

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERNÁRIAS
POS-GRADUAÇÃO EM AGRONOMIA (GENÉTICA E
MELHORAMENTO DE PLANTAS)**

**REDES NEURAIIS CONVOLUCIONAIS E IMAGENS RGB
NA CLASSIFICAÇÃO DE GENÓTIPOS DE BATATA-
DOCE (*Ipomoea batatas* (L.) Lam.)**

Juviliano Bonifácio da Costa

Engenheiro Agrônomo

Jaboticabal, SP

2026

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
POS-GRADUAÇÃO EM AGRONOMIA (GENÉTICA E
MELHORAMENTO DE PLANTAS)**

**REDES NEURAIS CONVOLUCIONAIS E IMAGENS
RGB NA CLASSIFICAÇÃO DE GENÓTIPOS DE
BATATA-DOCE (*Ipomoea batatas* (L.) Lam.)**

**Discente: Juviliano Bonifácio da Costa
Orientador: Prof. Dr. David Luciano Rosalen**

Dissertação apresentada à Faculdade de Ciências Agrárias e Veterinárias - Unesp, Campus de Jaboticabal, como parte das exigências para a obtenção do título de Mestre em Agronomia (Genética e Melhoramento de Plantas).

Jaboticabal, SP

2026

C837r

Costa, Juviliano Bonifácio da

Redes neurais convolucionais e imagens RGB na classificação de genótipos de batata-doce (*Ipomoea batatas* (L.) Lam.) / Juviliano Bonifácio da Costa. -- Jaboticabal, 2026

68 p. : il., tabs., fotos, mapas

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientador: David Luciano Rosalen

1. Fenotipagem de batata-doce. 2. Sensoriamento remoto. 3. Inteligencia artificial. I. Título.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: REDES NEURAIS CONVOLUCIONAIS E IMAGENS RGB NA CLASSIFICAÇÃO DE GENÓTIPOS DE BATATADOCE (*Ipomoea batatas* (L.) Lam.)

AUTOR: JUVILIANO BONIFÁCIO DA COSTA

ORIENTADOR: DAVID LUCIANO ROSALEN

Aprovado como parte das exigências para obtenção do Título de Mestre em Agronomia (Genética e Melhoramento de Plantas), pela Comissão Examinadora:

David Luciano

Rosalen:83555285734

Assinado de forma digital por David
Luciano Rosalen:83555285734
Dados: 2026.07.09 11:04:45 -03'00'

Prof. Dr. DAVID LUCIANO ROSALEN (Participação Presencial)

Departamento de Engenharia / UNESP / Câmpus de Jaboticabal - FCAV



Assinado de forma digital por

José María García

09/07/2026

Prof. Dr. JOSÉ MARÍA GARCÍA (Participação Virtual)

Instituto Nacional de Tecnología Agropecuaria (INTA) / San Miguel de Tucumán/Argentina



Assinado de forma digital por Pablo

Forlan Vargas

Dados: 2026.07.09 12:45:25 -03'00'

Prof. Dr. PABLO FORLAN VARGAS (Participação Presencial)

Departamento de Produção Vegetal / UNESP / Câmpus de Jaboticabal - FCAV

Jaboticabal, 03 de julho de 2026.

DADOS CURRICULARES DO AUTOR

JUVILIANO BONIFÁCIO DA COSTA, nasceu em 1 de maio de 1996 na cidade de Calequisse na região de Cacheu, Guiné-Bissau. Filho de Bonifácio João da Costa e de Elvira Gomes. É Engenheiro Agrônomo, formado pela Universidade da Integração Internacional da Lusofonia Afro-brasileira (UNILAB) em 2024. Durante a graduação, participou no grupo de estudo em Recursos Genéticos e Melhoramento de Plantas (GEREM) entre 2020 a 2024. Foi bolsista de iniciação científica financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) entre 2021 a 2022. Desenvolveu as atividades da Seleção Recorrente Intrapopulacional para obtenção de variedade de milho adaptada ao Maciço de Baturité terceiro ciclo (C3). Possui o estágio no GEREM, contribuiu na introdução de genótipos de mirtilo no Maciço de Baturité, na Fazenda Experimental Piorás - Ceará. Além disso, atuou como estagiário na Empresa de Assistência Técnica e Extensão Rural do Ceará (EMATERCE), exerceu a função de Assistente Técnico e Extensão Rural. Participou ativamente nas atividades acadêmicas e na representação estudantil. Foi membro do grupo de estudantes guineenses de Agronomia e Engenharia de Alimentos da UNILAB, atuando como conselheiro fiscal por dois anos. Também integrou Empresa Júnior (AGOZONE/UNILAB), desempenhou a função de Diretor de Projetos. Possui título de especialização em Agricultura de Precisão pela Faculdade de Minas (FACULMINAS) em maio de 2024. Em agosto de 2024, iniciou o mestrado em Agronomia (Genética e Melhoramento de Plantas) pela Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias (FCAV), Câmpus de Jaboticabal, sob orientação de Prof. Dr. David Luciano Rosalen, como bolsista de CAPES, desenvolveu uma pesquisa de fenotipagem de alto rendimento de batata-doce.

Aos meus pais, Bonifácio J. da Costa e Elvira Gomes, aos meus tios, Claudio J. Costa e Abel J. da Costa por me proporcionarem verdadeiros exemplos de força, coragem e determinação na busca dos meus objetivos. Os ensinamentos, o apoio constante e os valores que me transmitiram foram fundamentais ao longo desta jornada. Esta conquista também lhes pertence, por sempre acreditarem em mim.

Dedico

AGRADECIMENTOS

À Deus, por guiar meus passos, sobretudo nos dias difíceis, e conceder-me a resiliência e sabedoria para concretização deste trabalho.

À minha família: Elvira, Eugênia, Bonifácio, Claudio, Sanete, Pascoalina Mende, Mário, Soares, Euclides, Kamila Barbosa, Ismael Juviliano, Raquel, Leoneza, Júlio Vilela, Avelino Vilela, Aldair Velez Gomes, Aureliano Quessana, Liliana, Helia, sempre estiverem ao meu lado, pelo amor, apoio, incentivo e confiança em todos os momentos.

Aos amigos, em especialmente Bubacar Baldé e Leonardo Gaviria Galeano, que estiveram comigo nos momentos de alegria e de dificuldade, oferecendo apoio, palavras dolorosas de incentivo e amizade verdadeira.

Ao Programa de Pós-graduação em Agronomia (Genética e Melhoramento de Plantas), na Universidade Estadual Paulista – UNESP Câmpus de Jabotical, pela imensa oportunidade de realização do curso e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela oportunidade e pela concessão da bolsa do estudo.

Ao Laboratório de Núcleo de Geomática e Agricultura de Precisão (NGAP), pelo apoio técnico-científico e infraestrutura disponibilizada durante o período do desenvolvimento desta pesquisa.

Ao Prof. Dr. David Luciano Rosalen, expresso minha sincera gratidão por ter acreditado me orientar ao longo da minha vida acadêmica, pela confiança, pelos ensinamentos, pela paciência nos momentos de dificuldade e pelo constante incentivo.

Aos membros da Banca Examinadora de Qualificação e Defesa, Prof. Dr. Pablo Forlan Vargas e Prof. Dr. José María García, por aceitarem o convite para participar da avaliação deste trabalho e pelas valiosas contribuições.

Aos colegas do Laboratório, em especial Tainá Oliveira, Felipe Diniz, Edvaldo Nhanombe, Pedro Gomes e Souradj Idrissou, pelo apoio e acompanhamento ao longo desta jornada, bem como a todos que, direta ou indiretamente, contribuíram para parte da minha formação.

Este trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código do financiamento 001

Sumário

SUMÁRIO.....	i
LISTA DE FIGURAS.....	ii
LISTA DE TABELAS.....	iii
RESUMO.....	iv
ABSTRACT.....	v
1 INTRODUÇÃO.....	1
2 REVISÃO DA LITERATURA.....	3
2.1 Descrição e Importância Socioeconômica de Batata-doce.....	3
2.3 Melhoramento Genético e Fenotipagem de Alto Rendimento de Batata-doce.....	5
2.4 Sensoriamento Remoto e Agricultura Digital.....	7
2.5 Inteligência Artificial e Redes Neurais Convolucionais.....	11
3 MATERIAL E MÉTODOS.....	15
3.1 Obtenção dos Genótipos e Localização Experimental.....	15
3.2 Condução Experimental.....	16
3.3 Aquisição das Imagens.....	18
3.5 Pré-processamento de Dataset.....	19
4 RESULTADOS.....	24
4.1 Desempenho de Treinamento e Curva de Aprendizado de Redes Neurais Convolucionais em Imagens das Raízes de Batata-doce.....	24
4.2 Desempenho de Treinamento e Curva de Aprendizado das Redes Neurais Convolucionais em Imagens de Polpa.....	26
4.3 Desempenho de Métricas Entre os Algoritmos na Classificação das Raízes de Batata-doce.....	28
4.4 Desempenho de Métricas Entre os Algoritmos na Classificação dos Genótipos de Batata-doce a Partir da Polpa.....	31
4.6 Análise de Matriz de Confusão das raízes de Batata-doce.....	34
4.5 Análise de Matriz de Confusão Polpa.....	37
5 DISCUSSÃO.....	40
6 CONCLUSÕES.....	46
7 REFERÊNCIAS.....	47

LISTA DE FIGURAS

Figura 1. Localização Experimental, Faculdade de Ciências Agrárias e Veterinária - UNESP, 2026.....	16
Figura 2. Variações meteorológicas ao longo da condução experimental, entre abril e setembro de 2025, incluindo precipitação pluviométrica (mm), temperatura máxima (Tmax), média (Tmed) e mínima (Tmin) (°C) e umidade relativa do ar (UR, %).....	17
Figura 3. Colheita de genótipos de batata-doce no campo experimental (Fonte: Autoria própria, 2025).....	17
Figura 4. Genótipos avaliados no presente trabalho (Fonte: Autoria própria, 2025).....	18
Figura 5. Coleta das imagens RGB de genótipos da batata-doce (Fonte: Autoria própria, 2025).	19
Figura 6. Precisões de treinamentos e validações; perdas e validações de MobileNetV2 no conjunto das imagens das raízes de batata-doce.....	24
Figura 7. Precisões de treinamentos e validações; perdas e validações do DenseNet121 no conjunto das imagens das raízes de batata-doce.....	25
Figura 8. Precisões de treinamentos e validações; perdas e validações de ResNet50 no conjunto das imagens das raízes de batata-doce.....	26
Figura 9. Precisões de treinamentos e validações; perdas e validações de MobileNetV2 no conjunto das imagens de polpa de batata-doce.....	27
Figura 10. Precisões de treinamentos e validações; perdas e validações de DenseNet121 no conjunto das imagens de polpa de batata-doce.....	27
Figura 11. Precisões de treinamentos e validações; perdas e validações de ResNet50 no conjunto das imagens de polpa de batata-doce.....	28
Figura 12. Matriz de confusão na predição das raízes de batata-doce com MobileNetV2.....	35
Figura 13. Matriz de confusão na predição das raízes de batata-doce com DenseNet121.....	36
Figura 14. Matriz de confusão na predição das raízes de batata-doce com RestNet5.....	37
Figura 15. Matriz de confusão na predição de polpa de batata-doce com MobileNetV2.....	38
Figura 16. Matriz de confusão na predição de polpa de batata-doce com DenseNet121.....	39
Figura 17. Matriz de confusão na predição de polpa de batata-doce com ResNet50.....	40

LISTA DE TABELAS

Tabela 1. Cultivares de batata-doce (<i>Ipomoea batatas</i> L.) desenvolvidas pela Embrapa e pela Unesp, registradas no Ministério da Agricultura, Pecuária e Abastecimento (MAPA).....	6
Tabela 2. Resumo de análise de métricas de precisão, recall, F1-score e acurácia das imagens das raízes no modelo MobileNetV2.....	29
Tabela 3. Resumo de análise de métricas de precisão, recall, F1-score e acurácia das imagens das raízes no modelo DenseNet121.....	30
Tabela 4. Resumo de análise de métricas de precisão, recall, F1-score e acurácia das imagens das raízes no modelo ResNet50.....	31
Tabela 5. Resumo de análise de métricas de precisão, recall, F1-score e acurácia das imagens de polpa no modelo MobileNetV2.....	32
Tabela 6. Resumo de análise de métricas de precisão, recall, F1-score e acurácia de polpa no modelo DenseNet121.....	33
Tabela 7. Resumo de análise de métricas de precisão, recall, F1-score e acurácia de polpa no modelo ResNet50.....	34

REDES NEURAIS CONVOLUCIONAIS E IMAGENS RGB NA CLASSIFICAÇÃO DE GENÓTIPOS DE BATATA-DOCE (*Ipomoea batatas* (L.) Lam.)

RESUMO - A batata-doce é uma cultura que possui alta diversidade genética, capaz de produzir raízes tuberosas, amplamente utilizada na alimentação humana, também como matéria-prima na indústria de alimentos, tecidos, papéis, cosméticos, preparação em diversas formas e álcool carburante, é relevante para o animal. A batata-doce possui alto potencial nutricional, sendo fonte significativa de amido, fibras alimentares, minerais, compostos bioativos, como fenólicos. As tecnologias que estão associadas ao melhoramento genético de plantas para aumentar a produtividade, qualidade comercial de hortaliças, reduzindo as perdas no campo. Redes neurais transformaram profundamente o desempenho da visão computacional nas diversas áreas da inteligência de máquinas, permitindo uma revolução em atividades de reconhecimento visual mais complexas com altos níveis de precisão. Os avanços das redes neurais convolucionais integram na classificação e análise de saúde de plantas a partir sensores com obtenção das imagens hiperespectrais, multiespectrais e RGB. Assim, objetivou-se avaliar o desempenho de diferentes algoritmos de redes neurais convolucionais na classificação de genótipos de batata-doce a partir de imagens RGB. Os genótipos avaliados foram provenientes do programa de melhoramento de batata-doce da Universidade Estadual Paulista. O experimento foi instalado no Setor de Olericultura e Plantas Aromático-Medicinais, da UNESP/Jaboticabal. As imagens foram coletadas por meio de sensor RGB. O dataset de dados foi dividido em 80% para treinamento, 10% para validação e 10% para teste. Foram comparados os desempenhos de arquiteturas de MobileNetV2, ResNet50 e Densenet121 com diferentes números de épocas de treinamentos. Foram avaliadas as seguintes métricas: acurácia, precisão, F1-score, recall e análise de matriz de confusão. Todos os algoritmos apresentaram excelentes métricas, acima de 95% de acurácia global. Na classificação de polpa, DesneNet121 apresentou resultados das métricas ligeiramente superior aos demais. Na classificação das raízes, ResNet50 destacou-se com os melhores resultados. Os resultados proporcionam o potencial dos algoritmos como ferramentas de fenotipagem digital e classificação de raízes de batata-doce.

Palavras-chave: Fenotipagem de batata-doce, Sensoriamento remoto, Inteligência artificial.

CONVOLUTIONAL NEURAL NETWORKS AND RGB IMAGING IN THE CLASSIFICATION OF SWEET POTATO GENOTYPES (*IPOMOEA BATATAS* (L.) LAM.)

ABSTRACT - Sweet potato is a crop with high genetic diversity, capable of producing tuberous roots, widely used for food security, as well as a raw material in the food, textile, paper, cosmetics, and various other industries, and in fuel alcohol production. It is also relevant for animal feed. Sweet potato has high nutritional potential, being a significant source of starch, dietary fiber, minerals, and bioactive compounds such as phenolics. New technologies are associated with the genetic improvement of plants to increase productivity and commercial quality of vegetables, reducing field losses and overcoming subjectivity. Neural networks have profoundly transformed the performance of computer vision in various areas of machine intelligence, enabling a revolution in more complex visual recognition activities with high levels of precisão. Advances in convolutional neural networks integrate the classification and analysis of plant health from sensors, obtaining hyperspectral, multispectral, and RGB images. The objective was to evaluate the performance of different convolutional neural network models in classifying sweet potato genotypes from RGB images. The genotypes evaluated originated from the sweet potato breeding program at São Paulo State University. The experiment was installed in the Vegetable and Aromatic-Medicinal Plants Sector of UNESP/Jaboticabal. Images were collected using an RGB sensor. The dataset was divided into 80% for training, 10% for validation, and 10% for testing. The performance of MobileNetV2, RestNet50, and DenseNet121 architectures with different numbers of training epochs was compared. The following metrics were evaluated: Acurácia, precisão, F1-score, recall, and confusion matrix analysis. All models presented excellent metrics with scores above 95%. In the pulp classification task, DenseNet121 yielded slightly better metric results than the other models. In genotype classification, RestNet50 stood out with the best results. The results demonstrate the potential of these models as tools for digital phenotyping and classification of sweet potato roots.

Keywords: Sweet potato phenotyping, Remote sensing, Artificial intelligence.

1 INTRODUÇÃO

A batata-doce (*Ipomoea batatas* (L.) Lam.) é uma espécie alógama, pertencente à família Convolvulaceae, originária da América Central e América do Sul (Lima et al., 2023). Sendo uma das principais hortaliças mais cultivadas no Brasil (Amaro, et al., 2019). A sua produção vem aumentando nos últimos anos no país, refletindo na demanda crescente, principalmente em função das suas características organolépticas, além da sua capacidade de adaptação às condições edafoclimáticas favoráveis (Fernandes et al., 2021).

A batata-doce é uma espécie dicotiledônea do caule tuberosa que se destaca a sua rusticidade, sendo cultivada em todas as regiões do Brasil devido à sua resistência a pragas e doenças, fácil manejo, alta tolerância à seca, baixo custo da produção e fácil adaptação às condições climáticas (Otoboni et al., 2020).

A espécie *Ipomoea batatas* (L.) possui grande importância, sendo uma das principais culturas tanto para a subsistência dos pequenos produtores quanto para as empresas agrícolas (Troni et al., 2019). É uma das culturas de alta relevância globalmente, devido ao seu alto valor nutritivo e versatilidade, tem impacto socioeconômico, suas raízes são bastante utilizadas para alimentação humana e animal, na indústria para a fabricação de álcool, farinha, amido e pigmentos e para produção de biocombustíveis, como etanol (Zeist et al., 2024).

A fenotipagem de alto rendimento (*High-Throughput Plant Phenotyping* - HTP) tem se consolidado como uma ferramenta crucial na agricultura de precisão e digital, no melhoramento genético com uso das tecnologias digitais nas plantas, permitindo a coleta rápida e precisa de dados fenotípicos em larga escala (Villagran et al., 2024). Antigamente, era necessário realizar medições manuais em campo de fenotipagem, experimento por experimento, parcela por parcela. Com avanço tecnológico, a fenotipagem de alto rendimento está em constante desenvolvimento e aplicação, tornando-se cada vez mais acessíveis graças ao uso de drones equipados com sensores espectrais (Herrmann Junior et al., 2019).

O HTP apresenta grande importância no melhoramento genético de plantas, pois, permite lidar com o volume, a velocidade e a variedade de dados capturados por sensoriamento remoto (Thompson et al., 2020). No entanto, essa abordagem pode

requerer infraestrutura avançada como sistema de armazenamento de dados, bancos de dados robustos e pipelines de processamento de dados computacionalmente intensivos.

O melhoramento genético da batata-doce é um processo muito intenso devido ao grande número de características que precisam ser analisadas, alta demanda de uso de mão de obra e semelhanças entre genótipos. O uso de tecnologias de HTP da batata-doce surge como uma alternativa eficiente e promissora para reduzir esses desafios (Fernandes, 2022).

As técnicas de HTP por meio de sensores RGB, multiespectrais e hiperespectrais podem auxiliar os melhoristas para captura imagens precisas e em alta resolução sobre as plantas, tanto em escala geográfica quanto em escala de parcelas experimentais (Resende et al., 2023). Essa tecnologia facilita o monitoramento eficiente das plantas e de seu ambiente, sendo crucial para compreender a relação entre fenótipo e genótipo, possibilitando uma seleção mais acurada baseada em características desejáveis.

Sendo assim, avaliação de progênies de batata-doce por meio de técnicas de HTP pode melhorar e aumentar a capacidade do processo de melhoramento genético da batata-doce, enfrentando desafios, como a demanda por análises de múltiplas características fenotípicas e a semelhança entre genótipos, o que torna o processo tradicional de seleção demorado e de custo elevado.

As tecnologias de visão computacional, redes neurais convolucionais e aprendizado de máquinas representam uma oportunidade para expandir e aprimorar a prática agrícola com os métodos de processamento de imagem digital. Essas tecnologias são poderosas ferramentas empregadas em estudos de melhoramento genético de plantas na detecção, análise, interpretação dos dados complexos, além de predição dos fenótipos a partir dos seus genótipos (Ma et al., 2018, Niazian e Niebdabla, 2020).

Nesse sentido, trabalho tem por objetivo avaliar o desempenho de algoritmos redes neurais convolucionais na classificação de genótipos de batata-doce a partir de imagens RGB. Especificamente, buscou-se: i) construir um banco de imagens RGB de genótipos de batata-doce para o treinamento e validação dos algoritmos de redes neurais convolucionais; ii) selecionar redes neurais convolucionais adequados para

análise de imagens RGB aplicadas à fenotipagem de batata-doce; iii) avaliar o desempenho individual de diferentes algoritmos de redes neurais para automatizar a identificação de raízes e polpa de batata-doce na base da sua coloração; iv) comparar desempenho e eficiência das métricas de redes neurais convolucionais na classificação de genótipos de batata-doce e v) identificar melhor algoritmo para a discriminação dos genótipos de batata-doce a partir de imagens RGB.

2 REVISÃO DA LITERATURA

2.1 Descrição e Importância Socioeconômica de Batata-doce

A batata-doce é amplamente reconhecida como uma cultura nativa das Américas, a sua origem ainda é objeto de debate na literatura científica, especialmente quanto ao seu processo de evolução e domesticação. Sendo assim, existem duas hipóteses que têm sido propostas para explicar a origem de batata-doce. A primeira demonstra que a espécie tinha originado da hibridação entre *Ipomoea trifida* e *Ipomoea triloba*, enquanto a segunda sugere uma origem por autopoliploidização de populações relacionadas a *Ipomoea trifida*. Na base de estudo de análise moleculares, Roullier et al. (2013), não encontraram evidências que sustentassem a participação de *Ipomoea triloba* na origem de batata-doce. Nessa ocasião, os estudos enfatizaram que a domesticação da espécie tenha ocorrido por meio de múltiplos eventos independentes, envolvendo populações silvestres aparentadas a *Ipomoea trifida*.

A espécie *Ipomoea batatas* L. (Lam.) pertence à família Convolvulaceae, uma das hortaliças mais cultivadas no mundo (Kovtun e Stiurko, 2024, Momenté et al., 2025). A distribuição da espécie desta família é diversificada e adaptada às condições edafoclimáticas das regiões tropicais e subtropicais com cerca de 55 gêneros e 1930 espécies, os principais gêneros são *Ipomoea* (600sp), *Convolvulus* (250), *Cuscuta* (150) e *Jacquemontia* (120) (Rodrigues, 2022).

A cultura é perene, herbácea e rastejante com crescimento indeterminado da das ramas, frequentemente em espiral, glabro ou pubescente, as folhas geralmente apresentam as formas ovais com base cordada, alternas, simples, lobadas com pecíolo longo que varia de 5 a 30 centímetros (Otálora et al., 2024).

As flores de batata-doce são tubulares ou auxiliares, com brancas-rosado a púrpura enquanto as suas raízes são tuberosas (George et al., 2024). A cultura possui alta variabilidade genética, que reflete na diversidade morfológica e sensorial, abrangendo diferentes colorações de casca e de polpa, além de sabores e texturas variados (Bach et al., 2021).

A classificação da batata-doce é diversificada pela morfologia (formato, tamanho, folhas e flores) e pela precocidade. A identificação cromática se baseia na cor da casca (epiderme) e da polpa, incluindo tonalidades brancas, amarelas, laranjas, vermelhas e roxas (Basílio et al., 2022; Sanchez et al., 2020).

A batata-doce é a única da espécie do gênero *Ipomoea* capaz de produzir raízes tuberosas. Sua importância vai além da segurança alimentar globalmente, abrange aplicações na indústria de alimentos (na fabricação de tecidos, papéis, cosméticos, álcool carburante) e na alimentação animal (Leite et al., 2022).

A China lidera a produção mundial da batata-doce com 51,5 milhões toneladas, em uma área colhida estimada de 2,3 milhões de hectares, com uma produtividade média de 22,2 mil kg ha⁻¹ (FAOSTAT, 2026). O Brasil ocupa 14º posição em ranking mundial de produção, com estimativa de 970 mil toneladas em área colhida de 65 mil ha, sua produtividade foi de 14,8 mil kg ha⁻¹ (IBGE, 2026).

Geograficamente, a produção de batata-doce abrange todas as regiões brasileira, evidenciando a ampla adaptação da cultura em diversas condições edafoclimáticas do país. Entre os principais estados produtores do Brasil, destacam-se São Paulo, com 184.970 toneladas, Ceará, com 182.133 toneladas, Rio Grande do Sul, com 140.390 toneladas, Minas Gerais, com 71.208 toneladas e Sergipe, com 67.870 toneladas (IBGE 2026). O desempenho desses estados está associado ao impacto climático desejáveis, tradição da produção agrícola, que favorecem o desenvolvimento, a expansão e a consolidação da cultura de batata-doce.

A batata-doce apresenta grande importância socioeconômica, suas vantagens permitem abordar melhor as questões das seguranças alimentares e mudanças climáticas a nível mundial, principalmente nas zonas de agricultura extensiva como no Brasil (Sapakhova et al., 2023).

A cultura possui um elevado potencial tendo em conta o seu valor nutricional, sendo fonte significativa de amido, alcaloides de fibras alimentares, potássio, fonte de

vitamina C. Rica em carboidratos e minerais, apresenta a estrutura laticíferas que produz látex leitoso, além de alcaloides e compostos bioativos, como polifenóis (ácidos fenólicos e antocianinas), β -caroteno, tocoferóis (Hossain et al., 2022; Xu et al., 2024). Além disso, a cor da polpa e aparência são fundamentais nas características morfológicas que os produtores e consumidores geralmente usam como pistas visuais para tomar decisões sobre os indicadores de qualidade subjacentes, como sabor, qualidade de cozimento e de textura de uma determinada variedade (Nakatumba Nabende et al., 2023).

A produção de batata-doce é amplamente destinada para consumo humana, principalmente as partes de tuberosas de forma cozidas, assadas, fritas, doces, farinha, macarrão e bolo; as folhas são utilizadas para consumo animal; na industrial é utilizada para fabricação de farinha, produção de biscoito, macarrão, biocombustíveis como etanol (Souza et al., 2025).

2.3 Melhoramento Genético e Fenotipagem de Alto Rendimento de Batata-doce

O melhoramento genético de plantas tem avanço significativo nos últimos anos, devido às técnicas dos conhecimentos teóricos e habilidades práticos, as abordagens mais sistemáticas, focando nas seleções de excelentes progênies, nas avaliações de caracteres agrônômicos, fisiológicos e morfológicos para melhorar a eficiência da produtividade e a qualidade de cultivares (Sun et al., 2024).

Geneticamente, a batata-doce é uma planta hexaploide ($2n = 6x = 90$), altamente heterozigótica e alógama, com as características decorrentes da sua poliploidia, elevado número de cromossomos e sistema reprodutivo é predominantemente em alogamia e autoincompatibilidades (Luo et al., 2023). Essa combinação geneticamente confere devido a ampla variabilidade fenotípica, com diversas características que se expressam de forma quantitativa. Conforme Adem et al. (2024), a diversidade de cultivares de batata-doce centraliza nas cores da polpa e de casca das raízes tuberosas.

As tecnologias têm sido utilizadas para desenvolvimento de batata-doce, com foco em melhorar a produtividade, adaptabilidade e as características morfológicas e nutricionais, nesta circunstância, é possível ampliar as variedades mais produtivas

para diferentes regiões, visando aumentar seu potencial econômico e nutricional (Tarua et al., 2021). Atualmente, nota-se uma ampla diversidade genética na batata-doce em regiões produtoras do Brasil, resultante da segregação gerada pela reprodução sexuada e pela introdução das plantas das outras áreas (Fernandes et al., 2021).

O desempenho das cultivares está associado a sabores, texturas, formatos, produtividade, ciclo, critério edafoclimática, porte e arquitetura de planta, entre outras características morfológicas, que atende as demandas de alimento de qualidade (Yan et al., 2022).

As cultivares desenvolvidas pela Embrapa e Universidade Estadual Paulista (UNESP), registradas no Registro Nacional de Cultivares (RNC), conforme a Tabela 1, demonstram séries de lançamentos resultantes de programa de melhoramento. Grandes partes dessas cultivares apresentam adaptação edafoclimática da região, refletindo na busca de materiais mais adequados, e as necessidades locais para produtores e pesquisadores (MAPA 2025).

Tabela 1. Cultivares de batata-doce (*Ipomoea batatas* L.) desenvolvidas pela Embrapa e pela Unesp, registradas no Ministério da Agricultura, Pecuária e Abastecimento (MAPA).

Cultivar	Mantenedor	Registro
Beauregard	EMBRAPA	26934
Blesbok	EMBRAPA HORTALIÇAS – CNPH	54198
Brazlândia Branca	EMBRAPA	7840
Brazlândia Rosada	EMBRAPA	7841
Brazlândia Roxa	EMBRAPA	7852
BRS Amélia	EMBRAPA	27313
BRS Anembé	EMBRAPA	44047
BRS Aurora	EMBRAPA HORTALIÇAS – CNPH	56884
BRS BC179	EMBRAPA	59397
BRS Cottinga	EMBRAPA	44053
BRS Cuia	EMBRAPA	27315
BRS FEPAGRO Viola	EMBRAPA/DDPA	33889
BRS Gaita	EMBRAPA	33890
BRS Kira	EMBRAPA HORTALIÇAS – CNPH	56894
BRS Rubissol	EMBRAPA	27314
CIP BRS Nuti	EMBRAPA	46899
Coquinho	EMBRAPA	7849
Iapar 70	IAPAR-EMATER	2323
Princesa	EMBRAPA	6495
Unesp Maria Eduarda	UNESP	54891
Unesp Maria Isabel	UNESP	54920
Unesp Maria Rita	UNESP	54667

Fonte: MAPA, 2025.

No programa de melhoramento genético de plantas é comum a fenotipagem de grandes populações para avaliação de diversas características fenotípicas de interesse agrônômica ao longo do ciclo da cultura (Gill et al., 2022).

A fenotipagem de plantas, visualmente, permite realização das medições manuais no campo para análise de grandes volumes de dados, enfrentando desafios cruciais no programa de melhoramento genético de plantas (Resende et al., 2023). Neste sentido, a HTP surgiu como alternativa para usufruir essa demanda e acelerar os esforços de melhoramento de cultivares.

Este processo torna-se essencial adoção das tecnologias de HTP, capazes de lidar com volume de dados complexos e extrair informações precisas para auxiliar na tomada de decisões nos programa do melhoramento genético dos vegetais (Sandhu et al., 2021).

Ressalta-se que a HTP é uma ferramenta crucial na agricultura moderna, consiste na coleta automatizada de grande volume de dados e avaliação de saúde de plantas em larga escala, utilizando imagens avançadas, através de sensores e ferramentas computacionais para avaliar as respostas das plantas sob diversas condições ambientais (Angidi et al., 2025).

As diversas plataformas de HTP foram desenvolvidas, incluindo sistemas móveis terrestres, aéreos e satelitais, com destaque de uso de sensores proximais e de alta resolução, proporcionam obtenção das informações de características complexas, contribuindo para análise morfológica, fisiológica e de qualidade pós-colheita de plantas (Jiang 2020).

As tecnologias associadas ao melhoramento genético de plantas são importantes para aumentar a produtividade, qualidade comercial de hortaliças, reduzindo as perdas no campo, superando a subjetividade analítica e classificatória e os altos custos de avaliação convencional. Neste contexto, a análise de imagens baseada na inteligência computacional em aprendizado profundo surge como uma tecnologia para solução inovadora e precisa para fenotipagem de genótipos de interesse agrônômico (Fernandes et al., 2023).

2.4 Sensoriamento Remoto e Agricultura Digital

Sensoriamento remoto (SR) complementa as técnicas de HTP, como mecanismo poderoso utilizado para identificar e quantificar as diferenças nas características espectrais das superfícies de plantas submetidas a estresses bióticos, como as pragas, e abiótico como a seca, salinidade e poluição (Moriya et al., 2023).

SR contribui para uma gestão mais satisfatória dos ecossistemas naturais e agrícolas, consolidando-se como uma ferramenta indispensável para o avanço da agricultura moderna. Neste sentido, integra conjunto de técnicas e metodologias da agricultura de precisão e digital, biotecnologia, auxiliando na tomada de decisões e na otimização do manejo de cultivos (Souza et al., 2022; Rodrigues e Domingues, 2017).

SR é uma ferramenta que permite realizar a coleta de informações da superfície terrestre sem contato físico e aquisição das informações espaciais e múltiplas escalas capturando sinais de radiação eletromagnética refletidos ou emitidos (Wang, 2024; Barros et al., 2021).

No contexto de SR, existem tipos de sensores que são utilizados para captura das imagens e avaliação fenotípica de cultivares, destacando-se sensores RGB, multiespectrais, hiperespectrais e LiDAR (*Light Detection and Ranging*). Esses sensores podem ser utilizados para capturas das imagens em plataformas terrestres, orbitais e em aeronaves remotamente pilotadas (RPAs), ampliando as possibilidades de monitoramento e aplicações em navegação autônoma de máquinas agrícolas (Holler et al., 2022; Abebe et al., 2023; Rosalen et al., 2017; Ma, 2023).

A utilidade dos sensores varia conforme a sua natureza e finalidade. Neste cenário, pode-se classificar os sensores como: passivos (ópticos) que são sensores que permitem capturar a radiação refletida pelos diferentes alvos; incluem câmeras RGB, termais, multiespectrais e hiperespectrais. Os sensores ativos são aqueles que emitem a sua própria fonte de energia, por exemplo, os sensores LiDAR (*Light Detection and Ranging*) e RADAR (*Radio Detection and Ranging*). Dada a baixa capacidade de carga das RPA, deve-se levar em consideração o peso dos sensores. (Cavalcante et al., 2021).

Os sensores multiespectrais consolidam-se como ferramentas essenciais para gestão agrícola, devido a sua capacidade de monitoramento de dados em tempo real, flexibilidade e excelente custo-benefício. Auxiliam na fenotipagem de alto rendimento de plantas na análise de índice de vegetação, na reflectância multitemporal para

estimar a temperatura do dossel, também auxilia no mapeamento de padrões de reflectância espectral como azul, verde, vermelho, *red-edge* e infravermelho próximo (Zhang et al., 2025).

As tecnologias de sensoriamento remoto multiespectral por meio de aeronaves remotamente pilotadas (RPA) é fundamental para a agricultura, principalmente na genética e melhoramento de plantas e na agricultura de precisão.

LiDAR destaca-se como a tecnologia mais consolidada do sensoriamento remoto sensor ativo, utilizada para aquisição direta de dados tridimensionais (3D). Sua integração com imagens ópticas para combinação com imagens ópticas e avanços recentes dos sistemas LiDAR multiespectrais têm otimizado significativamente sua capacidade de análise e a precisão dos dados gerados. Essas tecnologias permitem capturar informações espectrais, intensidade de retorno e atributos estruturais dos alvos, favorecendo aplicações em mapeamento, monitoramento ambiental e agricultura de precisão (Takhkeshha et al., 2024).

LiDAR tem sido amplamente empregada na agricultura de precisão e digital, no melhoramento de plantas e entre outras áreas agrícola para fornecimento das informações detalhada sobre as características de cultura de interesse agrônômico, solo e as condições do campo, além disso, também auxilia na tomada de decisões mais eficientes e sustentáveis (Farhan et al., 2024).

Os sensores RGB (*Red, Green, Blue*) são as principais tecnologias utilizadas na fenotipagem de alto rendimento de plantas, devido ao seu baixo custo, simplicidade operacional e elevada capacidade de aquisição de imagens. Sensoriamento proximal baseado em câmeras RGB tem sido amplamente utilizado na fenotipagem de plantas para aquisição de imagens de alta resolução em distâncias curtas (Kior et al., 2024).

A utilização dos sensores RGB embarcados com aeronave remotamente pilotada (RPA) na coleta dos dados, podem fornecer as informações complementares sobre a cobertura vegetal e sua proporção, teor de clorofila, altura de plantas e produtividade, servindo como indicadores da saúde e da vitalidade geral das plantas (Mohammadi, et al., 2024; Sweet et al., 2022).

Ressaltando-se que, os sensores RGB permitem realizar a análise rápida e não destrutiva de características fisiológicas e fenotipagem morfológicas dos vegetais, consequentemente avaliação de crescimento, biomassa, cobertura vegetal, vigor e

respostas a estresse ambientais e à coloração de diferentes genótipos (Kim e Chu, 2021). Por exemplo, na caracterização dos níveis de estresse hídrico de batata-doce baseado em sensor RGB (Hikvision) e algoritmos de aprendizado profundo, proporcionaram 99% de acurácia global (Cho et al., 2025).

Os sensores RGB integram na tecnologia de processamento de imagens digitais e inteligência artificial, além disso, tem sido amplamente aplicado na agricultura moderna, principalmente nos programas de melhoramento genético de plantas (Alves et al., 2024). Os autores utilizaram sensor RGB de modelo DJI Phantom 4 Pro para análise de índice de vegetação de soja, evidenciando o desempenho de correlação entre índices RGB e características agrônômicas em programas de melhoramento genético.

Bhadra et al. (2024), aplicaram sensor RGB (Sistema UAV-RGB) de baixo custo na cultura da soja, evidenciaram que os gerados são suficientes para alimentar as redes neurais convolucionais 3D, permitindo avaliar a produtividade de forma eficiente e não destrutiva.

Uso sensor RGB-D (câmera RGB-D) de baixo custo é amplamente utilizado em diferentes cultivares, permitindo avaliar altura, arquiteturas e os fenótipos tridimensionais no campo agrícola (Song et al., 2023). Essa tecnologia também desempenha papel fundamental no controle de plantas daninhas por meio de segmentação semântica de múltiplas classes de espécies vegetais (Kitzler et al., 2023).

Neste contexto, a tecnologia de captura de imagens é fundamental na fenotipagem de alto rendimento de plantas, uma vez que os atributos fenotípicos extraídos são influenciados por esses sensores.

As contribuições da agricultura surgem como a transformação digital, novas tecnologias disruptivas foram usadas e provocaram a origem da agricultura digital e levando mais uma revolução tecnológica que permite proporcionar as simulações computacionais necessárias para os agricultores e pesquisadores (Massruhá et al., 2020).

A agricultura digital (AD) baseia-se no conteúdo digital, com a finalidade de monitoramento, análise e processamento de dados proveniente de diversas áreas que impulsionam o desenvolvimento agrícola, como a biotecnologia, as mudanças

climáticas, as geotecnologias, as ciências agrárias, além dos dados do mercado (Leite et al., 2024; Abiri et al., 2023).

AD é um fenômeno da produção agrícola que agrupa inteligência dos dispositivos, abrangendo robótica, sensoriamento remoto, geoprocessamento, processos de tomada de decisão e análises de dados e possibilitando alcançar novos patamares de produtividade no setor agrícola (Basso et al., 2019).

As tecnologias digitais têm se destacando com diversas possibilidades de aplicações na agricultura, seus impactos estão relacionados diretamente no desenvolvimento do setor agrícola. Agricultura possibilita maior conectividade de capturar dados precisos gerar informações para agricultores e pesquisadores, neste contexto, novas tecnologias computacionais como aplicação de inteligência artificial (IA), internet das coisas (IoT), Big Data, robótica, computação em nuvem e aprendizado de máquina têm sido utilizados para ampliar e tornando cada vez mais competitiva (Assis et al., 2024).

2.5 Inteligência Artificial e Redes Neurais Convolucionais

A inteligência artificial (IA) tem promovido avanços significativos em diferentes áreas de conhecimento, fornecendo a resolução dos problemas complexos mediante as técnicas computacionais sofisticadas e algoritmos. Entre eles, destacam-se as redes neurais artificiais, cuja sua capacidade de aprendizado e aprimoramento é inspirada em algoritmos matemáticos que se fundamentam nos processos de organização e funcionamento do cérebro humano equivalente a um computacional de neurônios (Castillo-Girones et al., 2025).

Aprendizado de máquina (ML) e aprendizado profundo (DL) são dois setores relevantes na inteligência artificial. São ferramentas que permitem a computadores “aprenderem” a treinar sob volume de dados por imagens e expressarem seu conhecimento ao longo do tempo, utilizando os algoritmos e os algoritmos para encontrar padrões nos dados e aprender com eles fazer as suas próprias previsões e classificações (Moshawrab et al., 2023).

ML consiste na automatização e construção de algoritmos analíticos, permitindo às máquinas aprenderem e melhorarem a partir de experiências, sem necessidade de programação explícita. ML consiste na utilização de redes neurais

para resolver problemas complexos, com algoritmos inspirados na estrutura e função do cérebro humano, capaz de lidar com os dados não estruturados ou não rotulados (Sharfifani e Mahyar, 2023). Neste sentido, a viabilidade do uso de inteligência, principalmente redes neurais convolucionais e aprendizados de máquinas são fundamentais para o alto desempenho que oferecem e pela possibilidade de implementação de diferentes algoritmos.

ML é subconjunto da inteligência artificial (IA) que engloba a construção de algoritmos computacionais que são qualificados para aprender e prever ou decisões na base de dados fornecido. Esses algoritmos apresentam desempenho continuamente a acurácia, fundamentado de forma sistemática e capacidade preditiva por meio da aprendizagem derivada dos dados (Kufel et al., 2023).

Dentre os tipos de aprendizagem de aprendizado de máquina (machine learning) as mais conhecidas como paradigmas de aprendizado de máquina são aprendizagem supervisionada, aprendizado não supervisionado e semissupervisionado e por reforço.

Aprendizado supervisionado é o principal método do aprendizado de máquina que utiliza a entrada de um conjunto de dados e saída de rotulados por humanos para treinar algoritmos de inteligência artificial. Neste método, cada exemplo é acompanhado de um rótulo de classe, permitindo ao algoritmo construir um modelo capaz de classificar novos exemplos (classificação para rótulos discretos e regressão para valores contínuos), sendo o método mais utilizado de aprendizado de máquina (Ludermir, 2021).

Aprendizado não supervisionado é um método de aprendizado da máquina em que o sistema, sistema de inteligência artificial recebe os dados de entrada e não apresenta rótulos de saída, nesta abordagem, o algoritmo identifica os padrões e similaridades, além disso, organiza os dados por transformação ou agrupamento. O aprendizado de máquina não supervisionado difere do aprendizado supervisionado, não necessita da presença de uma pessoa para supervisionar o modelo (Naeem et al., 2023).

Aprendizado semissupervisionado é o método de aprendizagem de máquina que consiste em unir duas atividades em que o algoritmo aperfeiçoa o seu desempenho, utilizando as informações relativamente associadas entre elas. Em

contextos de um problema de classificação, a utilização de instâncias não rotuladas pode contribuir para auxílio de generalização de algoritmos de aprendizado ao fornecer dados adicionais (Van Engelen e Hoos, 2020).

O método de aprendizado de máquina que influencia na simulação é o aprendizado por reforço. Ele consiste no treinamento de algoritmos de aprendizado de máquina para tomada de séries de decisões. Neste contexto, pode ser usado sem modelo de autoaprendizado como lidar com uma situação com base em parâmetros predefinidos e configurações de ambiente. Além disso, essas propriedades também permitem que o aprendizado por reforço se adapte a situações invisíveis enquanto tenta atingir a meta inicialmente definida. O propósito deste método é maximizar o sinal de recompensa além de fazê-lo chegar a um curso de ação ótimo (Goldenits et al., 2024).

O aprendizado profundo (DL) é subconjunto do aprendizado de máquina, baseado em redes neurais artificiais (RNAs). Diferentemente com os métodos tradicionais, ele utiliza as redes neurais profundas para analisar grandes volumes de dados composto por múltiplas camadas, com capacidade de aprender as representações hierárquicas de dados por meio de vários convolucionais, permitindo maior capacidade de aprendizado, desempenho e precisão em padrões complexos (Pandolfi et al., 2024).

O DL consiste também em combinações de vários componentes, como camadas convolucionais de pooling densa, camadas totalmente conectadas, células de memória, portas lógicas, funções de ativações, mecanismos de atenção, esquema de codificação e decodificação), com redes neurais convolucionais, redes neurais recorrentes, autoencoders, redes pré-treinadas não supervisionadas e transformers (Kamilaris e Prenafeta-boldú, 2018).

Aprendizado de máquina e aprendizado profundo são utilizados na agricultura moderna para potencializar e melhorar a robustez da fenotipagem de alto rendimento, baseado em imagens e englobar as características fenotípicas mais complexas e abstratas de genótipos (Ubbens e Staveness 2017).

As redes neurais demonstram particular eficaz previsão de eventos quando dispõem um grande conjunto de banco de dados históricos para treinamento, uma vez que a sua arquitetura permite diferenciar os padrões complexas e realizar as

inferências de forma analógica que se assimila em computadores digitais (Islam et al., 2019).

Redes neurais transformam profundamente o desempenho da visão computacional nas diversas áreas da inteligência de máquinas, permitindo uma revolução em atividades de reconhecimento visual mais complexas com altos níveis de precisão (Suave, 2024; Santos et al., 2020). Contudo, em busca de otimizar a precisão e a demanda, as redes neurais recentes exigem altos recursos computacionais e em dispositivos móveis (mobilidade) e sensores embarcados.

Os sucessos mais significativos residem na classificação das imagens, uma tarefa imprescindível para diversas aplicações, desde imagens médicas à direção autônoma até vigilância de segurança (Martins et al., 2025).

As redes neurais convolucionais (CNNs) integram na visão computacional bem-sucedida, projetadas para detectar e aprender padrões a partir de imagens, dado a sua arquitetura, permite extrair as características de uma imagem a partir de operações convolucionais e *pooling* (Guimarães et al., 2025). Os avanços das redes integraram algoritmos e as arquiteturas de (CNNs) como MobileNetV2, DenseNet121 e ResNet50 na classificação e análise de saúde de plantas a partir sensores com obtenção das imagens hiperespectrais, multiespectrais e RGB.

MobileNetV2 é uma arquitetura de redes neurais convolucionais leve e eficiente, desenvolvida pelo Google e lançada em 2018 baseada diretamente no MobileNetV1. Ele consiste em uma estrutura residual invertida, onde a entrada e a saída do bloco residual são camadas estreitas de gargalo que são diferentes algoritmos residuais tradicionais que utilizam representações expandidas na entrada. Além disso, ele usa convoluções *depthwise* leves para filtrar características na camada de expansão intermediária (Sandler et al., 2018).

O MobileNetV2 surgiu como uma alternativa para solução leve de arquitetura de convolucionais projetada para dispositivos móveis de internet das coisas (IOT), onde a capacidade de processamento é limitada em comparação com as demandas de um aplicativo em tempo real (Gondhalekar et al., 2024).

DenseNet121 (*Connected Convolutional Network*) é uma arquitetura da CNN profunda intensamente focada em visão computacional desenvolvido por Huang et al. (2017), designado pelo seu desempenho em reutilizar características (*features*) ao

longo de 121 camadas organizadas em um tronco inicial, quatro blocos densos intercalados com camadas de transição e uma camada de classificação final.

ResNet50 (rede residual) é uma arquitetura de rede neural convolucional constituída por 50 camadas, projetada para solucionar problema de desvanecimento de gradientes em redes profundas durante o treinamento através de uso de conexões residuais, proposta por He et al. (2015). ResNet50 é amplamente utilizada em diversas tarefas da visão computacional, incluindo a classificação de imagens, detecção de objetos e segmentação semântica demonstrando alto desempenho na sua aplicação (Shafiq e Gu, 2022).

3 MATERIAL E MÉTODOS

3.1 Obtenção dos Genótipos e Localização Experimental

Os genótipos avaliados neste estudo foram provenientes do programa de melhoramento genético de batata-doce da Universidade Estadual Paulista – UNESP.

O experimento foi instalado no período de abril a setembro de 2025, no Setor de Olericultura e Plantas Aromático-Medicinais da Faculdade de Ciências Agrárias e Veterinárias da Universidade Estadual Paulista (UNESP), Câmpus de Jaboticabal, localizada a uma altitude de 614 m nas coordenadas 21°14'05" S e 48°17'09" W (Figura 1). O clima encontrado na região é do tipo AW, quente e úmidos no verão e secos no inverno (Alvares et al., 2013). O solo classificado na área experimental foi do tipo Latossolo Vermelho-Escuro Eutrófico, com textura argilosa e relevo suave ondulado, características típicas da região (Andrioli e Centurion, 1999; Santos et al., 2018).




Figura 1. Localização Experimental, Faculdade de Ciências Agrárias e Veterinárias – UNESP, 2026.

3.2 Condução Experimental

O experimento foi conduzido em delineamento de blocos ao acaso. O plantio foi realizado utilizando as ramas apicais com 10 a 12 nós. As plantas foram dispostas com espaçamento de 0,33 m entre plantas e 0,80 m entre leiras. Foi adotado o sistema de irrigação por aspersão com dias alternados em uma duração de média de 40 minutos por aplicação e intensidade de precipitação de 25 mm h⁻¹, garantindo o atendimento das necessidades hídricas dos genótipos durante a condução do experimento no campo.

Com base na análise química do solo e nas recomendações para a cultura da batata-doce, na adubação plantio foi realizada no sulco, de plantio, com aplicação de 20 kg ha⁻¹ de nitrogênio (N), 80 kg ha⁻¹ de fósforo (P₂O₅) e 60 kg ha⁻¹ de potássico (K₂O), com análise química do solo e nas recomendações de adubação para a cultura da batata-doce. Posteriormente, adubação de cobertura foi realizada aos 30 e 60 dias após o plantio (DAP), utilizando a ureia como fonte de nitrogênio (N) com 30 kg ha⁻¹ mais KCl (Feltran et al., 2022).

As condições meteorológicas ao longo da condução experimental em Jaboticabal apresentaram variações significativas (Figura 2). A pressão atmosférica oscilou entre 943,7 e 949,8 hPa, com os maiores valores de registrados em julho (949,8 hPa). A temperatura máxima variou entre 26,7 °C e 32,8 °C (junho e setembro), enquanto a mínima apresentou valores entre 12,5 °C e 18,8 °C (julho e abril). A

temperatura média reduziu-se de 223,1 °C a 19,1°C (abril a julho), consequentemente a temperatura aumentou para 24,4 °C em setembro.

A umidade relativa do ar demonstrou a tendência da redução ao longo da época da condução do experimento, passando de 77,7% em abril para 49,4% em setembro. Na precipitação, observou-se maior volume da chuva no mês de abril (145,7 mm) e junho (60, 8 mm), enquanto houve menor acúmulo da chuva entre maio e agosto, demonstrando baixa pluviosidade. Esse cenário, demonstrou as condições da transição entre período chuvoso e a estação seca na região com aumento gradual da temperatura e redução da umidade relativa do ar ao longo do período de condução experimental.




Figura 2. Variações meteorológicas ao longo da condução experimental (entre abril e setembro de 2025), incluindo precipitação pluviométrica (mm), temperatura máxima (Tmax), média (Tmed) e mínima (Tmin) (°C) e umidade relativa do ar (UR, %).

Realizou-se a colheita das parcelas experimentais, posteriormente foram selecionadas as seguintes dez genótipos de batata-doce: CERAT 01-11, CERAT 01-222, CERAT 01-236, CERAT 03-10, CERAT 07-04, CERAT 10-04, CERAT 10-10, CERAT 31-11, CERAT 60-05 e Uruguaiana (Figura 3).



Figura 3. Colheita de genótipos de batata-doce no campo experimental (Fonte: Autoria própria, 2025).

3.3 Aquisição das Imagens

Os genótipos colhidos passaram por um processo de lavagem para remoção de impurezas no laboratório do Setor de Olericultura e Plantas Aromático-Medicinais da UNESP.

Foram realizadas capturas de 300 imagens por cada genótipo, resultando em um conjunto total de 3.000 imagens de raízes. Posteriormente, realizou o procedimento de corte transversal dos genótipos com auxílio de uma faca, no Setor de Olericultura e Plantas Aromático-Medicinais, expondo a superfície interna da polpa para captura imediatamente das imagens. O conjunto de polpa capturado contém 100 imagens para cada genótipo batata-doce, totalizando 1000 imagens.




Figura 4. Genótipos avaliados no presente trabalho (Fonte: Autoria própria, 2025).

As imagens das tuberosas e polpas foram coletadas por meio da câmera RGB (50 MP) presente em modelo SM-A16M/DSI (*Smartphone*), acoplado a suporte fixo (tripé) e padronizado no fundo branco, garantindo a uniformidade iluminação artificial do ambiente. A distância entre o sensor RGB e a superfície dos genótipos da parte interna e externa foram de 30 centímetros (Figura 5).




Figura 5. Coleta das imagens RGB de genótipos da batata-doce (Fonte: Autoria própria, 2025).

3.5 Pré-processamento de Dataset

Para avaliar o desempenho das redes neurais convolucionais para a tarefa de classificação de genótipos de batata-doce com base nas suas imagens, foram escolhidos três algoritmos diferentes: MobileNetV2, DenseNet121, RestNet50.

Para pré-processamento das imagens utilizou-se as bibliotecas Python 3.10 (Van Rossum, 2023), *TensorFlow* com API Keras e o GPU por meio de Google Colab, o GPU para acelerar o processamento das imagens (Abadi et al, 2016).

O dataset de dados foi realizado em conjunto de treinamento, validação e teste com as seguintes divisões: 80% para treinamento, 10% para validação e 10% para teste com os três algoritmos de redes neurais convencionais. Consequentemente, definiu-se uma arquitetura de redes neurais convolucionais adequada para a classificação de imagens.

Todas as imagens foram redimensionadas para 224x224 pixels e seus valores

de pixel foram normalizados dividindo-os por 255. Isso garante que os valores de pixel fiquem na faixa de $[0, 1]$, que é um pré-requisito comum para redes neurais e ajuda na estabilidade e na velocidade do treinamento. Para alimentar o modelo com os dados pré-processados em lotes *ImageDataGenerator.flow_from_directory()*, o *TensorFlow* atribuiu o rótulo de classe de cada imagem no nome da subpasta de onde ela foi lida. Isso é uma forma mais comum na rotulagem em tarefas de classificação de imagens quando os dados foram organizados.

A primeira classificação de tuberosas e suas polpas foi realizada utilizando algoritmo MobileNetV2 (uma arquitetura da rede neural convolucional) treinada com os conjuntos de treinamento e validação e avaliada no conjunto de teste, permitindo quantificar a acurácia do modelo na distinção de diferentes dos genótipos selecionados. Durante o treinamento do modelo de rede neural convolucional, foi utilizada uma técnica de *Early Stopping* para prevenir o sobreajuste e melhorar a capacidade de generalização do modelo.

Neste modelo, foi utilizado número parâmetros total de 2,423,242 (9.24 MB), número de parâmetros treináveis de 165,258 (645.54 KB) e número de parâmetros não treináveis de 2,257,984 (8.61 MB).

O modelo base foi carregado com os pesos pré-treinados na base de dados *ImageNet*, adotando a técnica de aprendizado por transferência. A entrada da rede foi configurada para imagens com dimensão de 224x224 pixels e três canais de cor (RGB). Foi utilizado a opção de exclusão da camada superior original (*include_top=false*) para remover a camada de classificação padrão de *ImageNet*, deixando apenas o extrator de características convolucional.

Os pesos do modelo base foram congelados (*trainable = False*) de forma que não fossem atualizados durante o treinamento. Esta estratégia permite aproveitar o conhecimento previamente aprendido pela rede e reduzir o risco de sobreajuste, principalmente quando trabalha com conjunto de dados de tamanho limitado.

Depois da base convolucional, foram adicionadas camadas totalmente conectadas para adaptação ao problema específico. No princípio, foi utilizado uma camada *Global Average Pooling* (GAP), responsável por diminuir os mapas de características em um vetor unidimensional. Foi adicionada uma camada densa com 128 neurônios e função de ativação de Unidade Linear Retificada (ReLU), permitindo

a aprendizagem de representações mais baratas. Para minimizar o sobreajuste, foi incorporada uma camada de *Dropout* com taxa de 0,3. Foi adicionada uma camada de saída com 10 neurônios e função de ativação *softmax*, correspondente às 10 classes do problema. A configuração proporcionou a construção de um desempenho de um modelo eficiente, com número reduzido de parâmetros treinados, garantindo melhor capacidade de generalização e estabilidade no processo de classificação.

O critério de monitoramento adotado foi a perda no conjunto de validação (*validation loss*), definida pelo parâmetro *monitor (val_loss)*. No treinamento de polpa, foi configurado o MobileNetV2 para ocorrer por até 50 épocas, na qual a rede apresentou o desempenho durante 35 épocas para conjunto de polpa e 50 épocas para raízes tuberosas. Portanto, a técnica de parada antecipada foi programada para interromper o treinamento caso não houvesse a melhoria na perda de validação por cinco épocas consecutivas (*patience = 5*). Foi também ativada a opção de *restore best weights = True*, assegurando que ao final do processo, o modelo recuperasse automaticamente os pesos correspondentes à maioria época no conjunto observada de avaliação, em vez de manter os pesos da última época de treinada.

Durante o período de treinamento do MobileNetV2, foram monitoradas as métricas de acurácia e a função de perda de cada época. Posteriormente, as curvas de acurácia de treinamento e validação foram plotadas para análise do comportamento de convergência do modelo.

Utilizou-se a biblioteca *split-folders* para DenseNet121, garantindo a reprodutibilidade com *seed = 42*. Com a base convolucional, foi utilizada uma camada de *Global Average Pooling*, para diminuir os mapas de ativação em um vetor unidimensional. E foi adicionada uma camada totalmente conectada com 256 neurônios e função de ativação ReLU, permitindo a aprendizagem de representações mais abstratas. Foi incorporada à camada de saída que é composta por número de neurônios igual ao total de classes do problema, utilizando a função de ativação *softmax* para a classificação multiclasse.

O modelo foi otimizado com o algoritmo Adam e função de perda *crossentropy*, utilizando *early stopping* para controle de sobreajuste. Os pesos da rede foram congelados (*Trainable = False*). Esta estratégia reduz o risco de sobreajuste e melhora a estabilidade do treinamento, principalmente em conjunto de dados com

número limitado de imagens. O treinamento de conjunto de imagens de polpa foi realizado durante 40 épocas e 50 épocas no treinamento de tuberosas, utilizando geradores de dados para conjunto de treinamento e validação do modelo e reprodutividade dos resultados de acurácia, precisão F1-score e recall.

O conjunto de imagens dos genótipos foi elaborado em repositórios projetados por classes, seguindo o padrão exigido pelo método *flow_from_directory*. As imagens de RestNet50 foram salvas no formato *hold-out*, propõe-se assegurar a independência entre conjuntos de imagens e permitir avaliação imparcialmente no desempenho do modelo. Foi utilizado o pré-processamento de conjunto de imagens por meio de função *preprocess_input* específica da arquitetura RestNet50, o que permite a conversão do espaço de cor em RGB para BGR centralizada dos valores de base na média do *ImageNet* padronização estatística de acordo com o treinamento original do modelo. Foi realizada a aplicação uniforme do mesmo gerador para treinamento, validação e teste que assegura a consistência estatística e reduz possíveis vieses experimentais neste algoritmo.

Arquitetura ResNet50 foi pré-treinada no conjunto de *ImageNet* com principal contribuição na introdução de conexões residuais (*skip connections*), demonstrando o treinamento de redes profundas sem degradação do gradiente.

Para a configuração a configuração de modelo foi utilizado *include_top = False*, removendo a camada classificatória original (1000 classes), congelamento dos pesos da base convolucional (*Treunable = False*), caracterizando a base a estratégia de *transfer learning* por extração de características. As camadas adicionais sobre a base convolucional foram as camadas *GlobalAveragePooling2D*, para redução dimensional, *batchNormalization*, demonstrando a estabilidade de ativações, camadas densas com 256 neurônios e função de ativação ReLU, a *dropout* com taxa de 0,5 para regularização, camada de saída com 10 neurônios e ativação *Softmax*, correspondente ao número de classes.

O modelo foi compilado com o algoritmo otimizador Adam com taxa de aprendizado de 0,0001 e a função de perda *categorical_crossentropy*, adequada para classificação de multiclasse com codificação *one-hot*. O treinamento de dados de polpa foi conduzido por 40 épocas e 33 épocas para as raízes tuberosas, utilizando o conjunto de validação para monitoramento do desempenho e verificação de possíveis

sinais de sobreajuste. Foi avaliada análise acurácia, precisão, recall e F1 score para o desempenho do modelo.

As métricas acurácias, precisão, F1-score, recall e matriz de confusão para 10 classes foram usadas para avaliar as eficiências dos algoritmos de redes neurais para o reconhecimento e classificação polpa dos genótipos de batata-doce.

Os cálculos das taxas de precisão, recall e F1-score e acurácia foram realizados pelas seguintes equações, conforme Sujon et al. (2025).

Precisão: Uma métrica que mede a proporção de amostras classificadas corretamente em relação ao número total de amostras, Eq. (1).

$$\text{Precisão} = \frac{TP}{TP+FP} \quad (1)$$

O recall é que avalia a capacidade do modelo de identificar corretamente todas as instantâneas positivas presentes no conjunto de testes. Sua equação é calculada pela razão entre verdadeiros positivos e soma dos verdadeiros positivos com falsos negativos, Eq. (2).

$$\text{Recall} = \frac{TP}{TP+FN} \quad (2)$$

F1 - score: é uma métrica que fornece uma avaliação equilibrada do desempenho de um modelo, combinando precisão e recall, Eq. (3).

$$\text{F1-score} = 2 * \frac{\text{precisão} * \text{recall}}{\text{precisão} + \text{recall}} \quad (3)$$

Acurácia é uma métrica que mede a proporção de amostras que foram corretamente previstas como positivas pelo modelo, em relação a todas as amostras que foram realmente positivas, Eq. (4).

$$\text{Acurácia} = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

TP representa os verdadeiros positivos no número de quadros-alvo corretamente previstos como pertencentes à classe positiva.

FP representa os falsos positivos no número de quadros-alvo incorretamente previstos como pertencentes à classe positiva.

FN representa os falsos negativos no número de quadros-alvo que realmente pertencem à classe positiva, mas são incorretamente previstos como pertencentes à classe negativa.

4 RESULTADOS

4.1 Desempenho de Treinamento e Curva de Aprendizado de Redes Neurais Convolucionais em Imagens das Raízes de Batata-doce.

O conjunto de treinamento e validação de raízes tuberosas de batata-doce submetido ao algoritmo MobileNetV2, proporcionou um aumento rapidamente nas primeiras épocas, o modelo conseguiu aprender os padrões mais relevantes dos dados de raízes de batata-doce logo no início do treinamento, depois de 10 épocas as curvas passaram a crescer de forma mais lenta.

A taxa de acurácia na validação no conjunto de treinamento e validação estabilizou por volta de 50 épocas, demonstrando o desempenho dos extratores de características na classificação das imagens das raízes de batata-doce (Figura 6). O modelo mostrou altos níveis de acurácia e baixos valores da perda no conjunto de treinamento e validação, indicando um aprendizado generalizado e sem ocorrência de sobreajuste.




Figura 6. Precisões de treinamentos e validações; perdas e validações de MobileNetV2 no conjunto das imagens das raízes de batata-doce.

DenseNet121 apresentou um desempenho satisfatório de acurácia no conjunto de treinamento de imagens de genótipos de batata-doce. Iniciou o treinamento com valores muito baixos, logo após de 10 épocas demonstrou um crescimento rápido, indicando um aprendizado progressivo no conjunto de treinamento e validação, o modelo estabilizou com 50 épocas com valores altos (Figura 7).

Houve uma queda acentuada nas primeiras épocas do treinamento e validação, este modelo sugere boa capacidade de generalização e ausência de sobreajuste significativo com 50 épocas de treinamento.




Figura 7. Precisões de treinamentos e validações; perdas e validações de DenseNet121 no conjunto das imagens de raízes de batata-doce.

O conjunto de treinamento e validação de ResNet50 apresentou um crescimento rápido nas primeiras épocas, com avanço do treinamento o crescimento tornou-se mais gradual até atingir os valores altos, aproximadamente 100% em 33 épocas (Figura 8).

Na evolução da perda (*loss*), observou-se que o ResNet50 demonstrou uma redução acentuada nas primeiras épocas, seguida de uma diminuição mais lenta e estável ao longo do treinamento. Portanto, os resultados indicam que o ResNet50 apresentou alta eficiência no treinamento das imagens das raízes, com altos valores de acurácia e baixos valores de perda. Além disso, a proximidade entre as curvas de treinamento e validação sugere boa capacidade de generalização, sem evidências significativas de sobreajuste, (Figura 8).




Figura 8. Precisões de treinamentos e validações; perdas e validações de ResNet50 no conjunto das imagens das raízes de batata-doce.

4.2 Desempenho de Treinamento e Curva de Aprendizado das Redes Neurais Convolucionais em Imagens de Polpa.

A acurácia do treinamento do MobileNetV2 começou relativamente baixa e a validação iniciou com um desempenho satisfatório (Figura 9). Ao longo das épocas, a acurácia demonstrou um crescimento progressivo atingindo os valores superiores proximidade entre curvas com boa capacidade de generalização da arquitetura, sem interferência significativa de sobreajuste.

O comportamento convergente demonstra que o desempenho da arquitetura do algoritmo MobileNetV2 foi adequada para a tarefa da identificação de progênies de batata-doce a partir de imagens de polpa. A função de perda apresentou redução significativa logo nas primeiras épocas, indicando rápida aprendizagem dos padrões de polpa. Observou-se comportamento convergente e estável ao longo do treinamento, com valores finais baixos tanto para o conjunto de treinamento quanto para validação. A proximidade entre as curvas sugere boa capacidade de generalização e ausência de sobreajuste significativo com 35 épocas de treinamento (Figura 9).




Figura 9. Precisões de treinamentos e validações; perdas e validações do MobileNetV2 no conjunto das imagens de polpa de batata-doce.

O DenseNet121 apresentou um crescimento da acurácia nas primeiras épocas, demonstrando os padrões discriminativos logo no início do treinamento. A acurácia do treinamento começou com baixa eficiência e ao final do treinamento (40 épocas de treino) atingiu alta eficiência no conjunto de polpa (Figura 10).

Houve ausência de sobreajuste significativo e estabilidade no aprendizado do DenseNet121, isso demonstrou o desempenho da capacidade de generalização. Observou-se que durante o treinamento de imagens de polpa, há queda acentuada nas primeiras épocas, tanto no treinamento quanto na validação, demonstrando rápida convergência do modelo treinado (Figura 10).




Figura 10. Precisões de treinamentos e validações; perdas e validações do DenseNet121 no conjunto das imagens de polpa de batata-doce.

O ResNet50 apresentou alta eficiência na tarefa de classificação de conjunto de imagens de polpa, demonstrando uma rápida convergência da acurácia pela redução da função da perda durante épocas de treinamento.

Houve um crescimento acentuado da precisão nas primeiras interações, indicando a capacidade que a rede foi capaz de extrair de forma eficiente as características discriminativas importantes para a separação de classes (Figura 11). Portanto, esse comportamento foi o esperado em arquiteturas baseadas em aprendizado principalmente quando se inicializadas com pesos pré-treinados em bases amplas de imagens.




Figura 11. Precisões de treinamentos e validações; perdas e validações de ResNet50 no conjunto das imagens de polpa de batata-doce.

4.3 Desempenho de Métricas Entre os Algoritmos na Classificação das Raízes de Batata-doce

O MobileNetV2 demonstrou excelente desempenho de acurácia global, com 96% no conjunto de treinamento e validação de imagens das raízes de batata-doce. O genótipo de classe CERAT 01-222 e Uruguaiana apresentaram alta eficiência em todas as métricas, com 100% de desempenho no modelo MobileNetV2.

O MobileNetV2 destacou-se por apresentar alto desempenho entre métricas em algumas classes dos genótipos. Os genótipos CERAT 01-11, CERAT 31-11, apresentaram 100% de eficiência de precisão, enquanto os genótipos CERAT 60-05,

CERAT 07-04 apresentaram 100% de recall. Os demais genótipos analisados apresentaram excelente desempenho, com acima de 93% em todas as métricas (Tabela 2).

Os resultados de macro-média e média ponderada proporcionaram excelente equilíbrio entre a precisão e sensibilidade com 96%, resultando em uma taxa de erro global de apenas 4% para MobileNetV2 na identificação das raízes de batata-doce.

Tabela 2. Resumo de análise de métricas de precisão, recall, F1-score e acurácia das imagens das raízes no modelo MobileNetV2.

Genótipo (Classe)	Precisão	Recall	F1-score
CERAT 01-11	1,00	0,90	0,95
CERAT 01-222	1,00	1,00	1,00
CERAT 01-236	0,97	0,93	0,95
CERAT 03-10	0,93	0,93	0,93
CERAT 07-04	0,91	1,00	0,95
CERAT 10-04	0,93	0,93	0,93
CERAT 10-10	0,97	0,97	0,97
CERAT 31-11	1,00	0,97	0,98
CERAT 60-05	0,94	1,00	0,97
URUGUIANA	1,00	1,00	1,00
Acurácia	0,96		
Macro-média	0,96	0,96	0,96
Média ponderada	0,96	0,96	0,96

O DenseNet121 demonstrou o desempenho muito bom, com alta acurácia global (96%) na classificação de das raízes dos genótipos de batata-doce (Tabela 3).

Apenas a classe do genótipo Uruguaiana que apresentou 100% do desempenho em todas as métricas. O desempenho deste modelo foi observado na precisão, com 100% da eficiência nos genótipos CERAT 03-10, CERAT 07-04 e CERAT 31-11; e 100% no recall, com os genótipos CERAT 10-10, CERAT 01-236.

Os demais genótipos avaliados apresentaram excelentes desempenho, variando entre 90% e 98% na precisão, recall e F1-score. Nesta ocasião, o modelo demonstrou um desempenho geral muito bom, com alta acurácia e F1-score.

Observou-se que no DenseNet121, os resultados de macro-média e média ponderada apresentaram um equilíbrio entre a precisão e sensibilidade com 96%, evidenciando uma taxa de erro global (4%) no conjunto de dados avaliados.

Tabela 3. Resumo de análise de métricas de precisão, recall, F1-score e acurácia das imagens das raízes no modelo DenseNet121.

Genótipo (Classe)	Precisão	Recall	F1-score
CERAT 01-11	0,93	0,90	0,92
CERAT 01-222	0,94	0,97	0,95
CERAT 01-236	0,85	0,97	0,91
CERAT 03-10	1,00	0,90	0,95
CERAT 07-04	1,00	0,97	0,98
CERAT 10-04	0,97	0,93	0,95
CERAT 10-10	0,97	1,00	0,98
CERAT 31-11	1,00	0,97	0,98
CERAT 60-05	0,97	1,00	0,98
URUGUIANA	1,00	1,00	1,00
Acurácia	0,96		
Macro-média	0,96	0,96	0,96
Média ponderada	0,96	0,96	0,96

ResNet50 demonstrou excelente desempenho na classificação das raízes de batata-doce, apresentando acurácia global de 98% no conjunto de treinamento e validação (Tabela 4).

Os resultados de ResNet50 evidenciaram altos valores de precisão e F1-score com 100% do desempenho das raízes para os genótipos CERAT 01-222, CERAT 31,11 e Uruguiana, indicando alta capacidade do modelo de classificar corretamente esses materiais genéticos em suas respectivas classes.

Os resultados de recall foram eficazes para todas as classes das raízes avaliadas, variando de 93% a 100%, evidenciando a capacidade de ResNet50 em reconhecer corretamente as imagens das raízes pertencentes à sua classe (Tabela 4). Ressaltando que o macro-média e média ponderada evidenciaram equilíbrio entre a precisão e sensibilidade nas imagens dos genótipos avaliados com 98%, indicando uma taxa de erro global de 2% neste modelo.

Tabela 4. Resumo de análise de métricas de precisão, recall, F1-score e acurácia das imagens das raízes no modelo ResNet50.

Genótipo (Classe)	Precisão	Recall	F1-score
CERAT 01-11	0,94	0,97	0,95
CERAT 01-222	1,00	1,00	1,00
CERAT 01-236	1,00	0,97	0,98
CERAT 03-10	0,97	0,97	0,97
CERAT 07-04	1,00	0,97	0,98
CERAT 10-04	0,94	0,97	0,95
CERAT 10-10	0,94	1,00	0,97
CERAT 31-11	1,00	1,00	1,00
CERAT 60-05	1,00	0,93	0,97
URUGUIANA	1,00	1,00	1,00
Acurácia	0,98		
Macro-média	0,98	0,98	0,98
Média ponderada	0,98	0,98	0,98

4.4 Desempenho de Métricas Entre os Algoritmos na Classificação dos Genótipos de Batata-doce a Partir da Polpa

O MobileNetV2 treinado apresentou um excelente acurácia global de 96%, considerando um total de 100 amostras de polpa avaliadas (10 por classe). Esse resultado indica alto desempenho na tarefa de classificação de polpa de batata-doce em diferentes genótipos.

A classificação do modelo MobileNetV2 revelou a eficiência variada entre diferentes polpas dos genótipos de CERAT 10-10, CERAT 01-11, CERAT 07-04, CERAT 01-236, CERAT 01-222, CERAT 03-10, CERAT 10-04 apresentaram 100% de desempenho da precisão (1,00), indicando que todas as vezes que o modelo previu essas classes, a predição estava correta.

Ressaltando que as demais classes apresentaram uma variação de precisão entre 0.83 a 0.90. De forma geral, observa-se que as classes CERAT 03-10, CERAT 07-04, CERAT 10-04 e CERAT 10-10 apresentaram o desempenho perfeito com a precisão, recall e F1 score. Para a classe CERAT 31-11, a precisão de 0,91 indica que 91% das vezes que o modelo previu CERAT 31-11, a classe real estava correta. O recall desta classe foi excelente (1.00), significando que o modelo conseguiu identificar todas as instâncias reais de CERAT 31-11, F1-score de 0,95 refletiu em um bom equilíbrio geral (Tabela 5).

No entanto, o recall de 0,90 para algumas classes mostrou que o modelo só conseguiu identificar 90% das ocorrências reais dessa classe, perdendo 10% delas.

O F1-score de 0,90 para classe Uruguaiana é um pouco mais baixo devido a essa falha no recall.

Foi observado um equilíbrio estatístico entre o macro-média e a média ponderada, demonstrando o destaque do modelo, não sofreu nenhuma influência de desbalanceamento de classes. O F1-score médio foi de 0,96 indicaram uma excelência harmonia entre precisão e a sensibilidade, a taxa de erro global foi apenas de 4% neste modelo. As pequenas confusões estão associadas à similaridade fenotípica entre classes determinadas, o que é esperado em materiais geneticamente semelhantes.

Tabela 5. Resumo de análise de métricas de precisão, recall, F1-score e acurácia das imagens de polpa no modelo MobileNetV2.

Genótipo (Classe)	Precisão	Recall	F1-score
CERAT 31-11	0,91	1,00	0,95
CERAT 10-04	1,00	1,00	1,00
CERAT 10-10	1,00	1,00	1,00
CERAT 01-11	1,00	0,90	0,95
URUGUAIANA	0,90	0,90	0,90
CERAT 60-05	0,83	1,00	0,91
CERAT 01-236	1,00	0,90	0,95
CERAT 03-10	1,00	1,00	1,00
CERAT 01-222	1,00	0,90	0,95
CERAT 07-04	1,00	1,00	1,00
Acurácia	0,96		
Macro-média	0,96	0,96	0,96
Média ponderada	0,96	0,96	0,96

O DenseNet121 apresentou acurácia global de 98% evidenciando elevada capacidade de generalização. Observou a alta eficiência da arquitetura de DenseNet121 na classificação de precisão, recall e f1-score de polpa de genótipos selecionados com 100% de acerto das seguintes classes: CERAT 01-11, CERAT 01-222, CERAT 01-236, CERAT 10-04, CERAT 10-10, CERAT 60-05 e Uruguaiana. As classes CERAT 03-10, CERAT 07-04, e CERAT 31-11 atingiram o desempenho superior de 90% em todas as métricas observadas (Tabela 6).

A classe CERAT 03-10 teve uma com leve redução de recall (0,90) e F1-score (0,90). Ressaltando que o valor com menor recall menor demonstrou que algumas amostras dessa classe foram classificadas incorretamente como outras classes. A classe CERAT 31-11, apresentou segundo menor precisão relativa (0,91), porém o

modelo conseguiu classificar todas as amostras dessa classe com 100% de recall. Portanto, a arquitetura deste modelo foi capaz de moldar padrões complexos para classificação das imagens com sensor proximal (RGB) selecionados a partir de polpa de batata-doce.

Estatisticamente houve equilíbrio entre macro-média e a média ponderada, demonstrando o destaque do modelo, não sofreu nenhuma influência de desbalanceamento de classes. O F1-score médio foi de 98% indicaram uma excelência harmonia entre precisão e a sensibilidade, a taxa de erro global foi apenas de 2% neste modelo. As pequenas confusões estão associadas à similaridade fenotípica entre classes determinadas, o que é esperado em materiais geneticamente semelhantes (Tabela 6).

Tabela 6. Resumo de análise de métricas de precisão, recall, F1-score e acurácia das imagens de polpa no modelo DenseNet121.

Genótipo (Classe)	Precisão	Recall	F1-score
CERAT 31-11	0,91	1,00	0,95
CERAT 10 -04	1,00	1,00	1,00
CERAT 10-10	1,00	1,00	1,00
CERAT 01-11	1,00	1,00	1,00
URUGUAIANA	1,00	1,00	1,00
CERAT 60-05	1,00	1,00	1,00
CERAT 01-236	1,00	1,00	1,00
CERAT 03-10	0,90	0,90	0,90
CERAT 01-222	1,00	1,00	1,00
CERAT 07-04	1,00	0,90	0,95
Acurácia	0,98		
Macro-média	0,98	0,98	0,98
Média ponderada	0,98	0,98	0,98

A arquitetura do modelo ResNet50 apresentou acurácia global de 97% (Tabela 7). O modelo demonstrou bons resultados, com alta acurácia para classificação de polpas de genótipos de batata-doce.

O ResNet50 apresentou 100% de eficiência em todas as métricas (precisão, recall e F1-score) avaliados para as classes de CERAT 31-11, Uruguaiana, CERAT 60-05, CERAT 01-222, e CERAT 07-04 (Tabela 7). Observou-se que demais classes apresentaram a partir de 90% de todas as métricas. Isso demonstra o alto desempenho do modelo na classificação de batata polpa de batata-doce.

Houve um equilíbrio estatístico entre macro-média e média ponderada,

demonstrando o destaque do modelo com 97%. O F1-score médio foi de 0.97 demonstrando um desempenho entre a precisão e a sensibilidade, a taxa de erro global foi apenas de 3% neste modelo não sofreu nenhuma influência de desbalanceamento de classes.

Tabela 7. Resumo de análise de métricas de precisão, recall, F1-score e acurácia de polpa no modelo ResNet50.

Genótipo (Classe)	Precisão	Recall	F1-score
CERAT 31-11	1,00	1,00	1,00
CERAT 10 -04	0,91	1,00	0,95
CERAT 10-10	0,91	1,00	0,95
CERAT 01-11	1,00	0,90	0,95
URUGUAIANA	1,00	1,00	1,00
CERAT 60-05	1,00	1,00	1,00
CERAT 01-236	1,00	0,90	0,95
CERAT 03-10	0,90	0,90	0,90
CERAT 01-222	1,00	1,00	1,00
CERAT 07-04	1,00	1,00	1,00
Acurácia	0,97		
Macro-média	0,97	0,97	0,97
Média ponderada	0,97	0,97	0,97

4.6 Análise de Matriz de Confusão das raízes de Batata-doce.

A matriz de confusão de MobileNetV2 apresentou um desempenho elevado na classificação das raízes de batata-doce. As raízes dos genótipos de CERAT 01-222, CERAT 07-04, CERAT 60-05 e Uruguaiana obtiveram 100% de acertos.

As três amostras de classe do genótipo CERAT 01-11 foram classificadas como CERAT 03-10, CERAT 10-04 e CERAT 60-05. Duas amostras de classe do genótipo CERAT 01-236 foram classificadas como CERAT 10-10 e CERAT 60-05. Uma das amostras do genótipo CERAT 31-11 foi classificada como CERAT 07-04. Uma amostra de genótipo CERAT 10-10 foi confundida e classificada como CERAT 01-236. Duas amostras de genótipo CERAT 10-04 foram classificadas como genótipo CERAT 03-10 e CERAT 07-04. Duas amostras de CERAT 03-10 foram classificadas como CERA 07-04 e CERAT 10-04. Duas amostras de CERAT 10-04 classificada como CERAT 07-04 e CERAT 03-10. Neste caso, foram observados poucos erros na

matriz de confusão, demonstrando que o MobileNetV2 foi capaz de distinguir adequadamente a maioria de classes das raízes avaliadas (Figura 12).




Figura 12. Matriz de confusão na predição das raízes de batata-doce com MobileNetV2.

A matriz de confusão do DenseNet121 demonstrou excelente desempenho elevado, com 100% na classificação das seguintes raízes de batata-doce: Uruguaiana, CERAT 60-05 e CERAT 07-04 (Figura 13).

Observou as pequenas confusões na classificação do DenseNet121 para classe dos genótipos de CERAT 01-222, CERAT 01-236, CERAT 07-04 e CERAT 31-11, indicando apenas uma foi classificada incorreta em cada uma das classes.

As três amostras das raízes foram classificadas de forma incorretamente, apresentando erro para os genótipos CERAT 01-11 e CERAT 03-10, indicando 90,0% de acerto, enquanto duas amostras foram incorretamente classificadas no genótipo CERAT 10-04, correspondendo a 93,33% de acerto.




Figura 13. Matriz de confusão na predição das raízes de batata-doce com DenseNet121.

Com base na matriz de confusão de ResNet50 para a classificação de raízes de batata-doce, observou-se que o modelo identificou corretamente a maioria das imagens dos genótipos em cada classe (Figura 14). Na classe do genótipo CERAT 01-222, CERAT 101-10, CERAT 31-11 e Uruguaiiana foram 100% classificadas corretamente.

O ResNet50 também apresentou bom desempenho na classificação das raízes de batata-doce nas classes dos genótipos. Embora ainda houve pequenos erros de classificação uma das amostras dos genótipos CERAT 01-11 e 07-04 que foram classificadas como CERAT 10-04, e uma das amostras dos genótipos CERAT 03-10 e CERAT 01-236 foram classificadas como CERAT 01-11. Também foi observado as duas amostras de classe do genótipo 60-05 que foram classificadas como CERAT 10-10.

A matriz de confusão no ResNet50 possui boa capacidade de classificação, com uma taxa de erro relativamente baixa e uma distribuição de erros tolerável entre as classes dos genótipos avaliado.




Figura 14. Matriz de confusão na predição das raízes de batata-doce com ResNet50.

4.5 Análise de Matriz de Confusão Polpa.

De modo geral, as polpas de batata-doce nas classes dos genótipos CERAT 10-10, CERAT 31-11, CERAT 60-05, CERAT 10-06 e CERAT 07-04, foram identificadas de forma correta na matriz de confusão predita pela arquitetura de MobileNetV2 (Figura 15). O modelo demonstrou alta capacidade discriminatória na predição de matriz de confusão, o desempenho da maioria das classes das predições, concentrou na diagonal principal.

Observou-se pequenas incoerências classificatórias entre as classes cromaticamente idênticas. O genótipo CERAT 01-11 apresentou predições corretas na respectiva classe, mas teve uma amostra confundida e atribuída à classe Uruguaiana.

Em contraste, foi observado que a classe real do genótipo CERAT 01-222 exibiu desempenho satisfatória nas classificações na predição correta, exceto uma amostra

que foi confundida e classificada como CERAT 31-11, indicando proximidade no gradiente de transição entre tons intermediários de coloração.

Amostra de classe do genótipo CERAT 01-236 e uma de Uruguaiiana foram confundidas e classificadas como CERAT 60-05. Esses comportamentos sugerem sobreposição parcial no RGB entre as tonalidades, especialmente em termos de matriz de confusão e luminosidade.




Figura 15. Matriz de confusão na predição de polpa de batata-doce com MobileNetV2.

O modelo DenseNet121 apresentou alta eficiência no desempenho da matriz de confusão entre as classes, com 100% de acerto de predição das seguintes classes: CERAT10-10, CERAT 01- 11, CERAT 01-222, CERAT 01-236, CERAT 10-04, CERAT 31-11, CERAT 60-05 e Uruguaiiana (Figura 16).

Houve pequenas confusões observadas entre as classes: Na classe CERAT 03-10 uma amostra confundida e predita na classe CERAT 31-11. Enquanto uma amostra de CERAT 07-04 foi confundida com CERAT 03- 10.

A matriz de confusão no modelo DenseNet121 nas classes com pouco erro na predição demonstrou visualmente poucas semelhanças, indicando similaridade

fenotípica de sobreposição de tonalidade das características intermediárias, o que é esperado geneticamente quando há proximidade de variação intra-classe.




Figura 16. Matriz de confusão na predição de polpa de batata-doce com DenseNet121.

Observou o desempenho da arquitetura de ResNet50 com 100% corretos de matriz de confusão das seguintes classes preditas: CERAT 01-222, CERAT 07-04, CERAT 10-04, CERAT 10-10, CERAT 31-11 e CERAT 60-03 (Figura 17).

Houve pequenas confusões nas demais classes, destacando áreas onde o modelo foi confundido com certas classes. Uma amostra de classe 01-11 classificada como CERAT 10-10, uma amostra CERAT 01-236 confundida e predita como CERAT 03-10 e uma amostra de classe CERAT 03-10, confundida e classificada como CERAT 10-04.




Figura 17. Matriz de confusão na predição de polpa de batata-doce com ResNet50.

5 DISCUSSÃO

Os três algoritmos de redes neurais convolucionais apresentaram desempenho expressivo na classificação dos genótipos de batata-doce a partir das imagens RGB.

Os algoritmos DenseNet121 e ResNet50 se destacaram por alcançar as excelentes acurácias globais no conjunto de testes e validações das imagens de polpa. Os resultados indicam que ambos os algoritmos de redes neurais convolucionais possuem alta capacidade de generalização e precisão na tarefa de reconhecimento e identificação de padrões das imagens de genótipos de batata-doce a partir das de polpa, configurando-se, portanto, como alternativas muito eficazes para essa tarefa de classificação.

O modelo DenseNet121 apresentou alto desempenho de acurácia global no conjunto de teste (98%), indicando uma capacidade ligeiramente superior de generalização para os dados de polpa no conjunto de treinamento e validação.

Resultados semelhantes foram observados no trabalho de Santos et al. (2024), ao realizarem uma análise comparativa de redes neurais convolucionais e

aprendizado por transferência DenseNet121 na agricultura com foco de identificação de doenças de folhas de culturas, o DenseNet121 destacou com excelente desempenho de acurácia global no conjunto de treinamento com 98,27%.

Além disso, os resultados corroboram também com o estudo de Raza et al. (2025), no reconhecimento de folhas de batata-doce; Insights Fusão de Densenet121 e filtro de eliminação gaussiana, o DenseNet121 apresentou alta performance no treinamento e validação de acurácia com 99% e 99 %, respectivamente. Esse resultado comprova o desempenho deste modelo na classificação de genótipos de batata-doce a partir de polpa no presente estudo.

Ismail et al. (2026), avaliaram a evolução da arquitetura do DenseNet121 que alcançou acurácia global de 97% na classificação de doenças, com precisão de 96,2%, recall de 97,97% e F1-score de 97%. As excelentes métricas do DenseNet121 foram observadas também no estudo de Hutapea et al. (2025), ao identificarem automaticamente o tipo de doença que afeta as folhas do milho a partir de dados de imagem. Esses resultados proporcionaram a robustez do modelo e corroboram os achados do presente trabalho, que DenseNet121 evidenciou alta eficiência de todas as métricas, com 96% de acurácia global na classificação das imagens dos genótipos avaliadas.

Os resultados obtidos para Sahlinal et al. (2025), na detecção precoce de doenças em plantas de milho, utilizando o DenseNet121, mostraram 93% de acurácia, F1-score, precisão média ponderada. Embora o modelo aprendeu detectar as doenças no milho, mas o desempenho dele foi inferior aos achados neste presente trabalho. Nesse sentido, DenseNet121 possui grande potencial nas aplicações em sistemas de detecção dos genótipos de batata-doce baseado na inteligência artificial.

Os valores de macro média e média ponderados de DenseNet121 mostraram que o desempenho do modelo é relativamente consistente entre as classes de polpa e raízes de batata-doce, não foram afetados por diferenças no conjunto de dados. Esses resultados corroboram o estudo de Purba (2026), no reconhecimento de doenças em plantas com base em imagens de folhas. Esses resultados evidenciaram que DenseNet121 possui alta capacidade de classificação estáveis no reconhecimento de genótipos e suas polpas a partir de imagens RGB.

O modelo ResNet50 alcançou acurácia de 97%, e também apresentou

resultados positivos e satisfatórios na atividade de classificação. O desempenho deste modelo ficou ligeiramente abaixo na classificação de polpa, quando se compara com DenseNet121 e considera especificamente a acurácia no conjunto de teste. Os resultados semelhantes foram vistos no estudo Rakesh et al. (2025), implementando a classificação em tempo real de folhas e tuberosas usando CNN em um microprocessador Raspberry Pi. Ambos os algoritmos apresentaram alto desempenho de acurácia do ResNet50 e de DenseNet121 com 99,6% e 97,6% respectivamente nos testes, demonstrando boa capacidade de generalização, consistentemente alta precisão, recall e pontuação F1 em todas as classes avaliados.

A eficiência deste modelo foi relatada no estudo de Kadam et al. (2022), que compararam diferentes arquiteturas, como GoogLeNet, ResNet50 e VGG16, observando que o modelo ResNet50 alcançou acurácia próxima de 90% na distinção entre folhas saudáveis e não saudáveis. A arquitetura de DenseNet121 e ResNet50 demonstraram excelentes resultados significativos com acurácia superiores atingido entre 90% e 98% na análise de redes neurais convolucionais para a classificação de doenças em folhas de soja (Rossi et al. 2022), o destaque deste modelo foi comprovado no presente estudo.

No estudo desenvolvido por Fernandes et al. (2023), ao avaliarem essas arquitetura com o objetivo de auxiliar na fenotipagem de raízes de batata-doce, principalmente na análise da cor da casca e do formato das raízes, o modelo ResNet50 apresentou desempenho inferior em relação a outras arquiteturas testadas, alcançando a acurácia de 81% para o formato e 90% para a cor da casca, mesmo após um número elevado de épocas de treinamento, além de exigir maior tempo computacional, ResNet50 também apresentou menor resultados no presente trabalho.

O modelo ResNet50 apresentou resultados altamente satisfatória, com o desempenho ligeiramente superior com 98% de acurácia global para todas as métricas e as médias ponderadas em comparação com DenseNet121 e MobileNet50 na classificação de raízes de batata-doce, oferecendo capacidades de detecção precisas e eficientes. Portanto, a arquitetura do modelo ResNet50 pode contribuir para uma classificação de genótipos de batata-doce, auxiliando os pesquisadores no uso de redes neurais para classificação de diferentes genótipos.

Naseer et al. (2025), analisaram os diferentes estágios de trigos com redes neurais convolucionais, observaram que as arquiteturas de MobileNetV2 e DenseNet-121, ambos apresentaram alta eficiência de acurácia, precisão, recall e F1-score e médias ponderadas. Esses resultados corroboram com os achados neste trabalho, indicando que ambos algoritmos proporcionam a eficácia e confiabilidade na classificação e predição das imagens dos genótipos de batata-doce.

Os algoritmos de redes neurais utilizados para classificações de raízes de batata-doce evidenciaram precisão e eficiência excepcionais em seus desempenhos no conjunto de treinamento e validação, na acurácia, precisão, recall, f1-score e matriz de confusão.

A acurácia do modelo MobileNetV2 neste trabalho alcançou o desempenho satisfatória com 96%, apresentando um equilíbrio relevante entre desempenho computacional na classificação de genótipos de batata-doce suas polpas. A eficiência do MobileNetV2 apresentou acurácia ligeiramente menor em relação ao observado nos algoritmos DenseNet121 e ResNet50 na classificação de polpa. Ainda assim, os resultados do MobileNetV2 mostraram que o modelo possui alta capacidade de classificação e desempenho consistente.

Fatmawati et al. (2026), utilizaram MobiliNetV2 na classificação de doenças em plantas de pimenta, obtiveram um desempenho sólido das métricas de precisão, recall e pontuação F1 com 89%, demonstrando a semelhança na classificação dos genótipos e polpas de batata-doce com todas as métricas acima de 95%.

O desempenho MobileNetV2 na classificação de doenças em folhas de macieira resultou uma alta acurácia global com 99% (Chen et al., 2021). Os resultados do estudo de Khoiruddin e Tena (2024), ao avaliarem rede neural convolucional (CNN) com a arquitetura MobileNetV2 para identificação de frutas, incluindo a batata-doce, o modelo demonstrou um excelente desempenho de acurácia global com 97,31%. Esses resultados corroboram com os achados neste trabalho, que proporcionam o modelo MobileNetV2 uma solução eficaz e prática na detecção e identificação dos genótipos e polpas de batata-doce.

Ressaltando que o MobileNetV2 é uma arquitetura mais leve para dispositivos móveis e é composto por gargalo, torna-se especialmente indicado para cenários em que a velocidade de processamento ou limitação de recursos computacionais são

fatores importantes, mantendo ainda assim um alto desempenho de acurácia (Sandler et al., 2018).

Para considerar a eficiência das métricas gerais que representam a proporções globais nas classificações corretas de genótipos de batata-doce a partir das imagens de polpa neste estudo, observou-se que o modelo DenseNet121 continua apresentando o melhor desempenho, superando ligeiramente o ResNet50 e o MobileNetV2. Essas diferenças são relativamente pequenas em termos absolutos, elas podem ser significativas em aplicações de classificação de alta precisão, pois indicam que o DenseNet121 foi capaz de reconhecer corretamente uma maior proporção das amostras do conjunto de treinamento. Portanto, o resultado deste modelo sugere uma capacidade superior do modelo em capturar padrões discriminativos presentes nas imagens.

Nesse sentido, o DenseNet121 exibiu os valores consistentes em todas essas métricas, demonstrando elevada capacidade de classificar corretamente as diferentes classes e manter equilíbrio entre precisão e sensibilidade. O ResNet50, por sua vez, seguiu-se como o segundo modelo mais destacado, mantendo um desempenho mais próximo ao do DenseNet121, o que pode confirmar a sua robustez e estabilidade. Por outro lado, o modelo MobileNetV2 exibiu os valores ligeiramente inferiores, variando entre as médias das métricas demonstrando um excelente desempenho geral, sua capacidade de discriminação entre algumas classes pode ser marginalmente menor.

Estudos prévios evidenciam o bom desempenho dessas arquiteturas em tarefas de classificação de imagens. Pramudita et al. (2025), analisaram o desempenho de MobileNetV2 e ResNet50 na classificação de imagens reais e imagens geradas por inteligência artificial em múltiplas classes, demonstrando a estabilidade e desempenho de MobileNetV2 e ResNet50 atingiram as acurácias satisfatória variando entre 89% e 93%, respectivamente. Neste estudo, o modelo ResNet50 apresentou desempenho mais estável ao longo do treinamento de que MobileNetV2, além de manter valores elevados e consistentes de precisão, recall e F1-score.

Resultados semelhantes foram obtidos por Hajar et al. (2025), ao analisarem as mesmas arquiteturas na classificação de folhas por ecoprint. Neste caso, os algoritmos MobileNetV2 e de ResNet50 apresentaram desempenho elevado, com

acurácia de 94,12% e 94,96%, onde o RestNet50 foi ligeiramente superior, conforme confirmado pelas métricas de desempenho e pela análise da matriz de confusão (acurácia de 0,94; precisão de 0,95; recall de 0,95; F1-score de 0,94). A superioridade ligeiramente de RestNet50 também foi comprovada no presente estudo em comparação com MobileNetV2 em todas as métricas analisadas.

Enfatizando que o Ariawan et al. (2025), também avaliou comparativamente o desempenho das arquiteturas DenseNet121 e MobileNetV2 na classificação de imagens de doenças em frutos do cacau, o modelo DenseNet121 apresentou desempenho ligeiramente superior em relação ao MobileNetV2, atingindo acurácia, precisão, recall e pontuação F1 acima de 94%. Embora que esses resultados foram menores em relação aos resultados do presente trabalho, mas ainda ambos resultados apresentaram excelentes métricas.

Contudo, pode-se observar que esses resultados comprovaram a capacidade do DenseNet-121 de extrair representações mais discriminativas das imagens, contribuindo para alta eficiência na técnica de classificação, o que foi observado no presente trabalho com este modelo. Porém, o uso de algoritmos de redes neurais convolucionais como MobileNetV2, ResNet50 e DenseNet121 têm demonstrado bons resultados na identificação de características de interesse agrônômicas em diferentes culturas.

Em comparação das métricas e médias ponderadas que levam em consideração a proporção de amostras de genótipos de batata-doce, por cada classe no conjunto de imagens, reforça essa tendência. O DenseNet121 destacando novamente os maiores valores para precisão, recall e F1-score ponderados na classificação de polpa, sugerindo que o modelo apresenta alto desempenho consistente mesmo quando a distribuição das classes é considerada. Seguindo por modelo ResNet50 apresentou resultados muito próximos, do modelo DenseNet121, indicando que também possui alta capacidade de generalização. Enquanto MobileNetV2 demonstrou os resultados consistentes e satisfatórios, com os valores próximos, mantendo desempenho competitivo, porém ligeiramente inferior aos demais algoritmos.

A superioridade do modelo DenseNet121 neste presente trabalho torna-se ainda mais evidente quando se observam precisão, recall e F1-score, macro-média e

macro-média. Essas métricas são particularmente importantes em problemas de classificação das imagens de batata-doce, pois avaliam a eficiência médio considerando todas as classes de forma equilibrada, independentemente da distribuição de amostras entre elas.

Diversos estudos têm evidenciado o potencial das redes neurais convolucionais para a classificação de imagens digitais no contexto agrícola. Arquiteturas amplamente utilizadas, como ResNet50, DenseNet121 e MobileNetV2, têm apresentado os resultados promissores em diferentes aplicações agrícolas, especialmente na identificação de características fenotípicas e na detecção de doenças em plantas.

As diferenças de desempenho observadas entre os estudos podem estar associadas a fatores como o tamanho e a diversidade dos conjuntos de dados, as características das imagens analisadas, o número de classes e as estratégias de treinamento utilizadas. Nesse sentido, os resultados obtidos no presente trabalho, com acurácia global superior de 96% na classificação de polpa de batata-doce, reforçam o potencial das redes neurais convolucionais como ferramentas eficientes para aplicações de fenotipagem e monitoramento agrícola baseadas em imagens.

6 CONCLUSÕES

As redes neurais convolucionais avaliadas neste estudo, são eficazes na identificação das imagens dos genótipos de batata-doce, alcançando o desempenho consistente em todas as métricas analisadas, incluindo acurácia, precisão, F1-score e recall.

Dentre as arquiteturas analisadas, DenseNet121 apresentou o desempenho ligeiramente superior na classificação de polpa em relação ao ResNet50 e MobileNetV2, destacando-se por obter maiores valores de todas as métricas avaliadas e apresentando maior capacidade de generalização para o conjunto de dados. O ResNet50, por sua vez, proporciona resultados excelentes para todas as métricas na classificação dos genótipos de batata-doce.

Os resultados evidenciam que o modelo DenseNet121 se destaca como melhor opção para classificação polpa e o ResNet50 como melhor opção para classificação das

raízes de batata-doce a partir das imagens RGB, apresentando desempenhos superiores em relação ao MobileNetV2.

Os resultados reforçam o potencial das redes neurais convolucionais como ferramentas eficientes para aplicações de fenotipagem digital e classificação de raízes de batata-doce, contribuindo para o avanço de estratégias de melhoramento genético baseadas em análise de imagens.

7 REFERÊNCIAS

Abebe AM, Kim Y, Kim J, Kim SL, Baek J (2023) Image-Based High-Throughput Phenotyping in Horticultural Crops. **Plants** 12:2061. <https://doi.org/10.3390/plants12102061>.

Abiri R, Rizan N, Balasundram SK, Shahbazi AB, Abdul-Hamid H (2023) Application of digital technologies for ensuring agricultural productivity. **Heliyon** 9:e22601. <https://doi.org/10.1016/j.heliyon.2023.e22601>.

Adem I, Yusuf Z, Chimdesa M (2024) On farm diversity and genetic erosion of sweet potato [*Ipomoea batatas* (L.) Lam.]. **International Journal of Vegetable Science** 30:279–293. <https://doi.org/10.1080/19315260.2024.2359484>.

Alvares CA, Stape JL, Sentelhas PC, Gonçalves JLM, Sparovek G (2013) Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift** 22(6):711–728. <https://doi.org/10.1127/0941-2948/2013/0507>

Alves AK, Araújo MS, Chaves SF, Dias LAS, Corrêdo LP, Pessoa GG, Bezerra AR (2024) High throughput phenotyping in soybean breeding using RGB image vegetation indices based on drone. **Scientific Reports** 14(1):32055.

Amaro GB, Talamini V, Fernandes FR, Silva GO, Madeira NR (2019) Desempenho de cultivares de batata-doce para rendimento e qualidade de raízes em Sergipe. **Revista Brasileira de Ciências Agrárias** 14:1–6. <https://doi.org/10.5039/agraria.v14i1a5628>.

Andrioli I, Centurion JF (1999) Levantamento detalhado dos solos da Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal. In CONGRESSO BRASILEIRO DE CIÊNCIA DO SOLO. **Anais do 27º Congresso Brasileiro de Ciência do Solo**, Sociedade Brasileira de Ciência do Solo, Brasília, DF, Brazil.

Angidi S, Madankar K, Tehseen MM, Bhatla A (2025) Advanced High-Throughput Phenotyping Techniques for Managing Abiotic Stress in Agricultural Crops-A Comprehensive Review. **Crops** 5:8. <https://doi.org/10.3390/crops5020008>.

Ariawan KR, Ekayana AAG, Indrawan IPY, Winatha KR, Setiawan INAF (2025) Performance Comparasion of DenseNet-121 and MobileNetV2 for Cacao Fruit

Disease Image Classification. **Indonesian Journal of Data and Science** 6(1), 30–38. DOI: <https://doi.org/10.56705/ijodas.v6i1.233>.

Assis KCDC, Piantoni J, Azevedo RF (2024) Tecnologias em agricultura inteligente: Eficiência e sustentabilidade. **Research, Society and Development** 13:e7013445072. <https://doi.org/10.33448/rsd-v13i4.45072>.

Bach D, Bedin AC, Lacerda LG, Nogueira A, Demiate IM (2021) Sweet Potato (*Ipomoea batatas* L.): A Versatile Raw Material for the Food Industry. **Brazilian Archives of Biology and Technology** 64:e21200568. <https://doi.org/10.1590/1678-4324-2021200568>.

Barros PPDS, Rosalen DL, Iost Filho FH, Martins GD, Di Leo N (2021) Monitoramento Fitossanitário Utilizando Sensoriamento Remoto: Avanços e Desafios. **Revista Brasileira de Cartografia** 73:489–515. <https://doi.org/10.14393/rbcv73n2-56597>.

Basílio LSP, Silva ACAF, Monteiro GC, Vargas PF, Vianello F, Lima GPP (2022) Pluralidade da batata-doce do campo à mesa: uma revisão narrativa. In: Open Science Research I. **Editora Científica Digital**, Cap. 12, p. 174–190. <https://doi.org/10.37885/220107403>.

Bassoi LH, Inamasu RY, Bernardi ACC, Vaz CMP, Speranza EA, Cruvinel, PE (2019) Agricultura de precisão e agricultura digital. **TECCOGS: Revista Digital de Tecnologias Cognitivas** (20):17–36. <https://doi.org/10.23925/1984-3585.2019i20p17-36>.

Bhadra S, Sagan V, Skobalski J, Grignola, F, Sarkar S, Vilbig J (2024) End-to-end 3D CNN for plot-scale soybean yield prediction using multitemporal UAV-based RGB images. **Precisão Agriculture** 25.2:834-864. <https://doi.org/10.1007/s11119-023-10096-8>.

Castillo-Girones S, Munera S, Martínez-Sober M, Blasco J, Cubero S, Gómez-Sanchis J (2025) Artificial Neural Networks in Agriculture, the core of artificial intelligence: What, When, and Why. **Computers and Electronics in Agriculture** 230:109938. <https://doi.org/10.1016/j.compag.2025.109938>.

Cavalcante SWS., Silva NF, Teixeira MB, Neto GZ, Cabral Filho, FR, Cunha FN, Corrêa FR (2022) Tecnologias e inovações no uso de drones na agricultura. **Brazilian Journal of Development** 8(1):7108-7117. DOI:10.34117/bjdv8n1-481.

Chen J, Zhang D, Suzauddola M, Zeb A (2021) Identifying crop diseases using attention embedded MobileNet-V2 model. **Applied Soft Computing** 113:107901. <https://doi.org/10.1016/j.asoc.2021.107901>.

Cho SB, Choi JW, Hidayat MS, Cho JI, Lee H, Cho BK, Kim G (2025) Development of a CNN classifier with XAI to detect interpretable water stress in sweet potato using RGB images. **Agricultural Water Management** 321:109899. <https://doi.org/10.1016/j.agwat.2025.109899>.

FAO (2024) FAOSTAT – Crops and Livestock Products: Sweet Potatoes. Food and Agriculture Organization of the United Nations. Disponível em: <https://www.fao.org/faostat/>. Acesso em: 1 Mar 2026.

Farhan SM, Yin J, Chen Z, Memon MS (2024) A Comprehensive Review of LiDAR Applications in Crop Management for Precision Agriculture. **Sensors** 24(16):5409. <https://doi.org/10.3390/s24165409>.

Fatmawati I, Podungge ES, Rahman A (2026) Classification of diseases in chili plants using the convolutional neural network method with MobileNetV2 architecture. **Jurnal Mandiri IT** 14(3):246-253.

Fernandes A, et al. (2023) Convolutional neural networks in the qualitative improvement of sweet potato roots. **Scientific Reports** 13(1):8429. <https://doi.org/10.1038/s41598-023-34375-6>.

Fernandes ACG (2022) **Fenotipagem de alta eficiência no melhoramento genético da batata-doce por análise computacional de imagens**. Tese (Doutorado em Produção Vegetal), Universidade Federal de Minas Gerais, Instituto de Ciências Agrárias, Montes Claros, MG, Brasil. 67 p.

Fernandes ACG, Valadares NR, Rodrigues CHO, Alves RA, Guedes LLM, Athayde ALM, Azevedo AM (2023) Convolutional neural networks in the qualitative improvement of sweet potato roots. **Scientific Reports** 13(1):8429. <https://doi.org/10.1038/s41598-023-34375-6>.

Fernandes AM, et al. (2021) Sistema de produção de batata-doce. Brasília, DF: Embrapa Hortaliças. (Sistema de Produção, 9).

Feltran JC, Peressin VA, Granja NdoP, Silva Filho HM, Lorenzi JO, Fernandes AM, Soratto RP, Factor TL, Rós AB, Aguiar EB (2022) Raízes e Tubérculos. In.: Cantarellan H, Quaggio JA, Mattos Jr D, Boaretto RM, Van Raij B (Eds.) **Boletim 100: Recomendações de Adubação e Calagem para o Estado de São Paulo**. São Paulo: Instituto Agrônômico de (IAC), p. 314–338.

George J et al. (2024) Sustainable sweetpotato production in the United States: Current status, challenges, and opportunities. **Agronomy Journal** 116:630–660. <https://doi.org/10.1002/agj2.21539>.

Gill T, Gill SK, Saini DK, Chopra Y, De Koff JP, Sandhu KS (2022) A Comprehensive Review of High Throughput Phenotyping and Machine Learning for Plant Stress Phenotyping. **Phenomics** 2:156–183. <https://doi.org/10.1007/s43657-022-00048-z>.

Goldenits G, Mallinger K, Raubitzek S, Neubauer T (2024) Current applications and potential future directions of reinforcement learning-based Digital Twins in agriculture. **Smart Agricultural Technology** 8:100512. <https://doi.org/10.1016/j.atech.2024.100512>.

Goldenits G, Mallinger K, Raubitzek S, Neubauer T (2024) Current applications and potential future directions of reinforcement learning-based Digital Twins in agriculture. **Smart Agricultural Technology** 8:100512. <https://doi.org/10.1016/j.atech.2024.100512>.

Guimarães AJS, Barbosa DS, Sousa GDS, Santos, AJDS (2025) Ação de redes neurais convolucionais na classificação de imagens: Abordagens e resultados. **Revista Contemporânea** 5(1):e7190. <https://doi.org/10.56083/RCV5N1-012>.

Hajar S, Murinto M, Yudhana A (2025) Comparison of Transfer Learning Strategies Using MobileNetV2 and ResNet50 for Ecoprint Leaf Classification. **Jurnal Teknik Informatika (Jutif)**, 6(5):3251–3264. <https://doi.org/10.52436/1.jutif.2025.6.5.5266>.

He K, Zhang, X, Ren S, Sun J (2016) Deep residual learning for image recognition. **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)** 770–778. <https://doi.org/10.1109/CVPR.2016.90>.

Herrmann Junior PDP, et al. (2024) Fenotipagem de plantas de alto rendimento, genotipagem, agricultura de precisão e agricultura digital para uma agricultura sustentável e produtiva. In L. H. Bassoi ACC, Bernardi CMP, Vaz JLF, Pires L, Gebler LAC, Jorge RY Inamasu (Eds.), **Agricultura de precisão: Um novo olhar na era digital** (Cap. 6, pp. 88–96). Editora Cubo. <https://doi.org/10.4322/978-65-86819-38-0.1000087>.

Hossain MM, Rahim MA, Moutosi HN, Das L (2022) Evaluation of the growth, storage root yield, proximate composition, and mineral content of colored sweet potato genotypes. **Journal of Agriculture and Food Research** 8:100289. <https://doi.org/10.1016/j.jafr.2022.100289>.

Huang G, Liu Z, Van DML, Weinberger KQ (2017) Densely connected convolutional networks. **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, 2261–2269. <https://doi.org/10.1109/CVPR.2017.243>.

Hutapea O, Ford L, Gaol TM (2025) Penerapan Convolutional Neural Network Dan DenseNet121 untuk Identifikasi Penyakit Daun Jagung Di Daerah Toba. **Jur Ris Kom** 12:443–453. <https://doi.org/10.30865/jurikom.v12i4.8646>.

IBGE (2024) Produção Agrícola Municipal (PAM): culturas temporárias e permanentes. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística. Disponível em: <https://cidades.ibge.gov.br/>. Acesso em: 1 Mar 2026.

Islam M, Chen G, Jin S (2019) An overview of neural network. **American Journal of Neural Networks and Applications** 5(1):7–11. <https://doi.org/10.11648/j.ajnna.20190501.12>.

Ismail A., Hamdy W, Ibrahim AH, Awad WA (2026) Classification of rice plant diseases using efficient DenseNet121. **Scientific Reports** 16:7482. <https://doi.org/10.1038/s41598-026-38078-6>.

Jiang Y, Li C (2020) Convolutional Neural Networks for Image-Based High-Throughput Plant Phenotyping: A Review. **Plant Phenomics** 2020:4152816. <https://doi.org/10.34133/2020/4152816>.

Kadam SU, Dhede VM, Khan VN, Raj A, Takale DG (2022) Machine Learning Methode for Automatic Potato Disease Detection. **NeuroQuantology** 20(16):2912–2916. DOI: <https://doi.org/10.48047/NQ.2022.20.16.NQ880300>.

Kamilaris A, Prenafeta-Boldú, FX (2018) Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture** 147:70-90. <https://doi.org/10.1016/j.compag.2018.02.016>.

Khoiruddin M, Tena S (2024) Fruit and Vegetable Classification using Convolutional Neural Network with MobileNetV2. **Journal of Applied Research In Computer Science and Information Systems** 2(2):203–210. <https://doi.org/10.61098/jarcis.v2i2.197>.

Kim J, Chung YS (2021) A short review of RGB sensor applications for accessible high-throughput phenotyping. **Journal of Crop Science and Biotechnology** 24(5):495-499. <https://doi.org/10.1007/s12892-021-00104-6>.

Kior A, Yudina L, Zolin Y, Sukhov V, Sukhova E (2024) Imagens RGB como ferramenta para sensoriamento remoto de características de plantas terrestres: Uma revisão. **Plants** 13(9): 1262. DOI:10.3390/plants13091262.

Kitzler, F., Barta, N., Neugschwandtner, R. W., Gronauer, A., & Motsch, V. (2023). WE3DS: An RGB-D image dataset for semantic segmentation in agriculture. **Sensors** 23(5):2713. <https://doi.org/10.3390/s23052713>.

Kufel J et al. (2023) What Is Machine Learning, Artificial Neural Networks and Deep Learning? - Examples of Practical Applications in Medicine. **Diagnostics** 13:2582. <https://doi.org/10.3390/diagnostics13152582>.

Leite CEC, Souza BDKF, Manfio CE, Wamser GH, Alves DP, De Francisco A (2022) Sweet Potato New Varieties Screening Based on Morphology, Pulp Color, Proximal Composition, and Total Dietary Fiber Content via Factor Analysis and Principal Component Analysis. **Frontiers in Plant Science** 13:852709. <https://doi.org/10.3389/fpls.2022.852709>.

Leite MA de A, Massruha, SMFS, Coral KJ (2024) Agricultura digital, inovação e aplicações. In.: FC da Silva FJ Freire (Eds.) **Inovação e desenvolvimento em cana-de-açúcar: manejo, nutrição, bioinsumos, recomendação de corretivos e fertilizantes**. Pernambuco: EMBRAPA, 39–60.

Lima MAA, Ferreira ME, Sánchez C, (2023) Batata-doce. **Revista Ciência Elementar** 11(2):018. <https://doi.org/10.24927/rce2023.018>.

Ludermir TB (2021) Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudo avançado** 35:85–94. <https://doi.org/10.1590/s0103-4014.2021.35101.007>.

Luo Z, Yao Z, Yang Y, Wang Z, Zou H, Zhang X, Chen J, Fang B, Huang L (2023) Genetic fingerprint construction and genetic diversity analysis of sweet potato (*Ipomoea batatas*) germplasm resources. **BMC Plant Biology** 23:355. <https://doi.org/10.1186/s12870-023-04329-1>.

Ma W, Qiu Z, Song J, Li J, Cheng Q, Zhai J, Ma C (2018) A deep convolutional neural network approach for predicting phenotypes from genotypes. **Planta** 248(5):1307–1318. <https://doi.org/10.1007/s00425-018-2976-9>.

Ma Z (2023) **Sensing Technologies for High-Throughput Plant Phenotyping: A Comprehensive Review with a Case Study**. Doctoral Thesis, The University of British Columbia, Kelowna, BC, Canada.

Martins, OO, Oosthuizen, CC, Desai, DA (2025) Evaluating unified training optimisations for MobileNetV2: Efficiency-Acurácia trade-offs in fine-grained dog breed classification. **Discover Applied Sciences** 7(11):1240. <https://doi.org/10.1007/s42452-025-07798-1>.

Ministério da Agricultura e Pecuária - MAPA (2025) Cultivares registradas. Disponível em https://sistemas.agricultura.gov.br/snpc/cultivarweb/cultivares_registradas.php. Acesso em: 5 de agosto de 2025.

Mohammadi S, Uhlen AK, Lillemo M, Ergon Å, Shafiee S (2024) Enhancing phenotyping efficiency in faba bean breeding: integrating UAV imaging and machine learning. **Precisão Agriculture** 25(3):1502-1528.

Momenté VG, Rocha WS, Neres LL, Nascimento IRD, Maciel LC, Silveira MAD (2025) Avaliação de genótipos de batata-doce com potencial para produção de etanol. Revista **Observatorio de la Economía Latinoamericana** 23:e8843. <https://doi.org/10.55905/oelv23n1-229>.

Moriya ÉAS, Imai NN, Tommaselli AMG, Honkavaara E, Rosalen DL (2023) Design of Vegetation Index for Identifying the Mosaic Virus in Sugarcane Plantation: A Brazilian Case Study. **Agronomy** 13(6):1542. <https://doi.org/10.3390/agronomy13061542>

Moshawrab M, Adda M, Bouzouane A, Ibrahim H, Raad A (2023) Reviewing Federated Machine Learning and Its Use in Diseases Prediction. **Sensors** 23(4):2112. <https://doi.org/10.3390/s23042112>.

Naeem S, Ali A, Anam S, Ahmed MM (2023) An Unsupervised Machine Learning Algorithms: Comprehensive Review. **International Journal of Computing and Digital Systems** 13:911–921. <https://doi.org/10.12785/ijcds/130172>.

Nakatumba-Nabende J et al. (2023) Using machine learning for image-based analysis of sweetpotato root sensory attributes. **Smart Agricultural Technology** 5:100291. <https://doi.org/10.1016/j.atech.2023.100291>.

Naseer A, Amjad M, Raza A, Munir K, Smerat A, Gongora HF, Rios CEU, Ashraf I (2025) Novel hybrid transfer neural network for wheat crop growth stages recognition using field images. **Scientific Reports** 15:11822. <https://doi.org/10.1038/s41598-025-96332-9>.

Niazian M, Niedbała G (2020) Machine Learning for Plant Breeding and Biotechnology. **Agriculture** 10(10), 436. <https://doi.org/10.3390/agriculture10100436>.

Otálora A, Valencia-Agresoft R, Lerma TA, Afanasjeva N, Palencia M, Institute of Analytical and Technology Science “Golden-Hammer,” Mindtech s.a.s, Universidad del Valle (2024) ‘Sweet potato, batata or camote’ (Ipomoea batatas): Agronomic aspects. **Journal of Science with Technological Applications** 17:1–10. <https://doi.org/10.34294/j.jsta.24.17.101>.

Otoboni MEF, Oliveira DJLSFD, Vargas PF, Pavan BE, Andrade MI (2020) Genetic parameters and gain from selection in sweet potato genotypes with high beta-carotene content. **Crop Breeding and Applied Biotechnology** 20:e31632038. <https://doi.org/10.1590/1984-70332020v20n3a42>.

Pandolfi JG, dos Reis Lucente A, Pandolfi MAC, de Oliveira MR, Felix LE (2024) Aplicação de Deep Learning na agricultura sustentável: Otimização de Práticas Agrícolas no Contexto Brasileiro. **Revista Interface Tecnológica** 21(2):63-73. DOI: 10.31510/inf. v21i2.2030

Pramudita IGNAEP, Sudipa IGI, Fittryani YP, Iswara IBAI, Aristamy IGAAM (2026) A Comparative Study of MobileNetV2 and ResNet50 for Multi-Class AI-Generated and Real Image Classification. **Sinkron**, 10(1):536–549. <https://doi.org/10.33395/sinkron.v10i1.15682>.

Purba M (2026) Plant Disease Recognition Based on Leaf Images Using Sequential-Based DenseNet Architecture. **Journal Scientific and Applied Informatics**, 9:153–159.

Rakesh MD, Jeevankumar M, Rudraswamy SB (2025) Implementation of real time root crop leaf classification using CNN on raspberry-Pi microprocessor. **Smart Agricultural Technology** 10:100714. DOI: <https://doi.org/10.1016/j.atech.2024.100714>.

Raza A, Pitafi AH, Shaikh MK, Ahmed K, 2025. RETRACTED: Optimizing potato leaf disease recognition: Insights DenseNet121 and Gaussian elimination filter fusion. **Heliyon**, 11(3), e42318. DOI: <https://doi.org/10.1016/j.heliyon.2025.e42318>.

Resende RT, Brondani C, Chaves LJ (2023) O melhoramento na era de agricultura de precisão. In: Resende RT, Brondani C (eds) **Melhoramento de Precisão: aplicações e perspectivas na genética de plantas**. Brasília, DF: Embrapa, p. 13–39.

Rodrigues LN, Domingues AF (eds) (2017) **Agricultura irrigada: desafios e oportunidades para o desenvolvimento sustentável**. Brasília, DF: INOVAGRI, 327 p.

Rodrigues VAP, Dare J, Junior JCC, Quintiliano Lins UQ, Moreira MM (2022) Batata-Doce: Diversidade e Conservação dos Recursos Genéticos. In: Científica Digital E (ed) Open Science Research VI, 1st edn. **Editora Científica Digital**, pp 52–66.

Rofianto D, Maulini R, Sahlinal D, Meilantika D, Pujiana T (2025) Deteksi Dini Penyakit Tanaman Jagung Berbasis Transfer Learning dengan Arsitektur DenseNet121. **Jurnal sistem komputer dan informatika** 7:559–567. <https://doi.org/10.30865/json.v7i2.9094>.

Rosalen DL, Goes MJ, Pinhal CVG, Silva I (2017) Caracterização altimétrica através de sensor multiespectral embarcado em aeronave remotamente pilotada. **Anais do XXVII Congresso Brasileiro de Cartografia e XXVI Exposicarta, SBC, 2017**. Rio de Janeiro - RJ, p. 679-683.

Rossi RZ, Machado MM, Oliveira LÁ, Araújo GE, Filho TADS, Silva SFD (2022) Analysis of Convolutional Neural Networks for diseases classification in soybean leaves. **Brazilian Journal of Development**, 8(6), 47914–47933. DOI: <https://doi.org/10.34117/bjdv8n6-339>.

Roullier C, Duputié A, Wennekes P, Benoit L, Fernández Bringas VM, Rossel G, Tay D, Mckey D, Lebot V (2013) Disentangling the Origins of Cultivated Sweet Potato (*Ipomoea batatas* (L.) Lam.) **PLoS ONE** 8(5): e62707. doi:10.1371/journal.pone.0062707.

Sanchez PDC, Hashim N, Shamsudin R, Mohd Nor MZ (2020) Applications of imaging and spectroscopy techniques for non-destructive quality evaluation of potatoes and sweet potatoes: A review. **Trends in Food Science & Technology** 96:208–221. <https://doi.org/10.1016/j.tifs.2019.12.027>.

Sandhu K, Patil SS, Pumphrey M, Carter A (2021) Multitrait machine and deep learning models for genomic selection using spectral information in a wheat breeding program. **The Plant Genome** 14:e20119. <https://doi.org/10.1002/tpg2.20119>.

Sandler M, Howard A, Zhu M, Zhmoginov A, Chen LC (2018) MobileNetV2: Inverted residuals and linear bottlenecks. **IEEE/CVF Conference on Computer Vision and Pattern Recognition**, 4510–4520. <https://doi.org/10.1109/CVPR.2018.00474>.

Santos HG et al. (2018) **Sistema Brasileiro de Classificação dos solos**. 5ª ed. rev. e ampl.). Embrapa.

Santos TT, Barbedo JGA, Ternes S, Camargo Neto J, Koenigkan LV, Souza KXS (2020) Visão computacional aplicada na agricultura. In Santos, TT, Barbedo JGA, Rodrigues GC (Orgs.), **Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas**. Brasília, DF: EMBRAPA, pp. 87–116.

Santoso HA, Fandhi Safsalta B, Febrianto N, Wilujeng Saraswati G, Haw S-C (2024) Comparative analysis of convolutional neural network and DenseNet121 transfer learning in agriculture focusing on crop leaf disease identification. **Applied Computing and Informatics**. <https://doi.org/10.1108/ACI-03-2024-0132>.

Sapakhova Z, Raissova N, Daurov D, Zhapar K, Daurova A, Zhigailov A, Zhambakin K, Shamekova M (2023) Sweet Potato as a Key Crop for Food Security under the Conditions of Global Climate Change: A Review. **Plants**, 12:2516. <https://doi.org/10.3390/plants12132516>.

Shafiq M, Gu Z (2022) Deep Residual Learning for Image Recognition: A Survey. **Applied Sciences**, 12(18), 8972. <https://doi.org/10.3390/app12188972>.

Sharifani K, Amini M (2023) Machine learning and deep learning: A review of methods and applications. **World Information Technology and Engineering Journal** 10(07), 3897-3904.

Song P, Li Z., Yang M, Shao Y, Pu Z, Yang W, Zhai R (2023) Dynamic detection of three-dimensional crop phenotypes based on a consumer-grade RGB-D camera. **Frontiers in Plant Science** 14: 1097725.

Souza CDJ, Guedes GB, Moraes FP, Oliveira AMS, Polesi LF (2025) Caracterização físico-química da farinha de batata-doce produzida por uma cooperativa de agricultura familiar de sergipe. **IJAS-PDVAGRO** 5:32–48. <https://doi.org/10.31692/7fh2tf57>.

Souza EDD, Santos LGD, Santos GMSSD, Cruz JFD, Lima JAMDC, Souza UO (2022) Índice NDVI em lavoura de batata-doce obtido por mapeamento com drone. **CONJ** 22:1377–1385. <https://doi.org/10.53660/CONJ-865-G05>.

Suave AA (2024) **Inteligência Artificial**. Freitas Bastos Editora. Rio de Janeiro, RJ 216 p.

Sun L, Lai M, Ghouri F, Nawaz MA, Ali F, Baloch FS, Nadeem MA, Aasim M, Shahid MQ (2024) Modern Plant Breeding Techniques in Crop Improvement and Genetic Diversity: From Molecular Markers and Gene Editing to Artificial Intelligence-A Critical Review. **Plants**, 13:2676. <https://doi.org/10.3390/plants13192676>.

Sweet DD, Tirado SB, Springer NM, Hirsch CN, Hirsch CD (2022) Opportunities and challenges in phenotyping row crops using drone-based RGB imaging. **The Plant Phenome Journal** 5(1): e20044. DOI: 10.1002/ppj2.20044.

Takhtkeshha N, Mandlbürger G, Remondino F, Hyypä J (2024) Multispectral Light Detection and Ranging Technology and Applications: A Review. **Sensors** 24(5):1669. <https://doi.org/10.3390/s24051669>.

Tarua, DCJ, Moisés, LC, Damba, GP, Serrote, CML, Mussalama, AZ (2022) Desempenho de genótipos de batata-doce no planalto de Lichinga, Moçambique. **Agropecuária Catarinense**, 35(1), 29–31. <https://doi.org/10.52945/rac.v35i1.1120>.

Thompson AL, Thorp KR, Conley MM, Roybal M, Moller D, Long JC (2020) A data workflow to support plant breeding decisions from a terrestrial field-based high-throughput plant phenotyping system. **Plant Methods** 16:97. <https://doi.org/10.1186/s13007-020-00639-9>.

Troni LM, Lima CSM, Pinto VZ, Campos FS, Trindade AGA, Koester D, Souza MA da C, Lotici JMC, Oliveira M (2019). Produção, produtividade e características físico-químicas de duas cultivares de batata-doce em sistema de cultivo orgânico. **Revista Iberoamericana de Tecnología Postcosecha** 20(2). <https://www.redalyc.org/articulo.oa?id=81361553010>.

Ubbens JR, Stavness I (2017) Deep plant phenomics: a deep learning platform for complex plant phenotyping tasks. **Frontiers in plant science** 8:1190. <https://doi.org/10.3389/fpls.2017.01190>.

Van Engelen JE, Hoos HH (2020) A survey on semi-supervised learning. **Machine Learning**, 109:373–440. <https://doi.org/10.1007/s10994-019-05855-6>.

Villagran E, Toro-Tobón G, Velázquez FA, Estrada-Bonilla GA (2024) Integration of IoT Technologies and High-Performance Phenotyping for Climate Control in Greenhouses and Mitigation of Water Deficit: A Study of High-Andean Oat. **AgriEngineering** 6:4011–4040. <https://doi.org/10.3390/agriengineering6040227>.

Wang J, Wang Y, Li G, Qi Z (2024) Integration of Remote Sensing and Machine Learning for Precisão Agriculture: A Comprehensive Perspective on Applications. **Agronomy** 14:1975. <https://doi.org/10.3390/agronomy14091975>.

Yan M et al. (2022) Exploring and exploiting genetics and genomics for sweetpotato improvement: Status and perspectives. **Plant Communications**, v. 3, n. 5, <https://doi.org/10.1016/j.xplc.2022.100332>.

Zeist AR, Carbonera MZ, Rech C, Oliveira GJA, Toroco BR, Silva Júnior AD, Garcia Neto J, Leal MHS (2024) Soaking time in sulfuric acid to overcome sweet potato seeds dormancy. **Horticultura Brasileira** 42:e2560. <https://doi.org/10.1590/S0102-0536-2023-e2560>.

Zhang S, Wang X, Lin H, Qiang Z (2025) A review of the application of UAV multispectral remote sensing technology in precisão agriculture. **Smart Agricultural Technology** 12:101406. <https://doi.org/10.1016/j.atech.2025.101406>.