenta alternativa aos algoritmos tradicionais, pois permite a análise de diferentes cenários em redes desafiadoras sem a necessidade de programação de regras de análise (BOCHIE et al., 2020).

O aprendizado de máquina é um processo que envolve a obtenção de uma representação matemática que modele o comportamento de uma função por meio do treinamento. Durante o treinamento, um modelo é ajustado a partir de amostras com múltiplos atributos, de forma a prever um conjunto inédito de amostras, exercer uma ação autônoma ou extrair informações relevantes (MAO et al., 2018). A seleção de atributos é crucial para o bom desempenho do modelo, por isso é uma área de pesquisa extensa.

Os algoritmos de aprendizado de máquina podem ser supervisionados, não supervisionados ou por reforço. No aprendizado supervisionado, o algoritmo tem acesso a um conjunto de dados rotulados, permitindo que ajuste seus parâmetros para reproduzir as mesmas saídas. No aprendizado não supervisionado, o conjunto de dados não possui rótulos, e os algoritmos buscam relações e características para classificar internamente os elementos. Já no aprendizado por reforço, o modelo interage com o ambiente e os resultados são obtidos através da realimentação entre o sistema de aprendizado e o ambiente.

2.5.2. Redes neurais artificiais

Redes neurais artificiais são modelos computacionais que se inspiram na estrutura e funcionamento do cérebro humano (NORVIG et. al, 2013) para realizar tarefas de aprendizado e reconhecimento de padrões. Elas são compostas por um conjunto de unidades de processamento simples, chamadas de neurônios artificiais, que são interconectadas por meio de conexões sinápticas artificiais.

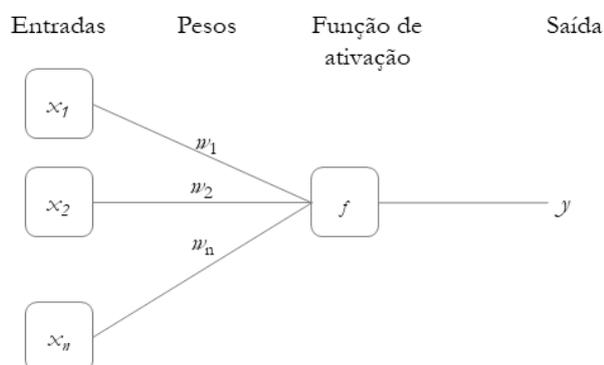
Cada neurônio artificial recebe uma ou mais entradas, processa essas entradas e produz uma saída que é transmitida para outros neurônios da rede. Por meio da adaptação dos pesos das conexões sinápticas, a rede é capaz de aprender a realizar tarefas complexas de classificação, previsão, reconhecimento de padrões, entre outras.

As redes neurais artificiais têm sido aplicadas em uma grande variedade de áreas, incluindo visão computacional, processamento de linguagem natural, reconhecimento de fala, reconhecimento de caracteres manuscritos, detecção de fraudes, entre outras. Elas são uma das principais técnicas utilizadas em inteligência artificial e aprendizado de máquina.

A base das redes neurais artificiais é o neurônio artificial, também conhecido como perceptron. O neurônio artificial é uma unidade de processamento que recebe uma ou mais entradas, aplica uma função de ativação e produz uma saída (SILVA et al., 2010).

O neurônio artificial é composto por três elementos principais, como exemplifica a Figura 1,: as entradas (x_1, x_2, \dots, x_n), os pesos sinápticos (w_1, w_2, \dots, w_n) e a função de ativação (f). Cada entrada é multiplicada por um peso sináptico correspondente e o resultado dessas multiplicações é somado para produzir um valor de entrada líquido. Esse valor de entrada líquido é então aplicado à função de ativação para produzir a saída do neurônio.

Figura 1. Representação do neurônio artificial.



Fonte: Autoria própria.

Na tabela 1 estão dispostos os componentes básicos de um neurônio artificial:

Tabela 1. Descrição dos componentes de um neurônio artificial.

Componente	Representação	Descrição
Entradas	x_n	sinais de entrada que são fornecidos ao neurônio artificial. Cada entrada é multiplicada por um peso sináptico correspondente.
Pesos sinápticos	w_n	valores numéricos que são atribuídos a cada entrada. Os pesos sinápticos são ajustados durante o processo de treinamento para que a rede neural possa produzir saídas precisas para um conjunto de entradas.
Função de ativação	f	é a função que é aplicada ao valor de entrada líquido do neurônio para produzir sua saída.
Saída do neurônio	y	é o valor produzido pelo neurônio artificial após a aplicação da função de ativação ao valor de entrada líquido.

Fonte: (SILVA et al., 2010).

Existem vários tipos de funções de ativação que podem ser utilizadas em neurônios artificiais, sendo as mais comuns a função sigmoide, a função degrau e a função ReLU (Rectified Linear Unit).

O processo de treinamento de uma rede neural artificial envolve a adaptação dos pesos sinápticos para que a rede possa produzir saídas mais precisas para um determinado conjunto de entradas. Isso é feito através de algoritmos de aprendizado supervisionado, como o backpropagation, que ajustam os pesos sinápticos com base no erro entre a saída produzida pela rede e a saída desejada (MELO, 2021).

2.5.3. Aprendizado profundo

Nos últimos cinco anos, houve grandes avanços nas técnicas de ponta para realizar a análise de imagem, principalmente com os computadores hoje que torna possível a classificação de imagens automaticamente e descrição dos vários elementos de uma imagem. Isso é realizado mediante a tecnologia *deep learning* que se baseia em redes neurais artificiais profundas e complexas para realizar tarefas de aprendizado e reconhecimento de padrões (ABDULLAHI et. al, 2022).

O aprendizado profundo está fazendo grandes avanços na solução de problemas que resistiram às melhores tentativas da comunidade de inteligência artificial por muitos anos. Acabou sendo muito bom em descobrir estruturas intrincadas em dados de alta dimensão e, portanto, aplicável a muitos domínios da ciência, negócios e governo. O aprendizado profundo é capaz de realizar tarefas de aprendizado de máquina de alto nível, como

reconhecimento de voz, processamento de linguagem natural, reconhecimento de imagens, análise de sentimentos, entre outras. Ele é usado em aplicações que envolvem grandes quantidades de dados e que exigem alto poder computacional para processamento, como análise de dados em tempo real, detecção de fraudes, diagnóstico médico, entre outros (MUELLER et al., 2019).

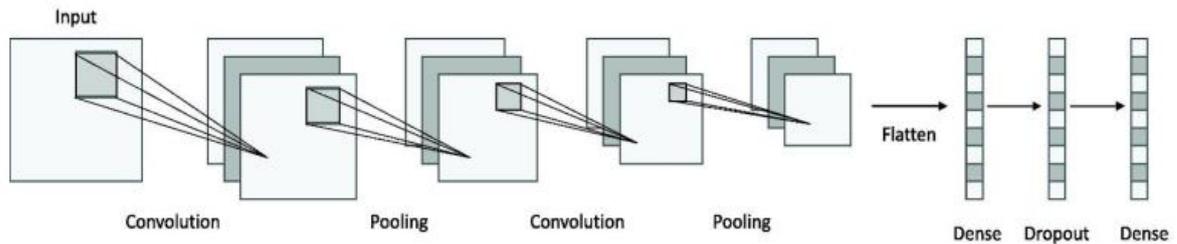
Uma das principais vantagens do aprendizado profundo é que ele é capaz de aprender automaticamente a partir de dados brutos, sem a necessidade de pré-processamento manual ou extração de recursos. Isso torna o processo de desenvolvimento de modelos de aprendizado de máquina mais eficiente e escalável (DWIVEDI et al., 2018). No entanto, o aprendizado profundo requer grandes quantidades de dados e recursos computacionais para treinar modelos complexos, o que pode ser um desafio em muitas aplicações. Além disso, a interpretabilidade dos modelos de aprendizado profundo pode ser um desafio, pois eles são muitas vezes considerados caixas-pretas, ou seja, é difícil entender como eles chegaram a uma determinada previsão ou decisão.

O aprendizado profundo é uma subcategoria do aprendizado de máquinas que se baseia em redes neurais profundas e complexas para realizar tarefas de aprendizado e reconhecimento de padrões. Enquanto o aprendizado de máquina pode ser usado em uma variedade de tarefas, desde classificação até regressão, o aprendizado profundo é geralmente usado em tarefas que envolvem grandes quantidades de dados e padrões complexos, como reconhecimento de fala, visão computacional, processamento de linguagem natural e outros problemas de aprendizado não supervisionado (PRÁ, 2020).

2.5.4. Rede neural convulucional – CNN

As redes neurais convolucionais são algoritmos avançados de aprendizado profundo que foram desenvolvidos para processar dados, incluindo imagens coloridas. Uma CNN é composta por várias camadas convolucionais, onde cada unidade em um mapa está conectada a partes locais das características anteriores por meio de pesos ou filtros, como segue na Figura 2. Essa estrutura permite que as CNNs capturem e expressem com precisão padrões espaciais em dados, o que as torna uma ferramenta poderosa para análise de imagens (LECUN et al., 2015).

Figura 2. Estrutura básica de uma rede neural de convolução.



Fonte: (RODRIGUES et al., 2022).

As redes neurais possuem uma estrutura dividida em duas etapas. A primeira etapa é conhecida como aprendizado de atributos ou características (feature learning), enquanto a segunda etapa é chamada de classificação. Na etapa de aprendizado de atributos, o modelo é treinado para reconhecer os detalhes das imagens, ou seja, aprender suas características distintas. Essas características são então utilizadas como entrada para a segunda etapa da rede, que é responsável por realizar a classificação das imagens. Na primeira etapa, o modelo utiliza camadas convolucionais e de *downsampling* (subamostragem) para processar as imagens e extrair suas características relevantes. Já na segunda etapa, são utilizadas camadas de uma rede totalmente conectada ou densa para realizar a classificação com base nas características aprendidas anteriormente (ZAFAR et al., 2018).

No campo da análise de dados e reconhecimento de imagens, as CNNs têm sido amplamente exploradas devido à sua capacidade de lidar com imagens de alta dimensão e reduzir a complexidade do modelo de rede. Elas são capazes de processar imagens diretamente como entrada, evitando abordagens mais complexas usadas em algoritmos tradicionais. Além disso, as CNNs demonstram um alto grau de invariância nos dados de saída, o que é vantajoso no processamento de imagens (DONG et al., 2021).

No contexto agrícola, as CNNs são utilizadas para detectar o estado nutricional das plantas por meio de imagens, fornecendo informações precisas para o manejo adequado das culturas. Estudos têm sido conduzidos para estimar o teor de nitrogênio em folhas de pepino (*Cucumis sativus L.*) e avaliar o teor de clorofila em folhas de milho, utilizando CNN em combinação com diferentes variáveis e sensores ópticos. Essas abordagens têm se mostrado eficientes para a detecção precoce de níveis de nutrientes e a estimativa precisa do conteúdo de clorofila, contribuindo para o monitoramento em tempo real das culturas e o aumento do rendimento da produção agrícola (SABZI et al., 2021).

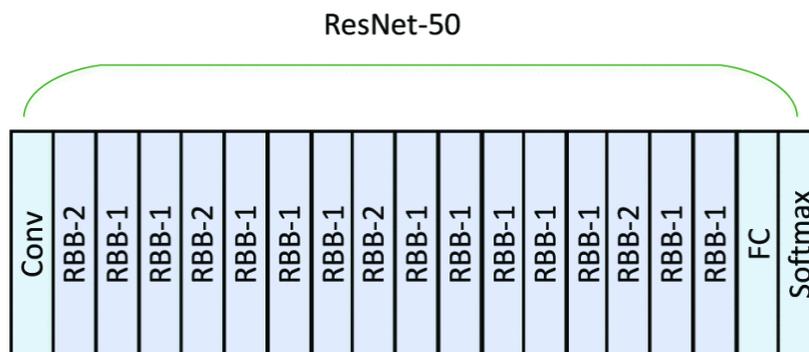
A aplicação das CNN no processamento de imagens RGB e a extração de informações relevantes têm se mostrado uma alternativa econômica e eficaz para o monitoramento de diversas culturas, incluindo trigo de inverno. Essa metodologia oferece estimativas precisas de

índices, como o índice de área foliar, e permite a obtenção de dados confiáveis com menor incerteza em comparação com os métodos convencionais (LI et al., 2021). Em resumo, as redes neurais convolucionais são ferramentas poderosas para análise de imagens no campo agrícola, contribuindo para melhorar a eficiência e a precisão do monitoramento e manejo das culturas.

2.5.5. Rede neural residual – Resnet 50

A ResNet-50, Figura 3, é uma arquitetura avançada de rede neural convolucional (CNN) que foi desenvolvida para melhorar o desempenho em tarefas de reconhecimento de imagens. Essa arquitetura foi desenvolvida com base na ideia específica de que redes mais profundas enfrentam problemas de degradação de desempenho (LIU et al., 2020).

Figura 3. Estrutura da Resnet 50.



Fonte: (LIU et al., 2020).

Identificou-se que ao adicionar camadas extras a redes mais profundas que realizem um mapeamento de identidade (ou seja, preservem a informação original), isso não resultará em uma degradação significativa do desempenho. No entanto, é desafiador ajustar esse mapeamento de identidade quando poucas camadas estão sendo adicionadas (HE et al., 2016).

Com a finalidade de solucionar esse desafio, He et al. (2016) introduziram um bloco de construção chamado *Residual Building Block* (RBB). Cada RBB possui uma conexão de atalho, que permite que a informação original seja preservada e transmitida para camadas posteriores. Essa conexão de atalho salta uma ou mais camadas convolucionais e permite que o gradiente de retropropagação flua diretamente para camadas anteriores durante o treinamento, evitando assim a degradação do desempenho.

Os RBBs são compostos por camadas convolucionais e de normalização. As camadas convolucionais são responsáveis por aprender e extrair características importantes das imagens, enquanto as camadas de normalização ajudam a melhorar a estabilidade e a generalização do modelo.

A Resnet-50 utiliza diferentes tamanhos de filtros convolucionais em suas camadas, permitindo que a rede capture informações em diferentes escalas e níveis de detalhe. Além disso, a arquitetura possui camadas de *pooling* e camadas totalmente conectadas no final para realizar a classificação final das imagens (PRÁ, 2020).

A presença dos blocos residuais na Resnet-50 permite que a rede aprenda representações mais profundas e complexas, o que ajuda a melhorar o desempenho em tarefas de reconhecimento de imagens, como classificação e detecção.

2.6. Métricas de avaliação

O desempenho de um modelo de Rede Neural Convolucional (CNN) é frequentemente avaliado por meio de métricas de qualidade de predição (XIE et al., 2021). Na literatura existem diversas métricas diferentes, podendo ser utilizadas individualmente ou em conjunto para possibilitar uma melhor avaliação do modelo.

A matriz de confusão é uma matriz quadrática de números que expressam a quantidade de unidades amostrais, associada a uma dada categoria durante o processo de classificação efetuado e à categoria real a que pertencem essas unidades, exemplificada na Tabela 2 (CONGALTON, 1991). Essa matriz fornece uma visão não apenas dos erros cometidos pelo classificador, mas quais os tipos de erros são cometidos.

Tabela 2. Exemplo de matriz de confusão, simulando 10 vetores de entrada de cada tratamento.

Valor estimado	Valor referência					Erros de inclusão (%)
	A	B	C	D	E	
A	10	1	0	0	0	9
B	0	8	3	0	1	33
C	0	0	7	0	0	0
D	0	1	0	10	0	9
E	0	0	0	0	9	0
Erros de omissão (%)	0	20	30	0	10	Exatidão global= 88%

Fonte: (BAESSO, 2005).

Ao analisar uma matriz de confusão, é possível identificar dois tipos de erros relacionados à classificação: erro de omissão, em que um objeto não é classificado na classe correta a que pertence, e erro de inclusão, em que um objeto é incorretamente incluído em uma classe à qual não pertence. Os erros de omissão podem ser observados nas colunas da matriz. Por exemplo, na classe C, o classificador cometeu 3 erros de omissão, ou seja, deixou

de classificar corretamente 3 objetos dessa classe. Já os erros de inclusão são identificados ao analisar as linhas verticais da matriz de confusão. No exemplo, foram registrados 4 erros de inclusão na classe B, o que significa que 4 objetos foram incorretamente classificados nessa classe.

A seguir, há a descrição métricas de desempenho derivadas da matriz de confusão usadas para avaliar os modelos de rede neural convolucional.

Acurácia é uma medida ampla da habilidade do modelo em fazer previsões corretas. Ela é calculada dividindo-se o número total de previsões corretas pelo número total de previsões feitas pelo modelo, conforme a equação 1 (NISBET et al., 2018).

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad \text{equação 1}$$

Em que,

$TP = \textit{verdadeiro positivo}$

$TN = \textit{verdadeiro negativo}$

$FP = \textit{Falso positivo}$

$FN = \textit{Falso negativo}$

Especificidade é a proporção de verdadeiros negativos sobre o total de verdadeiros negativos e falso positivos, ou seja, é a taxa total de negativos dentre os valores originais e previstos (SANTOS, 2020), segue a expressão na equação 2.

$$Sp = \frac{TN}{TN + FP} \quad \text{equação 2}$$

Em que,

$TN = \textit{verdadeiro negativo}$

$FP = \textit{Falso positivo}$

A precisão é uma medida que indica a confiabilidade das previsões feitas pelo modelo, ou seja, quantas das previsões realizadas pelo modelo são realmente corretas. É calculada usando uma equação específica que leva em consideração o número de previsões corretas e o número total de previsões (NISBET et al., 2018). Utilizando essa métrica significa dizer que a maioria das classes detectadas pelo modelo como positivo são verdadeiras, ou seja, o número de falso positivo é baixo, a expressão da precisão segue na equação 3.

$$Pre = \frac{TP}{TP + FP} \quad \text{equação 3}$$

Em que,

$TP = \text{verdadeiro positivo}$

$FP = \text{Falso positivo}$

A métrica *Recall* ou sensibilidade avalia a proporção de valores positivos corretamente previstos pelo modelo em relação ao total de valores positivos observados. Essa métrica reflete a capacidade do modelo em identificar corretamente todas as observações positivas, incluindo aquelas que poderiam ter sido erroneamente rotuladas como negativas (NISBET et al., 2018), conforme a equação 4.

$$Se = \frac{TP}{TP + FN} \quad \text{equação 4}$$

Em que,

$TP = \text{verdadeiro positivo}$

$FN = \text{Falso negativo}$

F1-score pode ser aplicada nos casos onde é necessária uma combinação entre as métricas *recall* e precisão. Ela utiliza uma média harmônica de precisão e *recall*, utilizando a equação 5:

$$F1 - Score = \frac{2 * Pre * Se}{Pre + Se} \quad \text{equação 5}$$

Em que,

$Pre = \text{precisão}$

$Se = \text{Sensibilidade}$

G-mean tem a finalidade de maximizar a precisão em cada uma das classes, mantendo o equilíbrio (SANTOS, 2020). Representado pela equação 6, onde é obtido a raiz do produto do *recall* pela especificidade.

$$G - mean = \sqrt{\text{recall} * \text{especificidade}} \quad \text{equação 6}$$

Na Tabela 3, estão demonstradas em resumo as fórmulas de das métricas de desempenho e suas expressões.

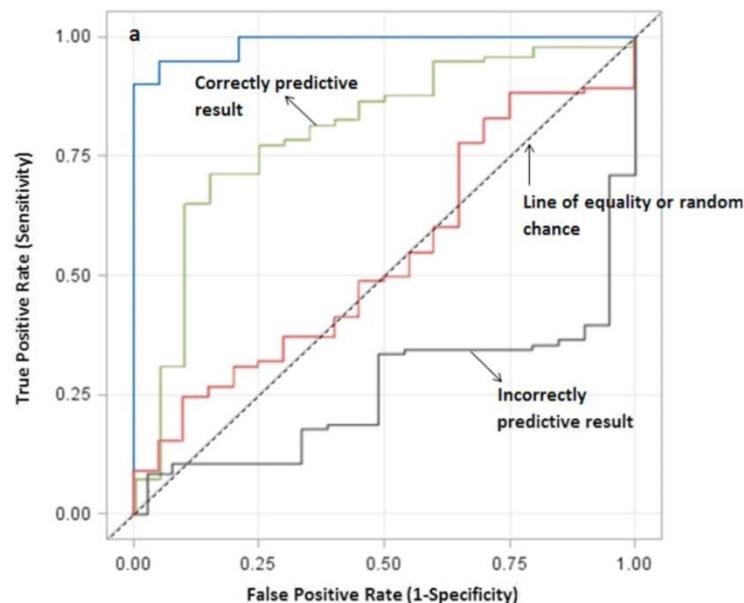
Tabela 3. Descrição das métricas de avaliação de desempenho.

Métrica	Fórmula	Descrição
Acurácia	$Acc = \frac{TP + TN}{TP + TN + FP + FN}$	A eficiência geral de um modelo.
Sensibilidade ou <i>Recall</i>	$Se = \frac{TP}{TP + FN}$	A eficiência de um modelo em amostras positivas.
Especificidade	$Sp = \frac{TN}{TN + FP}$	A eficiência de um modelo em amostras negativas.
Precisão	$Pre = \frac{TP}{TP + FP}$	A proporção de positivos reais em todos os positivos previstos pelo modelo.
F1 score	$F1 - Score = \frac{2 * Pre * Se}{Pre + Se}$	A média harmônica entre precisão e sensibilidade.
G-mean	$G - mean = \sqrt{recall * especificidade}$	Maximiza a precisão em cada uma das classes.

Fonte: Autoria própria

A métrica AUC (*Area Under the Curve*) é uma medida comumente utilizada na avaliação de modelos de classificação. Ela representa a área sob a curva ROC (*Receiver Operating Characteristic*), que é um gráfico, Figura 4, que mostra o desempenho do modelo em diferentes limiares de classificação (CARTER et al., 2016).

Figura 4. Curvas características de operação do receptor com sensibilidade e especificidade variáveis.



Fonte: (CARTER et al., 2016)

A métrica AUC é calculada pela integral da curva ROC, ou seja, calculando a área sob a curva. Seu valor varia de 0 a 1, sendo que um valor de AUC igual a 1 indica um modelo perfeito, capaz de distinguir perfeitamente entre as classes positiva e negativa, enquanto um valor de AUC igual a 0,5 indica um modelo que classifica aleatoriamente (CARTER et al., 2016).

Juntamente com as métricas de avaliação, como as citadas anteriormente a AUC (área sob a curva) é um fator essencial para a escolha do melhor modelo. A pontuação AUC define a capacidade de um algoritmo de classificação para diferenciar entre suas classes (NAYAK et al., 2023). A interpretação dos valores de AUC pode ser visualizada na Tabela 4.

Tabela 4. Classificação dos valores da AUC.

AUC	Classificação
1,0	Perfeito
0,9 - 0,99	Excelente
0,80 - 0,89	Bom
0,7 - 0,79	Razoável
0,51 - 0,69	Ruim
0,5	Não tem valor

Fonte: (CARTER et al., 2016).

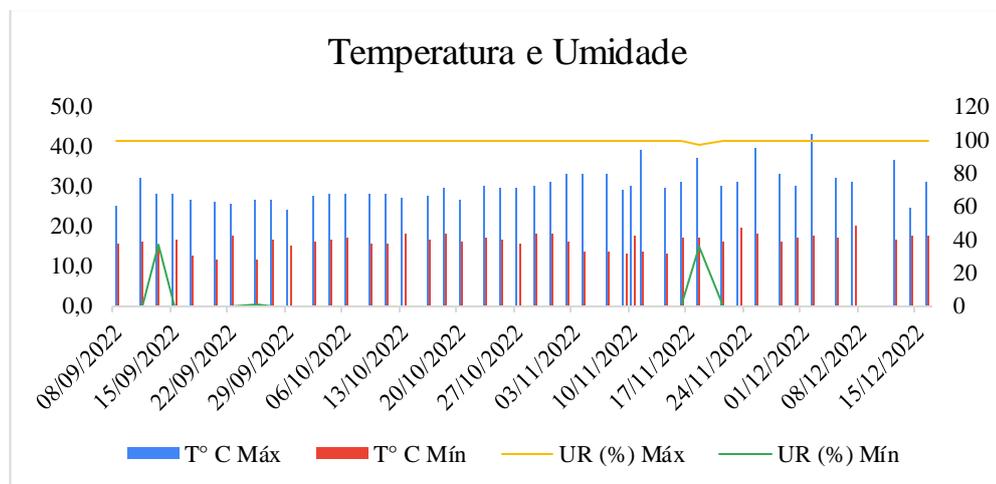
3 MATERIAL E METÓDOS

3.1. Caracterização do experimento para aquisição das imagens

O experimento foi conduzido na Faculdade de Zootecnia e Engenharia de Alimentos-FZEA/USP, *campus* “Fernando Costa”, no município de Pirassununga, em casa de vegetação com 100 m² de área, construída em policarbonato alveolar e com controle climático por sistema evaporativo de ar.

A caracterização climática da região, de acordo com a classificação de *Köppen* é do tipo CWA, com duas estações bem definidas, sendo uma chuvosa de outubro a março e outra seca de abril a setembro. A precipitação média anual é 1298 mm e a temperatura média 20,8 °C (OLIVEIRA e PRADO, 1984). A medição da temperatura e umidade foi conduzida por meio de um termo-higrômetro digital da marca EXBOM, especificamente o modelo de medidor de umidade e temperatura. Os resultados obtidos estão ilustrados na Figura 5.

Figura 5. Valores de umidade e temperatura durante o período de execução do estudo

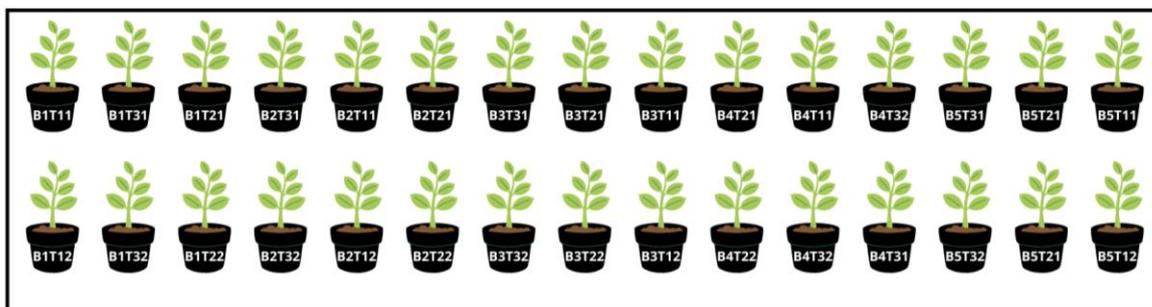


Fonte: Autoria própria.

O delineamento experimental adotado foi parcela subdividida no tempo, com três tratamentos e cinco repetições. A parcela experimental foi composta por dois vasos, contendo uma planta de morangueiro cada, com capacidade de 3 L (área de 0,02298 m² e diâmetro de 0,17 m), totalizando 30 vasos. Os tratamentos consistiram em 3 doses de adubação e foram nomeados de T1: 50% da adubação recomendada por Passos et. al, 2013, para nitrogênio, T2: 100% da adubação controle e T3: 150% da adubação controle, Figura 6.

As mudas de morango foram adquiridas comercialmente em estágio de mudas nuas, cultivar de morango de dias neutros, San Andréas.

Figura 6. Croqui do experimento.



Fonte: Autoria própria.

A coleta de folhas para digitalização da imagem foi realizada em 3 datas diferentes, correspondendo aos estádios de desenvolvimento do morango na fase vegetativa e indução floral, Tabela 5.

Tabela 5. Coletas das folhas para realização da digitalização.

		Data	Estádio
Plantio		06/09/2022	Transplante de muda
	1	11/10/2022	Vegetativo
Coleta	2	26/10/2022	Vegetativo
	3	07/11/2022	Indução floral

Fonte: Autoria própria.

No Laboratório de Máquinas Agrícolas e Agricultura de Precisão (LAMAP) do Departamento de Engenharia de Biosistemas da Universidade de São Paulo, as folhas foram preparadas para obtenção das imagens removendo-se qualquer excesso de poeira ou sujeira com um papel toalha. Com o auxílio do scanner de mesa convencional de alta resolução (HP scanjet 3800) com até 9600 DPI (dot per inch – pontos por polegada) realizou-se digitalização da imagem das folhas com 1200 DPI, Figura 7, as quais foram armazenadas no computador em formato JPG (Joint Photographic Experts Group), para o processamento.

Figura 7. Foliólo do morango digitalizada com 1200 DPI.



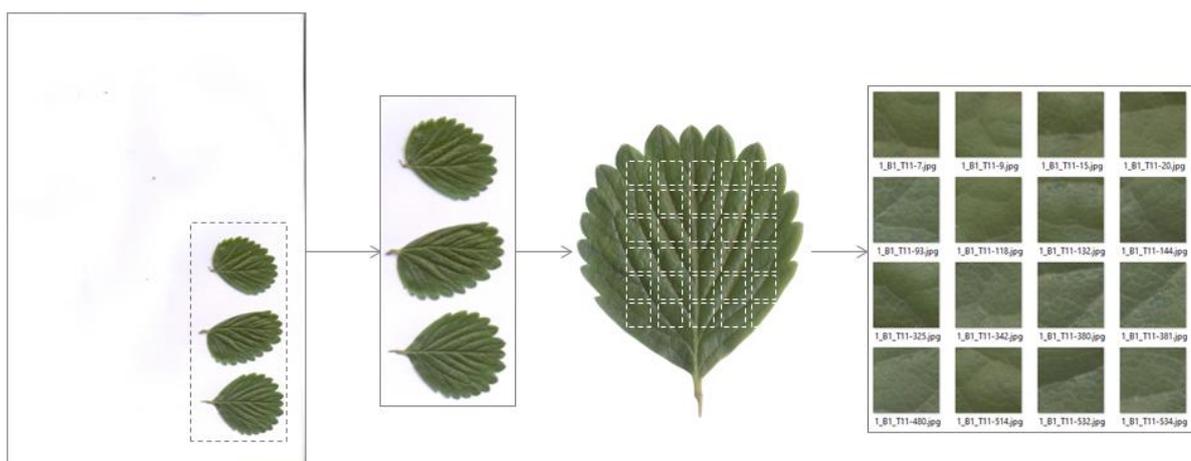
Fonte: Autoria própria.

A análise química foliar foi realizada no Laboratório de Ciências Agrárias/Solos da Faculdade de Zootecnia e Engenharia de Alimentos da Universidade de São Paulo de acordo com a metodologia descrita no manual de análises químicas de solos, plantas e fertilizantes da EMBRAPA (2009). Os elementos analisados foram nitrogênio, fósforo, potássio, sódio, cálcio, magnésio, enxofre, boro, cobre, ferro, manganês, zinco, molibdênio e silício, seus resultados foram submetidos a uma análise estatística de variância, empregando o teste de Tukey com um nível de significância de 5% utilizando o software SISVAR versão 5.8 (FERREIRA, 2015).

3.2. Pré-processamento das imagens

A partir das imagens foliares das amostras realizou-se a etapa de segmentação, que consiste na subdivisão da imagem em regiões distintas para assim dividir a imagem em áreas específicas que são de interesse para o processamento da imagem (BACKES et al., 2016) e obter a criação do conjunto de dados. As imagens do morango foram segmentadas usando um script elaborado no software Matlab R2021b (Mathworks, EUA) para extrair blocos de forma automática, de tamanho 224x224 pixels RGB, com finalidade de obter imagens que permitam a visualização ideal do estado nutricional nas folhas, Figura 8. Esse tamanho foi adotado tendo em vista a utilização desses recortes como entrada para o treinamento dos modelos baseados na arquitetura Resnet (GAJAVALLI et al., 2022).

Figura 8. Exemplo do banco de imagens formado pelos blocos da segmentação da folha do morango.



Fonte: Autoria própria.

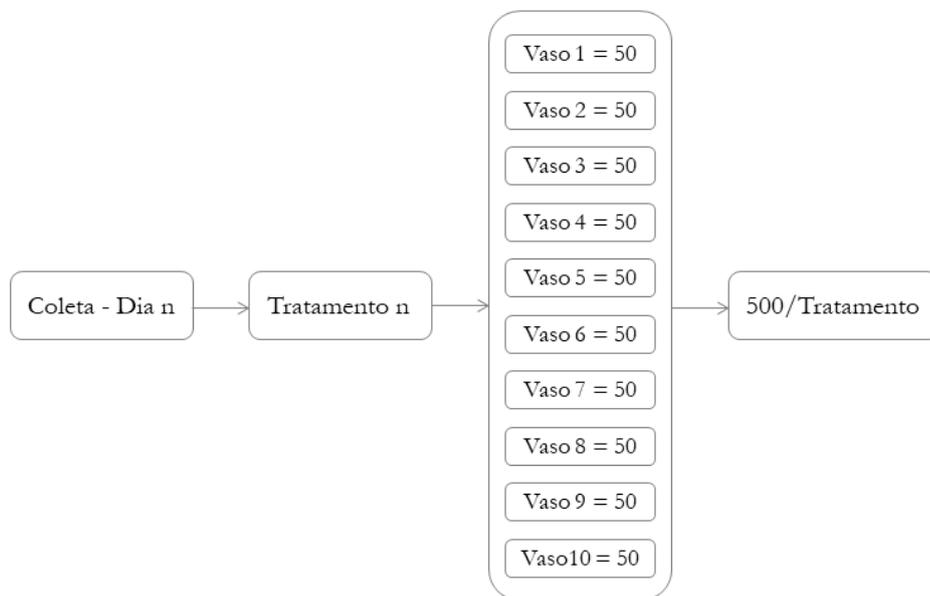
Após a conclusão da etapa de segmentação automática, executada através do script, procedeu-se com a seleção manual de blocos de imagens para compor o banco de dados.

Nesse processo de seleção manual, cada bloco de imagem foi cuidadosamente examinado para garantir a qualidade e a integridade dos dados a serem utilizados.

A seleção foi realizada levando em consideração critérios específicos: a imagem de cada bloco deveria estar completamente preenchida com a cor verde, a qual representa uma seção da folha. Isso assegurou que apenas as áreas relevantes para a análise estivessem presentes em cada bloco. Além disso, foram excluídos quaisquer blocos que apresentassem ruído ou partes em branco após o recorte, pois tais imperfeições poderiam interferir no processo de classificação posterior.

O processo de seleção manual resultou na escolha de 50 blocos de imagens para cada vaso, totalizando assim 500 blocos por tratamento. Considerando os três tratamentos analisados, o conjunto de dados final foi composto por um total de 1500 blocos de imagens, como ilustrado na Figura 9 para uma melhor compreensão visual. Esse rigoroso processo de seleção assegurou a qualidade e a confiabilidade dos dados utilizados para a análise subsequente.

Figura 9. Fluxograma da segmentação das imagens do morango.



Fonte: Autoria própria.

3.3. Construção dos modelos computacionais

Após a definição do conjunto de dados, foi elaborado um script no software Matlab para realizar o treinamento de modelos usando duas diferentes arquiteturas de CNN, sendo uma própria e a outra baseada na Resnet50. Na Tabela 6 estão as principais configurações da arquitetura do modelo baseada na rede neural convolucional que foi usada para classificar o nível de adubação.

Tabela 6. Arquitetura do modelo baseada na rede neural convolucional que foi usada para classificar as dosagens de adubação.

Camadas	Configurações
<i>2D Convolutional</i>	256 <i>kernels</i> com tamanho 5x5
<i>Batch Normalization</i>	<i>Default</i>
<i>2D MaxPooling</i>	Tamanho <i>pooling</i> = 2x2
<i>2D Convolutional</i>	128 <i>kernels</i> com tamanho 3x7
<i>Batch Normalization</i>	<i>Default</i>
<i>2D MaxPooling</i>	Tamanho <i>pooling</i> = 2x2
<i>2D Convolutional</i>	128 <i>kernels</i> com tamanho 7x3
<i>Batch Normalization</i>	<i>Default</i>
<i>2D Convolutional</i>	32 <i>kernels</i> com tamanho 3x3
<i>Batch Normalization</i>	<i>Default</i>
<i>Fully Connected</i>	Ativada pela <i>softmax</i>

Fonte: Autoria própria

A arquitetura foi projetada com um modelo sequencial sendo que a primeira e a segunda camadas são de convolução com 256 e 128, respectivamente, mapas de característica, com campos receptivos locais (*kernel*), dimensão de 5x5 e um input com o formato de 224x224 pixels. São seguidas por uma camada de subamostragem (*MaxPooling*), usando filtro 2x2. A terceira e quarta são camadas convolucionais, com 128 e 32, respectivamente, seguida por um *MaxPooling* com filtro 2x2. E por fim, a função *softmax layer* no MATLAB transforma as saídas da camada anterior de uma rede neural em probabilidades, permitindo a classificação multiclasse baseada nas probabilidades atribuídas a cada classe.

A função de ativação empregada foi a *ReLU*, que é comumente utilizada em projetos de reconhecimento de imagens. O *stride*, o qual determina o passo em que as janelas percorrem a imagem durante a convolução, tendo sido utilizado *stride* igual a 2.

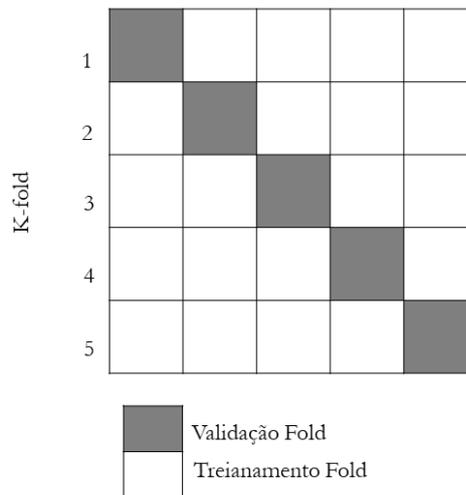
Neste estudo, utilizou-se a arquitetura Resnet-50 que é amplamente utilizada em projetos de reconhecimento de imagens e apresenta bons resultados, apesar de ser uma versão menor em comparação com as arquiteturas maiores do Resnet.

Além disso, foi utilizada a validação cruzada, uma técnica potente para evitar o *overfitting* do modelo, uma vez que permite avaliar o desempenho em diferentes conjuntos de dados de treinamento e validação, Figura 10. Ela combina medidas de desempenho do modelo em diferentes conjuntos de dados e fornece uma estimativa mais precisa de sua capacidade de generalização. Para o presente trabalho foi utilizado a técnica KFold, em que o conjunto de

treinamento é dividido em 5 subconjuntos, e em cada iteração, um subconjunto diferente é utilizado para validação, enquanto os outros 4, $k - 1$, são utilizados para treinamento. Ao final das 5 iterações, a precisão média é calculada e utilizada como medida final do desempenho do modelo.

Durante o processo de treinamento, o objetivo é minimizar a função de perda por meio de técnicas de otimização iterativas. (CAI et al., 2020).

Figura 10. Processo de 5 vezes validação cruzada.



Fonte: Adaptado Pytorch (2021)

Dessa forma, durante o processo de validação cruzada, em cada iteração, 4 dos folds são utilizados como conjunto de treinamento, o que corresponde a 80% das imagens no caso dessa divisão. Isso significa que 1200 blocos de imagens são usados para treinar o modelo. O fold restante, com 20% das imagens (300 imagens), é utilizado como conjunto de teste para avaliar o desempenho do modelo.

O processo de treinamento e teste é repetido 5 vezes, de forma que cada fold seja usado uma vez como conjunto de teste. Essa estratégia garante que todas as imagens sejam utilizadas tanto para treinamento quanto para teste, permitindo uma avaliação mais robusta do desempenho do modelo.

Para o modelo de rede neural convolucional levou-se em conta as opções, conforme na Tabela 7, para treinar rede neural de aprendizagem profunda e nela estão inseridos os hiperparâmetros já que eles são responsáveis por definir como o modelo será treinado e, conseqüentemente, como ele será capaz de realizar a tarefa para a qual foi projetado (BENGIO, 2012).

Tabela 7. Opções de treinamento utilizadas no modelo convolucional.

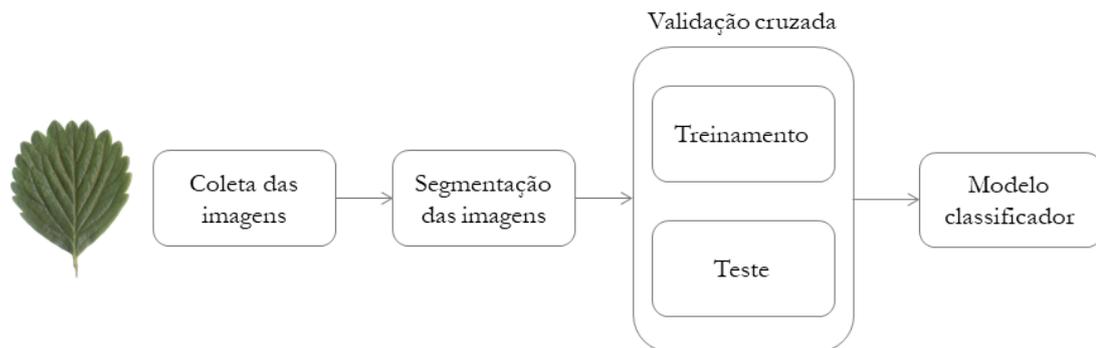
Número de épocas	10
Tamanho do minilote	8
Opção para embaralhamento de dados	<i>every-epoch</i>
Escalar positivo da taxa de aprendizado inicial	0,0001

Fonte: Autoria própria.

Tanto para rede neural convolucional própria, quanto para Resnet-50 o número de épocas utilizado foram 10. Too et al. (2019) em um estudo comparativo de modelos de aprendizado profundo de ajuste fino para identificação de doenças de plantas, compararam o comportamento para 10 e 30 épocas e observaram que a Resnet-50 e a Resnet 101 funcionam adequadamente com menos iterações e além disso, após o ajuste fino, os modelos usando 10 épocas obtiveram uma acurácia acima de 90%.

A Figura 11 fornece uma visão geral das etapas para o sistema proposto de identificação de nutricional.

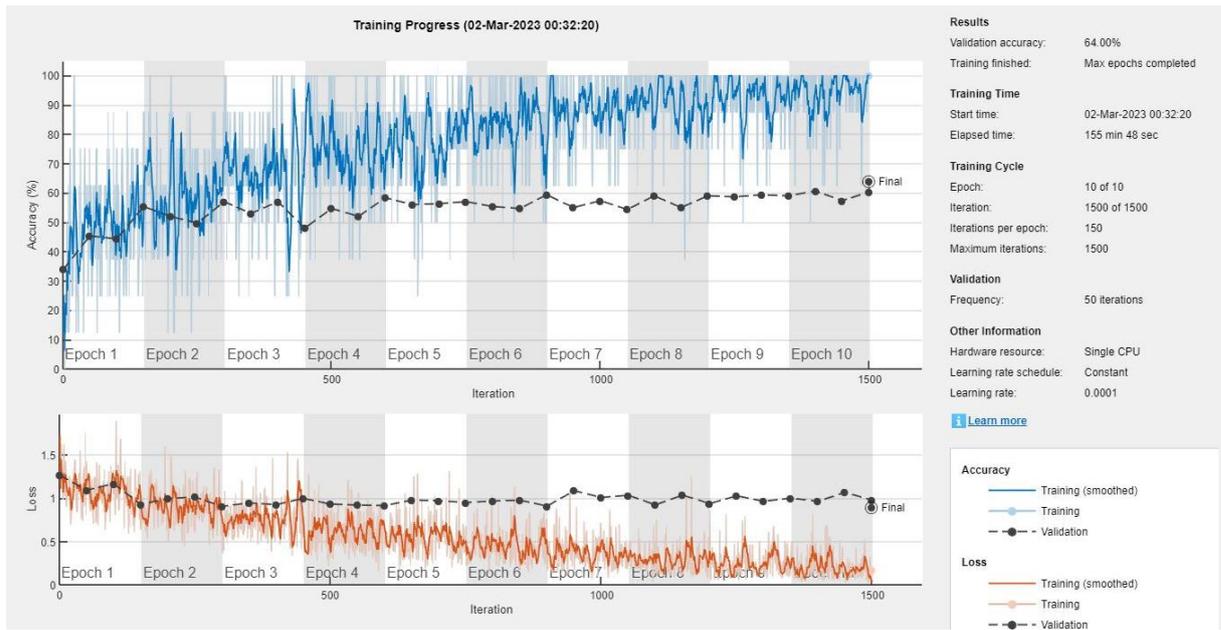
Figura 11. Fluxograma da visão geral do sistema proposto de aprendizagem profunda.



Fonte: Autoria própria.

Durante o treinamento, é possível visualizar o comportamento do modelo durante as épocas, conforme a Figura 12. O MATLAB oferece a função *trainingPlot* para visualização do gráfico de treinamento, que permite monitorar o progresso do treinamento de aprendizado profundo. O gráfico mostra várias métricas, como erro de treinamento, erro de validação, acurácia de treinamento, acurácia de validação, entre outras, ao longo do tempo. É possível personalizar o gráfico de treinamento para adicionar ou remover métricas e ajustar a escala dos eixos para melhor visualização (MATHWORKS, 2023).

Figura 12. Exemplo do progresso do treinamento.



Fonte: Autoria própria.

4 RESULTADOS E DISCUSSÕES

Nesta seção, são apresentados os resultados obtidos por meio de seis modelos de CNNs. Inicialmente, foram avaliados os resultados de cada modelo em cada fase da coleta das folhas de morango. Em seguida, realizou-se uma comparação dos resultados de todos os modelos.

4.1. Análise química foliar

O resultado da análise de variância considerando os valores dos parâmetros químicos das amostras foliares está apresentado na Tabela 8.

Tabela 8. Resultado da análise de variância com as médias para os elementos considerados para análise foliar.

Macronutrientes	Unidade	T1	T2	T3	CV (%)
N		27,12 a	27,15 a	27,39 a	16,15
P		2,22 a	2,26 a	2,37 a	11,3
K		22,92 a	23,13 a	23,18 a	17,66
Na	g/kg	-	-	-	-
Ca		16,97 a	17,41 a	18,02 a	7,25
Mg		5,57 b	5,66 ab	6,04 a	7,05
S		3,39 a	3,58 a	3,82 a	33,15
Micronutrientes					
B		ns	ns	ns	-
Cu		26,83 a	28,56 a	29,25 a	57,91
Fe		370,26 a	409,39 a	470,57 a	25,43
Mn	mg/kg	266,23 c	325,31 b	389,51 a	14,79
Zn		33,45 a	33,45 a	34,71 a	20,96
Mo		ns	ns	ns	-
Si		ns	ns	ns	-

*Comparações entre as médias dos dados sem transformação, na mesma linha seguidas por letras minúsculas distintas que diferem entre si pelo Teste de Tukey ($p < 0,05$).

Fonte: Autoria própria.

Observa-se que as médias dos tratamentos diferem entre si apenas para os elementos Manganês (Mg) e Magnésio (Mn), sendo que para o Mg apenas o tratamento T1 e T3

diferiram e no Mn todos os tratamentos apresentaram diferença significativa para probabilidade de 5% aplicando o teste de Tukey.

O magnésio (Mg) desempenha um papel crucial na fotossíntese, pois está presente na molécula da clorofila ligando-se quimicamente a quatro moléculas de N, sendo essencial para a absorção de luz e transferência de energia (EMBRAPA, 2013). Segundo Passos et al. (2013), o nível ideal de magnésio para a cultura do morango está na faixa de 6-10 g/kg, faixa que se encontra os níveis deste elemento em cada tratamento (T1: 5,57 g/kg, T2: 5,66 g/kg, T3: 6,04 g/kg).

A maior quantidade de magnésio no T3 pode ter influenciado positivamente o desempenho das plantas de morango em relação ao T1. Essa diferença pode ser atribuída à maior disponibilidade de magnésio no T3, fornecendo um suprimento adequado para as necessidades de fotossíntese e síntese de proteínas das plantas pela relação direta com a quantidade de nitrogênio.

A diferença significativa do magnésio entre os tratamentos T1 e T3 pode ter gerado diferença de coloração nas folhas e influenciado nos resultados de classificação do modelo, tanto na CNN quanto na Resnet50, como o Mg faz parte da molécula de clorofila e que por sua vez é relacionada com a reflectância na faixa do verde, possivelmente isso gerou um padrão de cor que durante as convoluções podem ter contribuído na discriminação das classes para o elemento alvo.

Ao analisar a Tabela 8, observa-se que, além do magnésio, o manganês (Mn) também apresentou diferenças significativas entre os três tratamentos. Essa diferença pode ser atribuída à importância do manganês na síntese da clorofila e na ativação de enzimas, como mencionado por Dechen (2006).

Segundo Passos et al. (2013), o nível ideal de magnésio para a cultura do morango está na faixa de 30-300 mg/kg. No entanto, é importante ressaltar que a quantidade de manganês nos tratamentos T1, T2 e T3 foi relatada como sendo de 266,23 mg/kg, 325,31 mg/kg e 389,51 mg/kg, respectivamente.

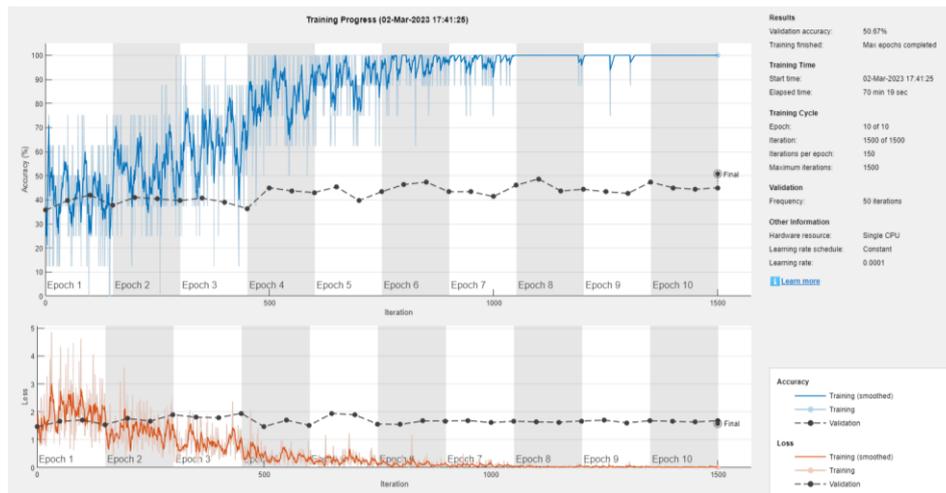
Com base nessas informações, é possível inferir que o manganês aplicado nos tratamentos T2 e T3 estão acima do nível ideal relatado para a cultura do morango. Essa diferença na quantidade de manganês pode ter influenciado o desempenho das plantas de morango, podendo afetar a síntese de clorofila, a atividade enzimática e, conseqüentemente, o crescimento e a produtividade das plantas, o que pode ter influenciado na discriminação das classes para o modelo.

4.2. Coleta 1

4.2.1. CNN própria

Na Figura 13, o gráfico do treinamento é referente ao terceiro fold executado, o que apresentou uma acurácia maior, com 50,67%.

Figura 13. Gráfico de acurácia e perda da CNN própria da coleta 1.



Fonte: Autoria própria

É importante distinguir a acurácia de treinamento (*training accuracy*) da acurácia de validação (*validation accuracy*) no progresso de treinamento de um modelo. A acurácia de treinamento reflete o desempenho do modelo nos dados de treinamento utilizados para treiná-lo, melhorando ao longo das épocas. Já a acurácia de validação é calculada em um conjunto de dados separado, conhecido como conjunto de validação, e avalia o desempenho do modelo em dados não vistos, verificando sua capacidade de generalização.

Observa-se que até a época 7 mostra que o modelo estava aprendendo e ajustando-se aos dados. Durante essas primeiras épocas, é esperado que a acurácia aumente à medida que o modelo compreende melhor os padrões nos dados de treinamento. A estabilidade alcançada após a época 7 indica que o modelo atingiu um nível de desempenho máximo.

Dessa forma, a acurácia de validação desempenha um papel crítico na análise do progresso de treinamento e na determinação da eficácia do modelo em situações do mundo real.

Na Figura 14 está a matriz de confusão derivada do conjunto de testes. Essa análise permitiu avaliar a capacidade do modelo de extrair características significativas das imagens fornecidas. A acurácia geral do modelo das previsões corretas foi de 44%.

Figura 14. Matriz de confusão da CNN própria para coleta 1.

Confusion Matrix

Output Class	T1	241 16.1%	111 7.4%	116 7.7%	51.5% 48.5%
	T2	140 9.3%	215 14.3%	175 11.7%	40.6% 59.4%
	T3	119 7.9%	174 11.6%	209 13.9%	41.6% 58.4%
		48.2% 51.8%	43.0% 57.0%	41.8% 58.2%	44.3% 55.7%
	↕	↕	↕	Target Class	

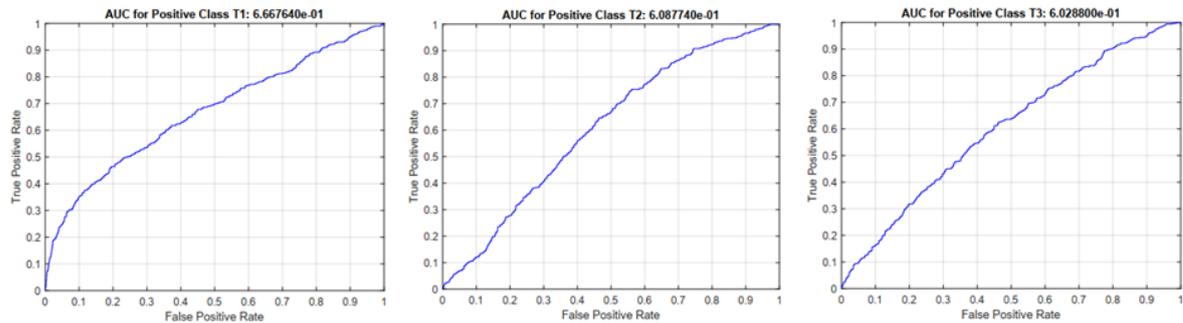
Fonte: Autoria própria

Ao analisar a acurácia geral do modelo, que foi de 44,3% durante a fase inicial de classificação de morangos, observa-se que os erros superaram os acertos. Esses resultados indicam que o modelo teve dificuldades em distinguir adequadamente as diferentes classes de morangos. Uma possível explicação para isso é o estágio inicial das plantas de morango.

Durante a fase inicial, as plantas de morango podem apresentar características semelhantes entre os diferentes tratamentos, o que dificulta a distinção precisa entre as classes pelos algoritmos de aprendizado profundo. Essa proximidade na acurácia entre os três tratamentos sugere que as diferenças entre eles não foram capturadas de maneira eficiente pelo modelo.

A análise da AUC, na Figura 15, para os três tratamentos revela que o desempenho do modelo, utilizando a CNN própria, não foi totalmente satisfatório. A AUC variou de 0,60 a 0,66, indicando que a capacidade discriminativa do modelo em distinguir as classes dos tratamentos não foi suficiente.

Figura 15. Gráfico AUC dos tratamentos utilizados da coleta 1 usando a CNN própria.



Fonte: Autoria própria.

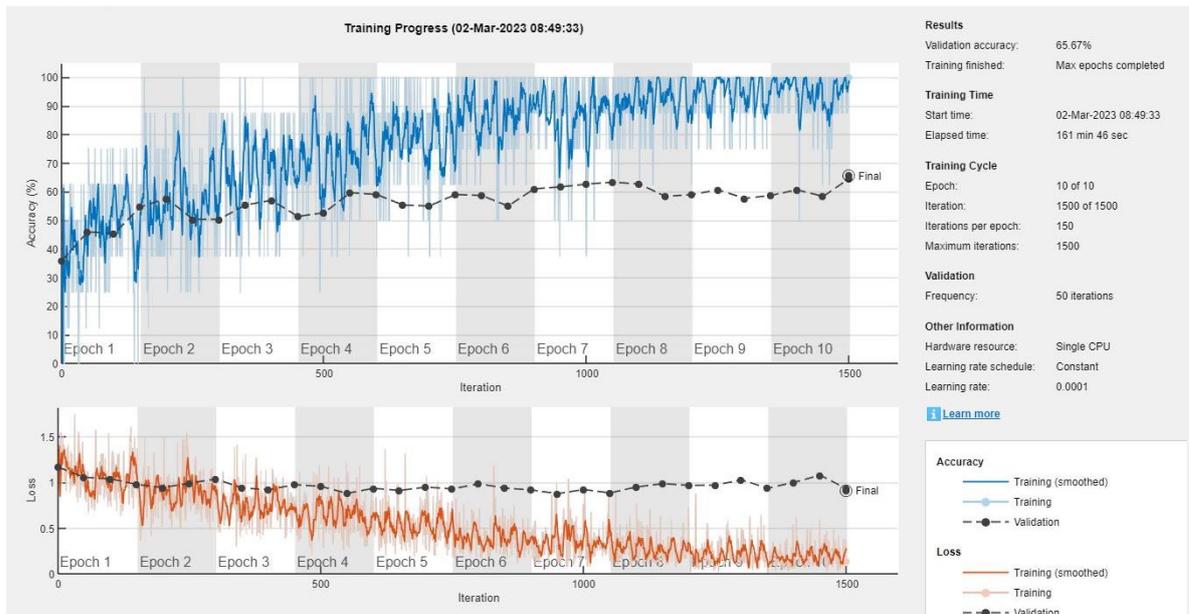
Uma AUC de 0,5 representa um desempenho aleatório, enquanto valores próximos a 1 indicam uma capacidade de classificação altamente precisa. No entanto, com valores de AUC variando entre 0,60 e 0,66, sugere que a CNN própria não foi capaz de extrair informações discriminativas suficientes dos dados para realizar uma classificação mais precisa.

Para melhorar o desempenho do modelo, podem ser exploradas algumas estratégias. Uma delas é a otimização dos hiperparâmetros da CNN, como o tamanho do filtro, o número de camadas e a taxa de aprendizado.

4.2.2. Resnet-50

Na Figura 16, o gráfico apresenta a avaliação da eficiência do modelo em que foi encontrado o valor de acurácia de 65,67% no quarto fold. Ao analisar o progresso do treinamento, nota-se que a curva de *training accuracy* apresenta variações ao longo das dez épocas. Isso indica que o modelo está passando por um processo de aprendizado, ajustando-se gradualmente aos dados de treinamento e refinando sua capacidade de fazer previsões corretas.

Figura 16. Gráfico de acurácia e perda da Resnet 50 da coleta 1.

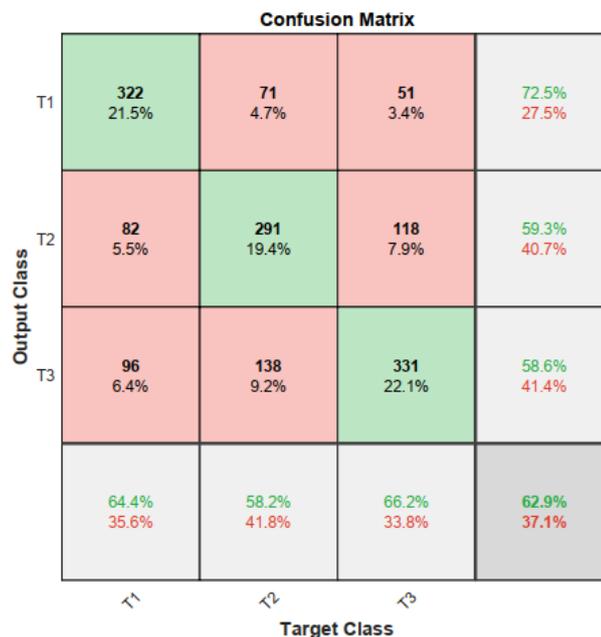


Fonte: Autoria própria.

A ausência de diferenças significativas nas plantas pode ser atribuída ao fato de estarem em um estágio inicial de adubação de controle, no qual as diferentes doses de adubo ainda não haviam surtido efeito.

Portanto, a falta de diferenciação observada pode ser justificada pelo estágio inicial das plantas e pelo período de tempo em que ocorreu o experimento, o que torna a distinção entre as classes mais desafiadoras. No entanto, o fato do modelo usando a Resnet-50 ter alcançado uma acurácia de 62,9%, Figura 17, indica que ele foi capaz de aprender padrões e características específicas que diferenciam as classes nesse estágio inicial.

Figura 17. Matriz de confusão da Resnet 50 para coleta 1.

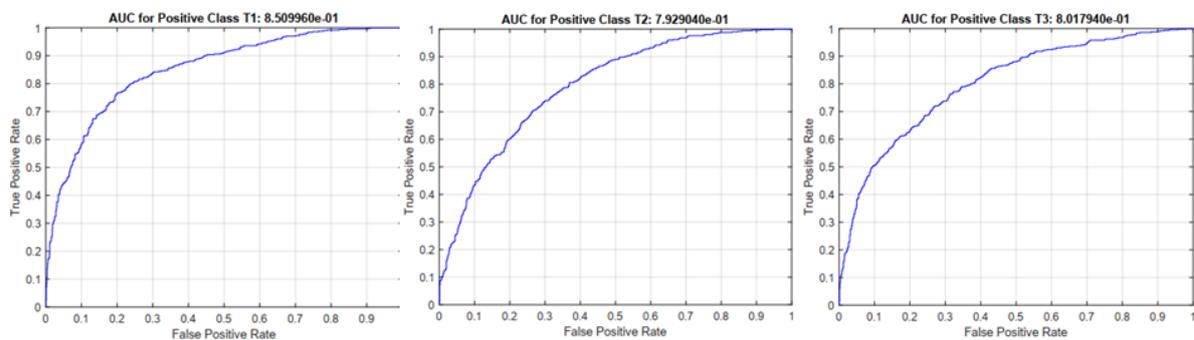


Fonte: Autoria própria

Ao analisar o gráfico de AUC, representado na Figura 1, podemos observar que o modelo obteve um desempenho mais satisfatório. Os valores de AUC para os tratamentos T1, T2 e T3 foram de 0,85, 0,79 e 0,80, respectivamente.

Para essa métrica valores mais próximos de 1 indicam um melhor desempenho de classificação (LIU et al., 2023), ou seja, o modelo possui uma capacidade maior de fazer previsões corretas. Esses resultados indicam que a arquitetura Resnet-50 foi capaz de aprender e extrair características discriminativas dos dados, permitindo uma classificação precisa dos diferentes tratamentos.

Figura 18. Gráfico AUC dos tratamentos utilizados da coleta 1 usando Resnet 50.



Fonte: Autoria própria.

Conforme a Tabela 9, para o tratamento 1, que corresponde a 50% da dose recomendada de adubação, a CNN própria obteve uma acurácia de 67%. Isso significa que o modelo foi capaz de prever corretamente 67% das amostras desse tratamento. Além disso, a AUC de 0,6 indica que o modelo apresenta um desempenho razoável na classificação das amostras desse tratamento.

Já a Resnet-50 superou a CNN própria, alcançando uma acurácia de 85% para o tratamento 1. Esse resultado indica uma melhoria significativa em relação à CNN própria, sugerindo que a Resnet-50 é mais eficaz na predição das doses adequadas de adubação.

Segundo Feitosa (2002) em um estudo constatou que a falta de magnésio nas plantas de alfafa afeta negativamente seu crescimento, taxa de fotossíntese, condutância estomática e capacidade de capturar e transferir energia. Isso mostra que a deficiência de magnésio tem um impacto significativo no desenvolvimento e funcionamento das plantas de alfafa.

Tabela 9. Resultados obtidos ao utilizar diferentes métricas de avaliação para as folhas do morango.

Métricas de Avaliação	CNN própria			Resnet-50		
	T1	T2	T3	T1	T2	T3
AUC	67%	61%	60%	85%	79%	80%
Acurácia	44%	44%	44%	63%	63%	63%
Sensibilidade	48%	43%	42%	64%	58%	66%
Especificidade	42%	45%	46%	62%	65%	61%
Precisão	29%	28%	28%	46%	46%	46%
Recall	48%	43%	42%	64%	58%	66%
F1 score	37%	34%	33%	54%	51%	54%
G-mean	45%	44%	44%	63%	62%	64%

Fonte: A autoria própria.

4.3. Coleta 2

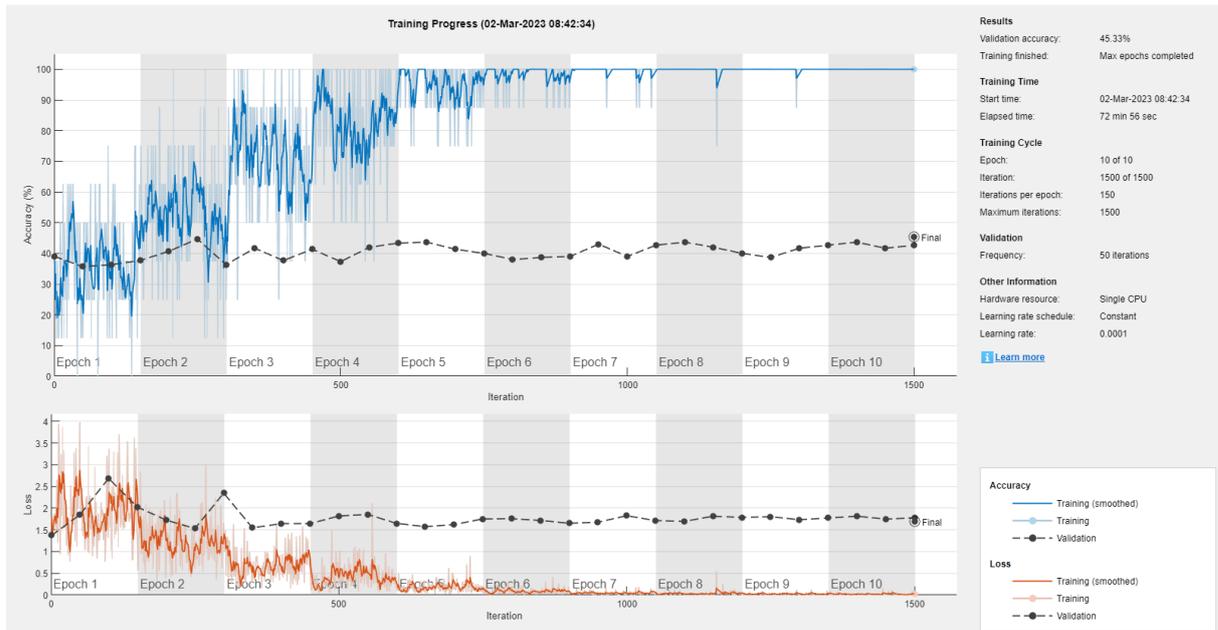
4.3.1. CNN própria

A análise do gráfico de treinamento, Figura 19, apresentou uma acurácia de 45,33% no primeiro fold. Esse valor representa a porcentagem de previsões corretas realizadas pelo modelo nos dados de treinamento durante essa etapa inicial.

Ao analisar o gráfico do processo de treinamento, observa-se que a *training loss* começa em um valor alto e diminui gradualmente ao longo das épocas. Isso indica que o modelo está aprendendo com os dados de treinamento e refinando suas previsões.

Por outro lado, a *validation loss* começa em um valor alto, mas se estabiliza ao longo das épocas. Isso sugere que o modelo não está melhorando significativamente sua capacidade de generalização para dados não vistos, conforme demonstrado pela perda de validação relativamente constante.

Figura 19. Gráfico de acurácia e perda da CNN própria da coleta 2.



Fonte: Autoria própria

A partir da Figura 20, pode-se observar que a taxa geral de acurácia é de 41,5%, o que significa que o modelo classificou corretamente aproximadamente 41,5% das amostras considerando as três classes em conjunto.

A diagonal principal da matriz de confusão indica as classificações corretas realizadas pelo modelo para cada classe específica da planta do morango. Os valores correspondentes são os seguintes: T1: 14,1%, T2: 11,9% e T3: 15,5%. Quanto maior a taxa de classificação correta, melhor o desempenho do modelo em identificar corretamente as amostras para cada classe.

Figura 20. Matriz de confusão da CNN própria para coleta 2.

		Confusion Matrix			
		↖	↙	↘	
Output Class	T1	212 14.1%	151 10.1%	127 8.5%	43.3% 56.7%
	T2	133 8.9%	179 11.9%	141 9.4%	39.5% 60.5%
	T3	155 10.3%	170 11.3%	232 15.5%	41.7% 58.3%
		42.4% 57.6%	35.8% 64.2%	46.4% 53.6%	41.5% 58.5%
		Target Class			

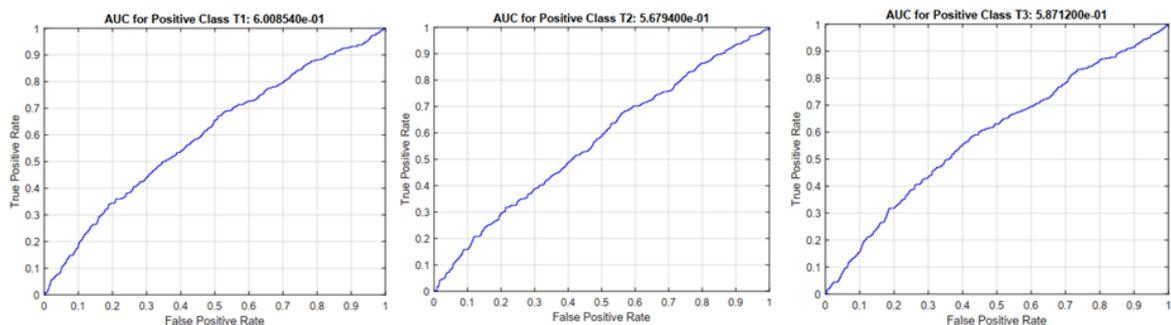
Fonte: Autoria própria

Ao utilizar a CNN própria, o modelo apresentou valores variados de AUC na faixa de 0,58 a 0,60, sendo o maior valor alcançado para o tratamento 1, como mostra a Figura 21.

Pode destacar que a variável do tratamento 1, relacionada à menor dose de nitrogênio, possui um impacto significativo nas características analisadas pelo modelo.

É possível afirmar que a diferença no teor de magnésio entre os tratamentos T1 e T3 desempenhou um papel importante na classificação das plantas, permitindo que o modelo identificasse padrões visuais específicos relacionados à menor dose de nitrogênio. Essa relação entre o magnésio, tonalidade das folhas e a discriminação das classes sugere uma possível influência direta dos níveis de magnésio na capacidade do modelo de identificar a classe alvo.

Figura 21. Gráfico AUC dos tratamentos utilizados da coleta 2 usando a CNN própria.

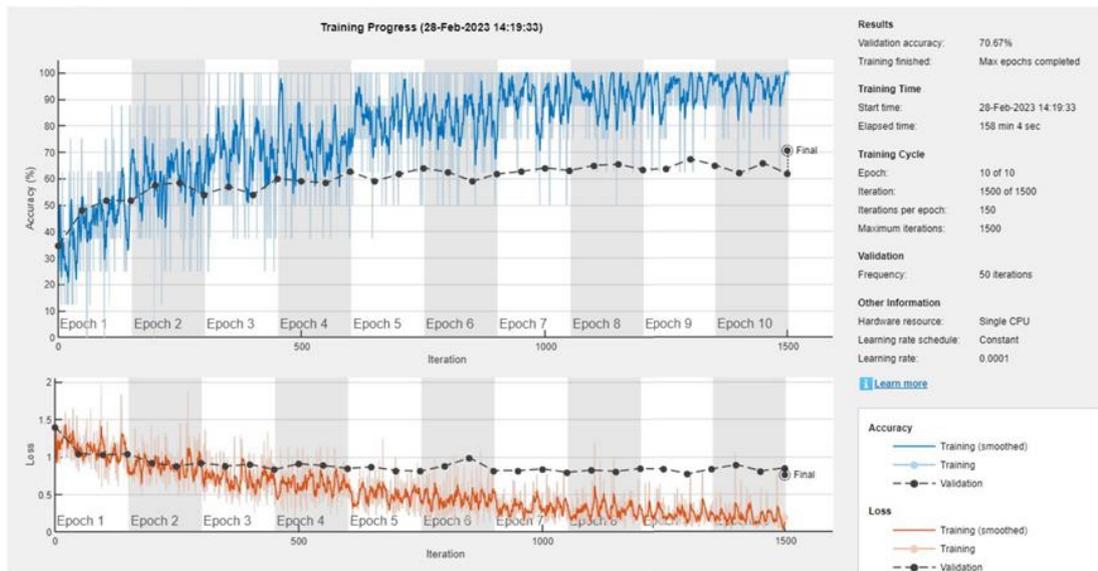


Fonte: Autoria própria.

4.3.2. Resnet-50

Ao analisar a Figura 22, observa-se que o modelo alcançou um desempenho melhor na classificação das amostras do primeiro fold em comparação com os outros folds. Essa diferença de desempenho entre os folds pode ser atribuída ao fato que o primeiro fold provavelmente ter sido composto por amostras que apresentavam padrões mais distintos e facilmente separáveis, permitindo uma classificação mais precisa pelo modelo.

Figura 22. Gráfico de acurácia e perda da Resnet 50 da coleta 2.



Fonte: Autoria própria

A análise da matriz de confusão, representada pela Figura 23, com a acurácia geral do modelo de 66,9%, indica que o modelo obteve uma taxa de acerto relativamente alta na tarefa de classificação.

Nota-se que as previsões corretas (na diagonal principal) são mais numerosas do que as previsões errôneas (fora da diagonal principal). Isso é um indicativo positivo e sugere que o modelo foi capaz de realizar classificações corretas na maioria dos casos.

Figura 23. Matriz de confusão da Resnet 50 para coleta 2.

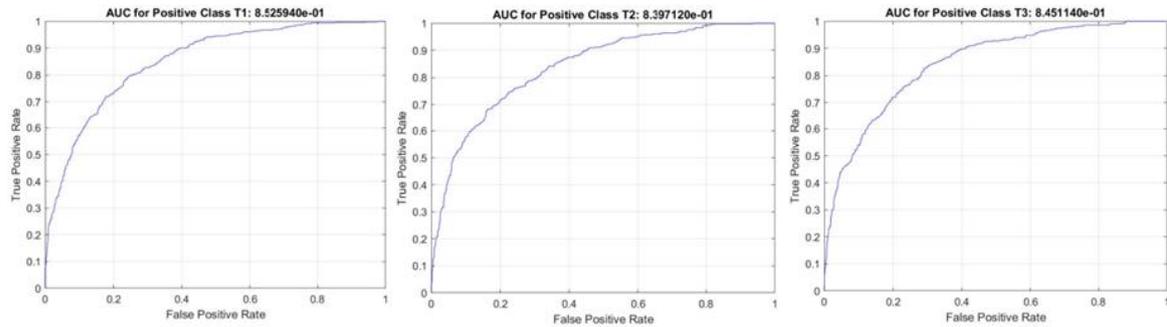
		Confusion Matrix			
Output Class	T1	322 21.5%	80 5.3%	60 4.0%	69.7% 30.3%
	T2	66 4.4%	315 21.0%	73 4.9%	69.4% 30.6%
	T3	112 7.5%	105 7.0%	367 24.5%	62.8% 37.2%
		64.4% 35.6%	63.0% 37.0%	73.4% 26.6%	66.9% 33.1%
		Target Class			

Fonte: Autoria própria

Ao analisar o gráfico de AUC, representado pela Figura 24, tem-se a variação entre 0,83 a 0,85 para as três classes. Esses valores indicam um desempenho consistente da Resnet-50 na capacidade de discriminação das classes.

A diferença na disponibilidade de magnésio entre os tratamentos pode ter gerado uma variação nas características das plantas, como a coloração das folhas. O magnésio desempenha um papel essencial na fotossíntese e na síntese de proteínas nas plantas, pois está diretamente relacionado à quantidade de nitrogênio disponível. Durante o processo de treinamento da Resnet-50, essas diferenças na coloração podem ter sido capturadas pelas convoluções e ajudado o modelo a discriminar as classes com maior precisão.

Figura 24. Gráfico AUC dos tratamentos utilizados da coleta 2 usando Resnet 50.



Fonte: Autoria própria.

Ao analisar as métricas de avaliação na Tabela 10, é possível observar que a Resnet-50 apresentou valores mais altos em todas as métricas em comparação à CNN própria. Um aspecto relevante a ser destacado é a diferença na especificidade entre os dois modelos. A especificidade é uma métrica que mede a capacidade do modelo de identificar corretamente os verdadeiros negativos, ou seja, as amostras que não pertencem à classe de interesse.

Tabela 10. Resultados obtidos ao utilizar diferentes métricas de avaliação para as folhas do morango.

Métricas de Avaliação	CNN própria			Resnet-50		
	T1	T2	T3	T1	T2	T3
AUC	60%	57%	59%	85%	84%	85%
Acurácia	42%	42%	42%	67%	67%	67%
Sensibilidade	42%	36%	46%	64%	63%	73%
Especificidade	41%	44%	39%	68%	69%	64%
Precisão	26%	24%	28%	50%	50%	50%
Recall	42%	36%	46%	64%	63%	73%
F1 score	33%	29%	35%	56%	56%	60%
G-mean	42%	40%	43%	66%	66%	68%

Fonte: Autoria própria

No caso da Resnet-50, a especificidade variou de 64% a 69% para os três tratamentos da planta do morango. Isso indica que o modelo teve um bom desempenho na classificação das amostras negativas, conseguindo distinguir efetivamente aquelas que não eram do tratamento em questão.

Por outro lado, a CNN própria apresentou uma especificidade mais baixa, variando de 41% a 44% para os três tratamentos. Indicando que o modelo teve uma menor capacidade de distinguir corretamente as amostras negativas, resultando em um maior número de falsos positivos.

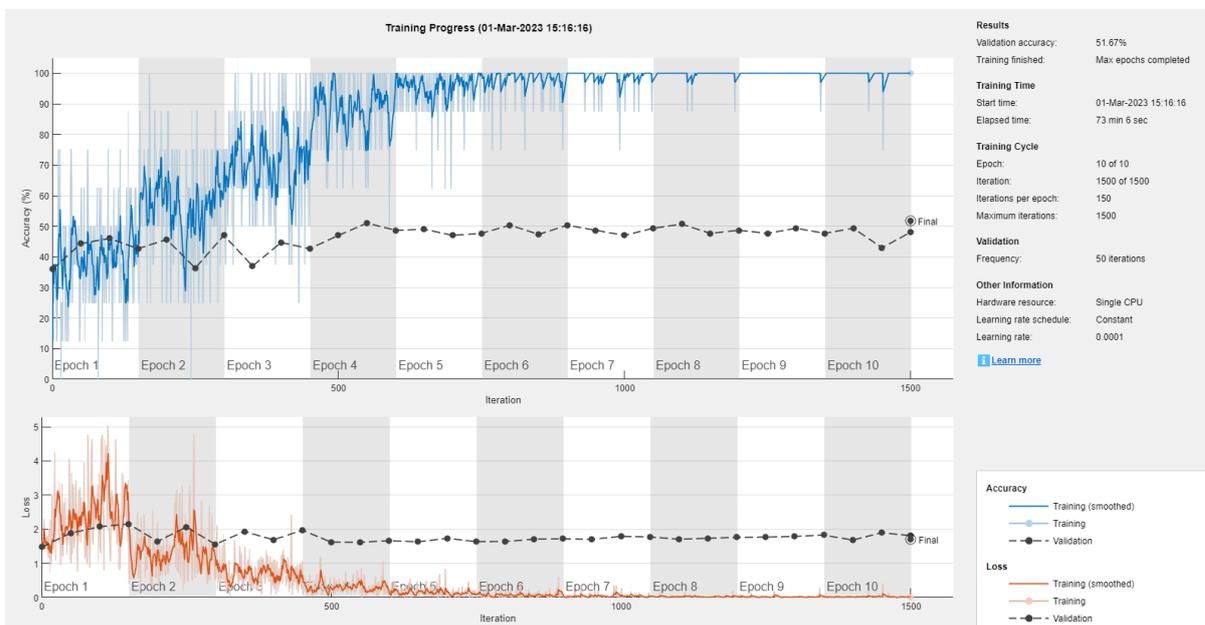
A diferença na especificidade entre os modelos pode ser atribuída às arquiteturas e características específicas de cada um. A Resnet-50, uma rede pré-treinada em grandes conjuntos de dados, capturou melhor os padrões relevantes nas imagens das folhas de morango. Já a CNN própria teve um desempenho inferior devido à menor capacidade de aprendizado e falta de generalização em relação às amostras negativas.

4.4. Coleta 3

4.4.1. CNN própria

Durante a realização da validação cruzada, é comum observar variações na acurácia do modelo em cada execução. No caso específico do quinto fold, foi obtida uma acurácia de 51,67%, Figura 25. Essa variação na acurácia entre os diferentes folds indica que o desempenho do modelo pode variar dependendo das características específicas das amostras presentes nesse fold em particular.

Figura 25. Gráfico de acurácia e perda da CNN própria da coleta 3.

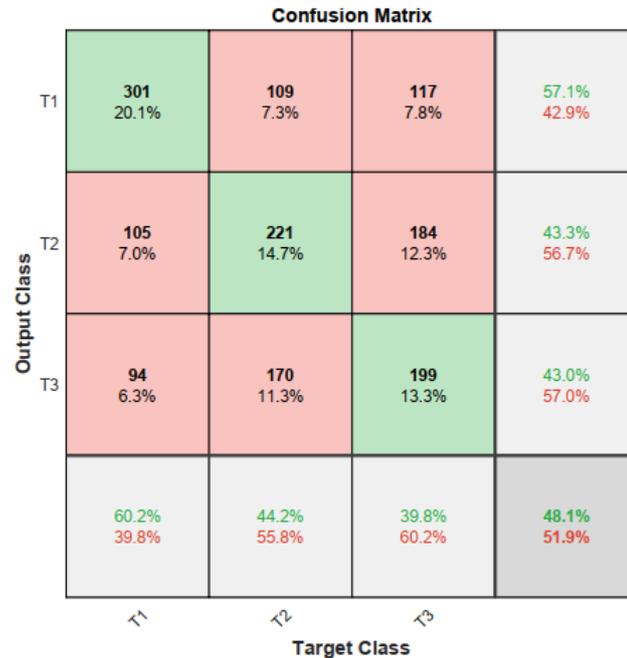


Fonte: Autoria própria

Ao analisar a matriz de confusão, representada pela Figura 26, o modelo obteve uma acurácia geral de 48,1%. Durante a fase reprodutiva, o T1 foi mais facilmente distinguido pelo modelo, apresentando um maior número de classificações corretas na diagonal principal. Por outro lado, o modelo teve mais dificuldade em diferenciar corretamente T2 e T3. Isso sugere que os tratamentos 2 e 3 podem ter características mais semelhantes e que confundiram o

modelo, tornando mais desafiador para ele fazer uma distinção precisa entre essas duas classes.

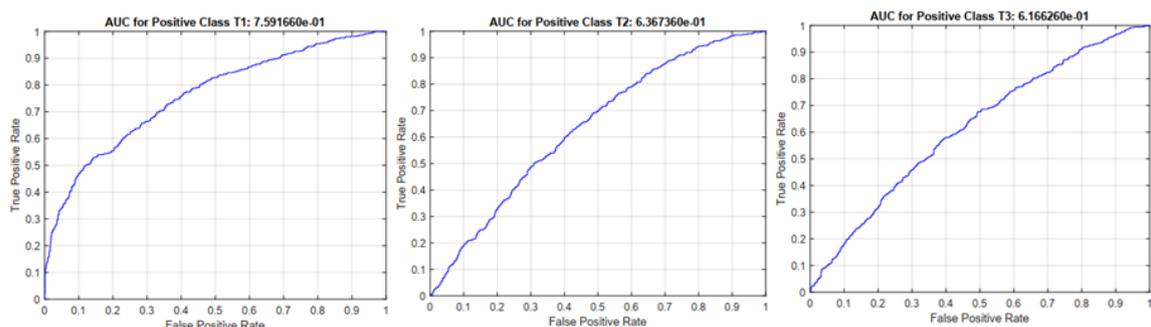
Figura 26. Matriz de confusão da CNN própria para coleta 3.



Fonte: Autoria própria

Com o avanço do estágio fenológico da planta, pode ser observado um aumento da clorose foliar devido às diferenças na concentração de nitrogênio entre os tratamentos. Como mostrado no gráfico da Figura 27, a AUC foi maior no tratamento 1 com 0,75, em que a dose recomendada é de 50%. De acordo com a disponibilidade de nitrogênio na planta a coloração das plantas pode ser afetada de diferentes maneiras. Na deficiência de nitrogênio, a cor das folhas tende a ficar mais pálida, amarelada ou esverdeada clara, devido à redução na síntese de clorofila, que é responsável pela coloração verde das folhas e o excesso de nitrogênio pode levar a uma cor verde muito escura das folhas e um crescimento vegetativo excessivo (TAIZ et al., 2013).

Figura 27. Gráfico AUC dos tratamentos utilizados da coleta 3 usando a CNN própria.

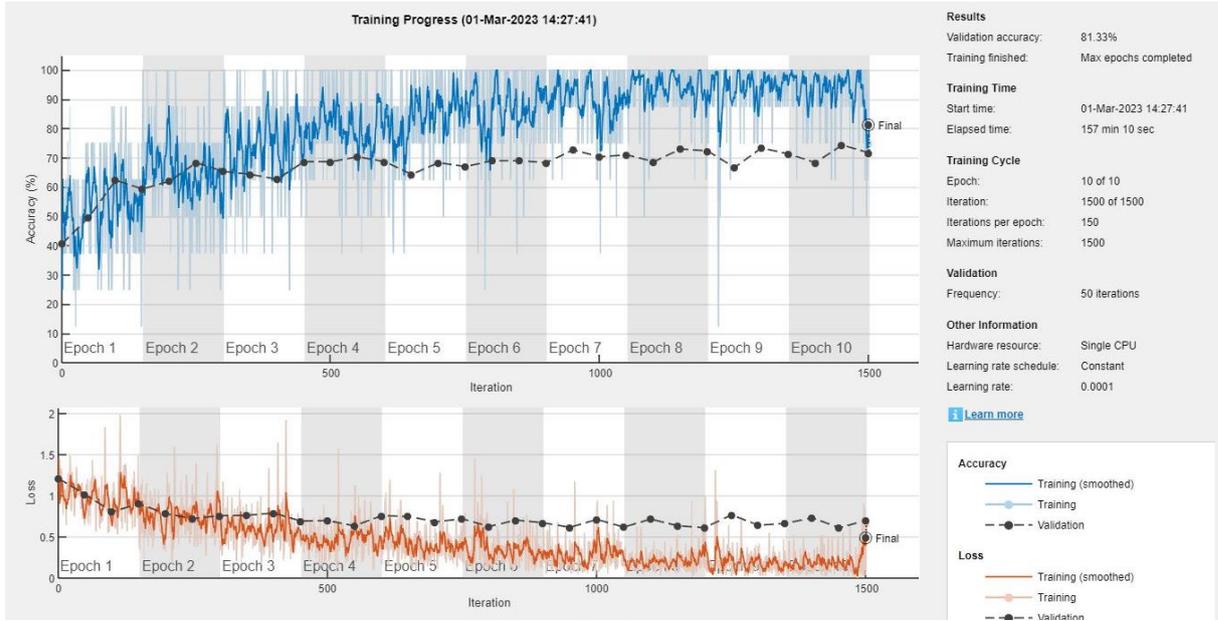


Fonte: Autoria própria.

4.4.2. Resnet-50

Destaca-se que a maior acurácia obtida pelo modelo ocorreu no terceiro fold, alcançando um valor de 81,33%, Figura 28.

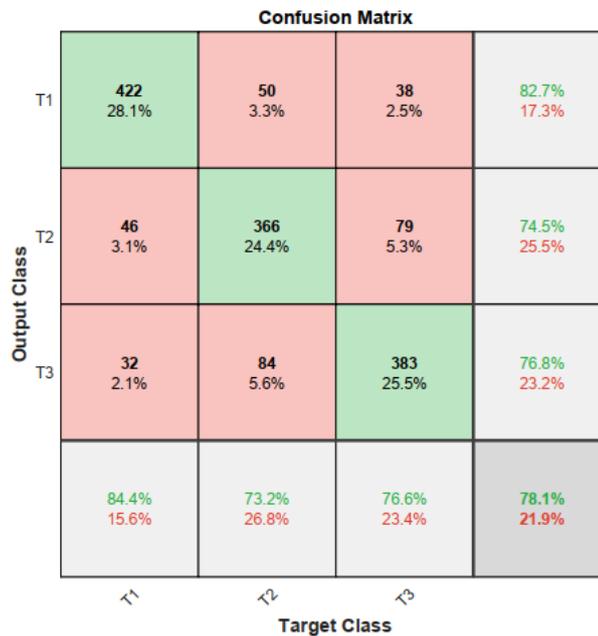
Figura 29. Gráfico de acurácia e perda da Resnet 50 da coleta 3.



Fonte: Autoria própria

A acurácia geral obtida para o modelo foi de 78,1%, comparada com o modelo da rede neural própria para a mesma data de coleta, o desempenho foi mais satisfatório, conforme pode ser observado na Figura 29.

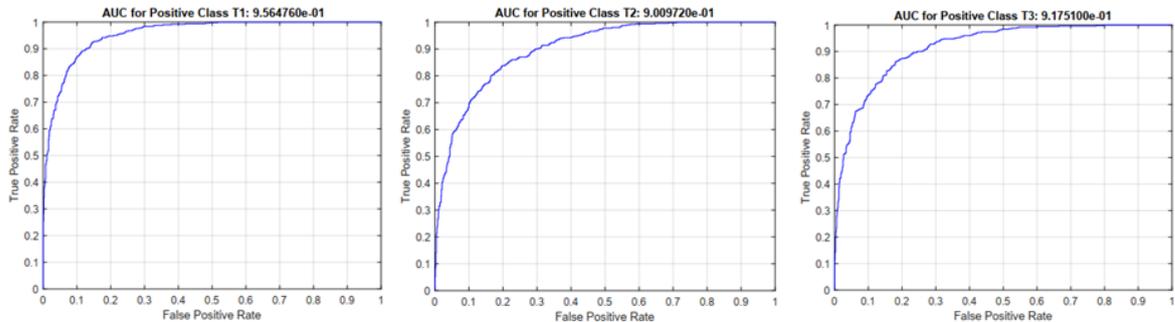
Figura 30. Matriz de confusão da Resnet 50 para coleta 3.



Fonte: Autoria própria

O bom desempenho da Resnet-50 pode ser reforçado com os resultados da AUC para os tratamentos, que segundo Carter et al. (2016) pode ser classificada como excelente, já que se encontra entre 0,9-0,99 como mostra a Figura 31.

Figura 31. Gráfico AUC dos tratamentos utilizados da coleta 3 usando Resnet 50.



Fonte: Autoria própria.

Ao comparar os resultados dos modelos de predição de doses de adubação no estágio de indução floral do morango, podemos observar diferenças significativas entre a CNN própria e a Resnet-50, conforme a Tabela 11. Essas diferenças são evidenciadas tanto pela acurácia quanto pela área sob a curva (AUC) para cada tratamento de adubação.

Tabela 11. Resultados obtidos ao utilizar diferentes métricas de avaliação para as folhas do morango.

Métricas de Avaliação	CNN própria			Resnet-50		
	T1	T2	T3	T1	T2	T3
AUC	76%	64%	62%	96%	90%	92%
Acurácia	48%	48%	48%	78%	78%	78%
Sensibilidade	60%	44%	40%	84%	73%	77%
Especificidade	42%	50%	52%	75%	81%	79%
Precisão	34%	31%	29%	63%	65%	64%
Recall	60%	44%	40%	84%	73%	77%
F1 score	44%	36%	34%	72%	69%	70%
G-mean	50%	47%	46%	80%	77%	78%

Fonte: Autoria própria

No estágio de indução floral, a CNN própria apresentou para cada tratamento uma acurácia de T1 = 76%, T2 = 64% e T3 = 62%. Esses valores indicam uma capacidade moderada de predição por parte do modelo. Embora seja positivo que a AUC para os três tratamentos esteja acima de 0,5, indicando uma capacidade de discriminação melhor do que uma escolha aleatória, os resultados da CNN própria sugerem uma precisão relativamente limitada na predição das doses de adubação nesse estágio.

Por outro lado, a Resnet-50 apresentou um desempenho superior. A acurácia foi de T1 = 96%, T2 = 90% e T3 = 92%. Esses valores indicam uma alta taxa de previsões corretas, o que é promissor para a utilização desse modelo na predição das doses de adubação. Além disso, a AUC de 0,9 para os três tratamentos reforça a capacidade discriminativa robusta da Resnet-50 nesse estágio do cultivo.

Estudo realizado por Costa et al. (2020) alcançou 94,6% de AP em um grande conjunto de dados com todas as camadas ajustadas da ResNet-50 foi aplicado para a detecção de defeitos externos de tomate. Dessa forma, a ResNet pode extrair características relevantes das imagens de folhas de plantas, permitindo que o modelo identifique diferentes níveis de adubação com alta precisão.

Uma das razões para melhoria significativa no desempenho da Resnet-50 é o fato de o estágio de indução floral representar uma fase mais avançada do desenvolvimento das plantas. Nesse estágio, é provável que ocorram alterações morfológicas e fisiológicas mais distintas nas plantas submetidas a diferentes doses de adubação, o que facilita a identificação de padrões por parte do modelo. Essas diferenças visíveis e mensuráveis podem ser capturadas pela Resnet-50, permitindo uma predição mais precisa das doses de adubação.

Ao comparar as arquiteturas de rede neural própria e a Resnet-50 para classificar diferentes dosagens de adubação em plantas, observou-se que a Resnet-50 alcançou uma acurácia superior, como indica na Tabela 12. Isso indica que a Resnet-50 foi mais eficiente em distinguir e classificar corretamente as diferentes doses de adubação aplicadas nas plantas.

Tabela 12. Resumo das acurácia geral para cada coleta.

		Acurácia	
		CNN própria	Resnet-50
	1	44,3%	62,9%
	2	41,5%	66,9%
Coleta	3	48,1%	78,1%

Fonte: Autoria própria.

Além disso, a observação de que o melhor estágio para identificar as diferentes doses de adubação foi na fase de indução floral, o que sugere que a transição para a fase reprodutiva das plantas influencia diretamente as características visuais ou espectrais que podem ser utilizadas para diferenciar as dosagens de adubação. A fase de indução floral pode ser um momento em que as plantas apresentam características distintas em resposta à disponibilidade de nutrientes, incluindo o nitrogênio.

Esses resultados destacam a importância de considerar o estágio de desenvolvimento das plantas ao avaliar a eficácia de diferentes arquiteturas de rede neural na classificação de dosagens de adubação. A sensibilidade da rede neural à fase de indução floral indica a relevância desse estágio para a detecção e diferenciação de diferentes doses de adubação.

Tabela 13. AUC para os tratamentos em diferentes coletas.

Tratamento	CNN	Resnet-50
	Coleta 1	
50	67%	85%
100	61%	79%
150	60%	80%
Coleta 2		
50	60%	85%
100	57%	84%
150	59%	85%
Coleta 3		
50	76%	96%
100	64%	90%
150	62%	92%

Fonte: Autoria própria.

Ao comparar as arquiteturas de rede neural própria e a Resnet-50 para classificar diferentes dosagens de adubação na planta, a AUC obtida pela ResNet-50 foi superior, como demonstra a Tabela 13. Dessa forma, a utilização de uma rede neural convolucional como a ResNet-50 pode ser uma estratégia eficaz para a classificação de diferentes dosagens de adubação na planta, e a fase de indução floral pode ser um período importante para a identificação dessas doses.

5 CONCLUSÃO

O estudo comparativo das arquiteturas de redes neurais convolucionais para a predição da adubação de nitrogênio em cultivo de morangos mostrou que a arquitetura ResNet-50 obteve melhores resultados em comparação com a rede neural própria. Essa constatação indica que a utilização de uma arquitetura pré-treinada como a ResNet-50 pode trazer benefícios significativos para a modelagem e classificação nesse contexto específico.

Ressalta-se a importância de considerar a arquitetura da rede neural e o estágio de desenvolvimento das plantas ao projetar modelos para a predição da adubação de nitrogênio em cultivo de morangos. A utilização da ResNet-50 apresentou desempenho superior, fornecendo resultados mais precisos e discriminando melhor as diferentes dosagens de adubação, especialmente durante o estágio de indução floral.

Pesquisas futuras devem explorar ainda mais o uso de redes neurais convolucionais e considerar a integração de informações adicionais para aprimorar a precisão das predições do teor de nitrogênio foliar na cultura do morango. Recomenda-se a realização de pesquisas adicionais, abrangendo mais estágios de desenvolvimento das plantas, a exploração de outras arquiteturas de redes neurais convolucionais e o uso de conjuntos de dados mais abrangentes e diversificados.

REFERÊNCIAS

- ABDULLAHI, Halimatu Sadiyah; SHERIFF, Ray E.. Introduction to deep learning in precision agriculture: farm image feature detection using unmanned aerial vehicles through classification and optimization process of machine learning with convolution neural network. **Deep Learning For Sustainable Agriculture**, [S.L.], p. 81-107, 2022. Elsevier. <http://dx.doi.org/10.1016/b978-0-323-85214-2.00013-6>.
- ACM Trans. Multimedia Comput. Commun. Appl.** n. 13, v.3, 2017.
- Andrianjaka-Camps *et al.* (2017) (ANDRIANJAKA-CAMPS *et al.*, 2017)
- ANDRIANJAKA-CAMPS, Zo-Noroso; HERITIER, Julien; ANÇAY, André; ANDLAUER, Wilfried; CARLEN, Christoph. Evolution of the taste-related and bioactive compound profiles of the external and internal tissues of strawberry fruits (*Fragaria x ananassa*) cv. 'Clery' during ripening. **Journal Of Berry Research**, [S.L.], v. 7, n. 1, p. 11-22, 22 mar. 2017. IOS Press. <http://dx.doi.org/10.3233/jbr-160142>.
- ANTUNES, Luís Eduardo Corrêa et al. Morango: produção aumenta ano a ano. 2021. Embrapa Clima Temperado. Disponível em: <http://www.alice.cnptia.embrapa.br/alice/handle/doc/1131057>. Acesso em: 01 mar. 2023.
- AZADNIA, Rahim; KHEIRALIPOUR, Kamran. Recognition of leaves of different medicinal plant species using a robust image processing algorithm and artificial neural networks classifier. **Journal Of Applied Research On Medicinal And Aromatic Plants**, [S.L.], v. 25, p. 100327, dez. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.jarmap.2021.100327>.
- BACKES, André Ricardo; JUNIOR, Sá; DE MESQUITA, Jarbas Joaci. **Introdução à visão computacional usando Matlab**. Alta Books Editora, 2016.
- BAESSO, Murilo Mesquita. **ANÁLISE DO STATUS DO NITROGÊNIO NO FEIJOEIRO UTILIZANDO IMAGENS DIGITAIS**. 2005. 64 f. Tese (Doutorado) - Curso de Engenharia Agrícola, Universidade Federal de Viçosa, Viçosa, 2005.
- BENGIO, Yoshua. Practical recommendations for gradient-based training of deep architectures. **Neural Networks: Tricks of the Trade: Second Edition**, p. 437-478, 2012.
- BERTOLINI, Caio Augusto; TECH, Adriano Rogério Bruno; BAESSO, Murilo Mesquita; ROSSI, Fabrício; PEREIRA, Lilian Elgalise Techio. DESAFIOS NO USO DE ÍNDICES DE VEGETAÇÃO BASEADOS NO RGB PARA DIAGNÓSTICO DO STATUS DE NITROGÊNIO EM GRAMÍNEAS SOB PASTEJO. **Zootecnia de Precisão: desafios e aplicações**, [S.L.], p. 74-93, 2021. Editora Científica Digital. <http://dx.doi.org/10.37885/211106788>.
- BOCHIE, Kaylani et al. Aprendizado profundo em redes desafiadoras: Conceitos e aplicações. **Sociedade Brasileira de Computação**, 2020.
- BORTH, Marcelo Rafael et al. A visão computacional no agronegócio: Aplicações e direcionamentos. **7 Encontro Científico de Administração, Economia e Contabilidade (ECAECO)**, 2014.

CARTER, Jane V.; PAN, Jianmin; RAI, Shesh N.; GALANDIUK, Susan. ROC-ing along: evaluation and interpretation of receiver operating characteristic curves. **Surgery**, [S.L.], v. 159, n. 6, p. 1638-1645, jun. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.surg.2015.12.029>.

CHENG, Weiwei; SUN, Da-Wen; PU, Hongbin; WEI, Qingyi. Chemical spoilage extent traceability of two kinds of processed pork meats using one multispectral system developed by hyperspectral imaging combined with effective variable selection methods. **Food Chemistry**, [S.L.], v. 221, p. 1989-1996, abr. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.foodchem.2016.11.093>.

CONCI, Aura; AZEVEDO, Eduardo; LETA, Fabiana R. Computação gráfica–teoria e prática,[v. 2]. **Rio de Janeiro**, 2008.

CONGALTON, R.G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote sensing thematic accuracy assessment: A compendium**, n 37, p.35-46, 1991.

COSTA, Arthur Z. da; FIGUEROA, Hugo E.H.; FRACAROLLI, Juliana A.. Computer vision based detection of external defects on tomatoes using deep learning. **Biosystems Engineering**, [S.L.], v. 190, p. 131-144, fev. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.biosystemseng.2019.12.003>.

DA SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. Redes neurais artificiais para engenharia e ciências aplicadas-curso prático. **São Paulo: Artliber**, 2010.

DARROW, G. M. The strawberry–history, breeding and physiology. The New England Institute for Medical Research. 1966.

DECHEN, A. R.; NACHTIGALL, G. R. Micronutrientes. In: FERNANDES, M. S. (Ed.). **Nutrição mineral de plantas**. Viçosa, MG: Sociedade Brasileira de Ciência do Solo, 2006. p. 326-354.

DENG, X. The Growth and Yield Responses of *Fragaria ananassa* to Elevated CO₂ and N Supply. **Annals Of Botany**, [S.L.], v. 81, n. 1, p. 67-71, jan. 1998. Oxford University Press (OUP). <http://dx.doi.org/10.1006/anbo.1997.0535>.

DONG, Shi; WANG, Ping; ABBAS, Khushnood. A survey on deep learning and its applications. **Computer Science Review**, [S.L.], v. 40, p. 100379, maio 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.cosrev.2021.100379>.

DURNER, Edward F.. Responses to nitrogen conditioning in ‘Albion’ strawberry (*Fragaria X ananassa* Duch.) for off-season plasticulture production are primarily qualitative rather than quantitative. *Scientia Horticulturae*, [S.L.], v. 257, p. 108684, nov. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.scienta.2019.108684>.

DWIVEDI, Chaitanya; KALRA, Divyanshu; NAIDU, Divesh; AGGARWAL, Swati. Keystroke dynamics based biometric authentication: a hybrid classifier approach. **2018 Ieee Symposium Series On Computational Intelligence (Ssci)**, [S.L.], v., n., p. 266-273, nov. 2018. IEEE. <http://dx.doi.org/10.1109/ssci.2018.8628852>.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **134**: Diagnose Visual de Deficiências Nutricionais do Algodoeiro. Campina Grande: Embrapa, 2013. 11 p.

EMBRAPA. **Manual de análises químicas de solos, plantas e fertilizantes**. 2009. Fábio Cesar da Silva. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/330496/1/Manual-de-analises-quimicas-de-solos-plantas-e-fertilizantes-ed02-reimpressao-2014.pdf>. Acesso em: 20 maio 2023.

EMBRAPA. **VII Plano Diretor da Embrapa 2020-2030**. 2020. Empresa Brasileira de Pesquisa Agropecuária. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/217274/1/VII-PDE-2020.pdf>. Acesso em: 14 mar. 2023.

FEITOSA, Ávila Maria Bastos Santos. **Trocas gasosas, fluorescência da clorofila e crescimento de alfafa em resposta ao alumínio, ao pH e à relação cálcio:magnésio**. 2002. 72 f. Tese (Doutorado) - Curso de Microbiologia Agrícola, Universidade Federal de Viçosa, Viçosa, 2002.

FERREIRA, Daniel Furtado. Sisvar. 2015. Niversidade Federal de Lavras, Departamento de Estatística. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/330496/1/Manual-de-analises-quimicas-de-solos-plantas-e-fertilizantes-ed02-reimpressao-2014.pdf>. Acesso em: 20 maio 2023.

FU, Yuanyuan; YANG, Guijun; PU, Ruiliang; LI, Zhenhai; LI, Heli; XU, Xingang; SONG, Xiaoyu; YANG, Xiaodong; ZHAO, Chunjiang. An overview of crop nitrogen status assessment using hyperspectral remote sensing: current status and perspectives. **European Journal Of Agronomy**, [S.L.], v. 124, p. 126241, mar. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.eja.2021.126241>.

GAJAVALLI, J.; JEYALAKSSHMI, S.. ConvNet of Deep Learning in Plant Disease

GALVÃO, GEFERSON FLÁVIO PORTO et al. Visão computacional para detecção de doenças fúngicas na agricultura. **ÚNICA Cadernos Acadêmicos**, v. 2, n. 1, 2018.

GARRIDO, L. da R.; Hoffmann, A.; Silveira, S. V. Produção integrada de uva para processamento: manejo de pragas e doenças. 2016..

HE, Kaiming et al. Deep residual learning for image recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2016. p. 770-778.

IBGE. **Censo agropecuário**. 2017. Nstituto Brasileiro de Geografia e Estatística. Disponível em: <https://sidra.ibge.gov.br/tabela/6954>. Acesso em: 20 mar. 2023.

IPEA. **Agronegócio brasileiro começa 2023 com superávit de US\$ 8,69 bilhões**. 2023. Instituto de Pesquisa Econômica Aplicada. Disponível em: <https://www.ipea.gov.br/porta/categorias/45-todas-as-noticias/noticias/13523-agronegocio-brasileiro-comeca-2023-com-superavit-de-us-8-69-bilhoes>. Acesso em: 10 abr. 2023.

KIRSCHBAUM, Daniel Santiago et al. Strawberry in South America: from the Caribbean to Patagonia. In: **VIII International Strawberry Symposium 1156**. 2016. p. 947-956.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. **Nature**, [S.L.], v. 521, n. 7553, p. 436-444, 27 maio 2015. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/nature14539>.

LI, Daoliang; SONG, Zhaoyang; QUAN, Chaoqun; XU, Xianbao; LIU, Chang. Recent advances in image fusion technology in agriculture. **Computers And Electronics In Agriculture**, [S.L.], v. 191, p. 106491, dez. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2021.106491>.

LIU, Shen; ROEMER, Frank; GE, Yong; BEDRICK, Edward J.; LI, Zong-Ming; GUERMAZI, Ali; SHARMA, Leena; EATON, Charles; HOCHBERG, Marc C.; HUNTER, David J.. Comparison of Evaluation Metrics of Deep Learning for Imbalanced Imaging Data in Osteoarthritis Studies. **Osteoarthritis And Cartilage**, [S.L.], v. 1, n. 12, p. 1-21, maio 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.joca.2023.05.006>.

LIU, Yiping; LI, Junmin. Comparing the Effectiveness of Two Convolutional Neural Networks Methods on Fault Diagnosis. **2020 Ieee 9Th Data Driven Control And Learning Systems Conference (Ddcls)**, [S.L.], v., n., p. 1-5, 20 nov. 2020. IEEE. <http://dx.doi.org/10.1109/ddcls49620.2020.9275096>.

MACHADO, André Wilson; SOUKI, Bernardo Quiroga. Simplificando a obtenção e a utilização de imagens digitais: scanners e câmeras digitais. **Revista Dental Press de Ortodontia e Ortopedia Facial**, [S.L.], v. 9, n. 4, p. 133-156, ago. 2004. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1415-54192004000400012>.

MAO, Qian; HU, Fei; HAO, Qi. Deep learning for intelligent wireless networks: A comprehensive survey. **IEEE Communications Surveys & Tutorials**, v. 20, n. 4, p. 2595-2621, 2018.

MAPA. **Vendas externas do agronegócio somam US\$ 96,8 bilhões em 2019**. 2020. Ministério da Agricultura, Pecuária e Abastecimento. Disponível em: <https://www.gov.br/pt-br/noticias/agricultura-e-pecuaria/2020/01/vendas-externas-do-agronegocio-somam-us-96-8-bilhoes-em-2019>. Acesso em: 14 mar. 2023.

MATHWORKS. **Monitor Deep Learning Training Progress**. 2023. Disponível em: <https://www.mathworks.com/help/deeplearning/ug/monitor-deep-learning-training-progress.html>. Acesso em: 04 fev. 2023.

MELO, Leonardo Leite de. **Deep learning para identificação de déficit hídrico em plantas com base em imagens térmicas**. 2021. 87 f. Tese (Doutorado) - Curso de Engenharia de Sistemas Agrícolas, Escola Superior de Agricultura "Luiz de Queiroz", Piracicaba, 2021.

MUELLER, John Paul; MASSARON, Luca. **Deep learning for dummies**. John Wiley & Sons, 2019.

NAYAK, Anshuman; CHAKRABORTY, Somsubhra; SWAIN, Dillip Kumar. Application of smartphone-image processing and transfer learning for rice disease and nutrient deficiency detection. **Smart Agricultural Technology**, [S.L.], v. 4, p. 100195, ago. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.atech.2023.100195>.

NISBET, Robert; MINER, Gary; YALE, Ken. **Handbook of Statistical Analysis and Data Mining Applications**. 2. ed. Índia: Candice Janco, 2018. 795 p.

NORVIG, Peter; RUSSELL, Stuart. Inteligência artificial. **Rio de Janeiro: Grupo GEN**, 2013.

OLIVEIRA, J. B., & PRADO, H. Levantamento pedológico do estado de São Paulo: quadrícula de São Carlos. II Memorial descritivo. *Boletim Técnico do Instituto Agrônomo de Campinas*, 98, 1- 188, 1984

PALENCIA, P.; MARTINEZ, F.; RIBEIRO, E.; PESTANA, M.; GAMA, F.; SAAVEDRA, T.; VARENNES, A. de; CORREIA, P.J.. Relationship between tipburn and leaf mineral composition in strawberry. **Scientia Horticulturae**, [S.L.], v. 126, n. 2, p. 242-246, set. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.scienta.2010.07.024>.

PASSOS, Francisco A.; TRANI, Paulo E.. **Calagem e adubação do morangueiro**. 2013. Instituto agrônomo de Campinas. Disponível em: https://www.iac.sp.gov.br/imagem_informacoestecnologicas/88.pdf. Acesso em: 20 abr. 2023.

PEREIRA, F.R.Da S.; LIMA, J.P. de; FREITAS, R.G.; REIS, A.A. dos; AMARAL, L.R.Do; FIGUEIREDO, G.K.D.A.; LAMPARELLI, R.A.C.; MAGALHÃES, P.s.G.. Nitrogen variability assessment of pasture fields under an integrated crop-livestock system using UAV, PlanetScope, and Sentinel-2 data. **Computers And Electronics In Agriculture**, [S.L.], v. 193, p. 106645, fev. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2021.106645>.

POULADZADEH, Parisa; SHIRMOHAMMADI, Shervin. Mobile multi-food recognition using deep learning. **ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)**, v. 13, n. 3s, p. 1-21, 2017.

PRÁ, Bruno Rover dal. **Desenvolvimento de modelos de redes neurais convolucionais para avaliação nutricional da Brachiaria brizantha**. 2020. 120 f. Tese (Doutorado) - Curso de Ciências na Área de Tecnologia Nuclear - Reatores, Instituto de Pesquisas Energéticas e Nucleares, São Paulo, 2020.

PRADO, Renato de Mello; CAIONE, Gustavo. Plant Analysis. **Soil Fertility**, [S.L.], p. 115-134, 12 dez. 2012. InTech. <http://dx.doi.org/10.5772/53388>.

PULLANAGARI, R.R.; DEGHAN-SHOAR, Mohammad; YULE, Ian J.; BHATIA, N.. Field spectroscopy of canopy nitrogen concentration in temperate grasslands using a convolutional neural network. **Remote Sensing Of Environment**, [S.L.], v. 257, p. 112353, maio 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2021.112353>.

RICHTER, Adrik Francis; FAGUERAZZI, Antonio Felipe; ZANIN, Daniel Suck; CAMARGO, Samila Silva; ARRUDA, Ana Luiza; KRETZSCHMAR, Aike Anneliese; RUFATO, Leo; SILVA, Pricila Santos. PRODUTIVIDADE E QUALIDADE DO MORANGO SOB CULTIVO DE SOLO E SEMI-HIDROPÔNICO. **Revista Científica Rural**, Sl, v. 20, n. 1, p. 193-203, jan. 2018.

RODRIGUES, Nuno M.; MALAN, Katherine M.; OCHOA, Gabriela; VANNESCHI, Leonardo; SILVA, Sara. Fitness landscape analysis of convolutional neural network architectures for image classification. **Information Sciences**, [S.L.], v. 609, p. 711-726, set. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.ins.2022.07.040>.

ROMUALDO, L.M.; LUZ, P.H.C.; DEVECHIO, F.F.s.; MARIN, M.A.; ZÑIGA, A.M.G.; BRUNO, O.M.; HERLING, V.R.. Use of artificial vision techniques for diagnostic of nitrogen nutritional status in maize plants. **Computers And Electronics In Agriculture**, [S.L.], v. 104, p. 63-70, jun. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2014.03.009>.

SABZI, Sajad; POURDARBANI, Raziéh; ROHBAN, Mohammad H.; GARCÍA-MATEOS, Ginés; ARRIBAS, Juan I. Estimation of nitrogen content in cucumber plant (*Cucumis sativus* L.) leaves using hyperspectral imaging data with neural network and partial least squares regressions. **Chemometrics And Intelligent Laboratory Systems**, [S.L.], v. 217, p. 104404, out. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.chemolab.2021.104404>.

SANKARAN, Sindhuja; MISHRA, Ashish; EHSANI, Reza; DAVIS, Cristina. A review of advanced techniques for detecting plant diseases. **Computers And Electronics In Agriculture**, [S.L.], v. 72, n. 1, p. 1-13, jun. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2010.02.007>.

SANTOS, Marlu da Silva. **Modelos de aprendizagem de máquina para identificar o risco do trabalho escravo contemporâneo em cidades brasileiras**. 2020. 65 f. Dissertação (Mestrado) - Curso de Computação Aplicada, Universidade de Brasília, Brasília, 2020.

SHIN, Jaemyung; CHANG, Young K.; HEUNG, Brandon; NGUYEN-QUANG, Tri; PRICE, Gordon W.; AL-MALLAHI, Ahmad. A deep learning approach for RGB image-based powdery mildew disease detection on strawberry leaves. **Computers And Electronics In Agriculture**, [S.L.], v. 183, p. 106042, abr. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2021.106042>.

SINGH, Rajbir; GUPTA, R.K.; PATIL, R.T.; SHARMA, R.R.; ASREY, R.; KUMAR, A.; JANGRA, K.K.. Sequential foliar application of vermicompost leachates improves marketable fruit yield and quality of strawberry (*Fragaria×ananassa* Duch.). **Scientia Horticulturae**, [S.L.], v. 124, n. 1, p. 34-39, fev. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.scienta.2009.12.002>.

SOUZA, Maione Almeida de. Panorama nacional da produção de morangos. *Campo e Negócio*, [s. l], v. , n. , p. 0-0, 21 abr. 2022. Disponível em: <https://revistacampoenegocios.com.br/panorama-nacional-da-producao-de-morangos/>. Acesso em: 10 abr. 2023.

SUBEESH, A.; BHOLE, S.; SINGH, K.; CHANDEL, N.s.; RAJWADE, Y.A.; RAO, K.V.R.; KUMAR, S.P.; JAT, D.. Deep convolutional neural network models for weed detection in polyhouse grown bell peppers. **Artificial Intelligence In Agriculture**, [S.L.], v. 6, p. 47-54, 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.aiia.2022.01.002>.

TAIZ, Lincoln; ZEIGER, Eduardo. Fisiologia vegetal. 5. ed. Porto Alegre: Artmed, 2013.

TENG, Jianing; ZHANG, Dong; LEE, Dah-Jye; CHOU, Yao. Recognition of Chinese food using convolutional neural network. **Multimedia Tools And Applications**, [S.L.], v. 78, n. 9, p. 11155-11172, 21 set. 2018. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11042-018-6695-9>.

TOO, Edna Chebet; YUJIAN, Li; NJUKI, Sam; YINGCHUN, Liu. A comparative study of fine-tuning deep learning models for plant disease identification. **Computers And Electronics In Agriculture**, [S.L.], v. 161, p. 272-279, jun. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2018.03.032>.

VIGNOLO, Gerson Kleinick et al. Produção de morangos a partir de fertilizantes alternativos em pré-plantio. **Ciência Rural**, v. 41, p. 1755-1761, 2011.

WANG, Zhonglin; CHEN, Junxu; FAN, Yuanfang; CHENG, Yajiao; WU, Xiaoling;

XIE, Kun; REN, Yuhan; CHEN, Aiqun; YANG, Congfan; ZHENG, Qingsong; CHEN, Jun; WANG, Dongsheng; LI, Yiting; HU, Shuijin; XU, Guohua. Plant nitrogen nutrition: the roles of arbuscular mycorrhizal fungi. **Journal Of Plant Physiology**, [S.L.], v. 269, p. 153591, fev. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.jplph.2021.153591>.

ZAFAR, Iffat et al. **Hands-on convolutional neural networks with TensorFlow: Solve computer vision problems with modeling in TensorFlow and Python**. Packt Publishing Ltd, 2018.