

**UNIVERSIDADE ESTADUAL PAULISTA**  
**FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS**  
**CÂMPUS DE JABOTICABAL**

**USO DE SENSORIAMENTO REMOTO PARA PREDIÇÃO DE PRODUTIVIDADE DA  
CULTURA DA BATATA**

**BRUNO RIPA BAPTISTA**

Jaboticabal – SP

2025

**UNIVERSIDADE ESTADUAL PAULISTA**  
**FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS**  
**CÂMPUS DE JABOTICABAL**

**USO DE SENSORIAMENTO REMOTO PARA PREDIÇÃO DE PRODUTIVIDADE DA  
CULTURA DA BATATA**

**BRUNO RIPA BAPTISTA**

Orientador: Prof. Dr. Rouverson Pereira da Silva

Coorientadora: Dr. Samira Luns Hatum de Almeida

Trabalho apresentado à Faculdade de Ciências  
Agrárias e Veterinárias – UNESP, Câmpus de  
Jaboticabal, para graduação em ENGENHARIA  
AGRONÔMICA.

Jaboticabal – SP

2025

B222u	<p data-bbox="507 1435 1230 1585">Baptista, Bruno Ripa Uso de sensoriamento remoto para predição da produtividade da cultura da batata / Bruno Ripa Baptista. -- Jaboticabal, 2025 45 p.</p> <p data-bbox="507 1637 1230 1823">Trabalho de conclusão de curso (Bacharelado - Engenharia Agrônômica) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal Orientador: Rouverson da Silva Coorientadora: Samira de Almeida</p> <p data-bbox="507 1874 1230 1944">1. Batata.. 2. Redes neurais.. 3. Processamento de dados.. 4. Sensoriamento remoto.. 5. Produtividade.. I. Título.</p>
-------	---

**BRUNO RIPA BAPTISTA**

**USO DE SENSORIAMENTO REMOTO PARA PREDIÇÃO DE PRODUTIVIDADE DA CULTURA DA BATATA**

Trabalho de Conclusão de Curso apresentada à Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal, para obtenção do título de Bacharel em Engenharia Agrônômica.


Orientador: Prof. Dr. Rouverson Pereira da Silva  
Coorientadora: Dr. Samira Luns Hatum de Almeida.

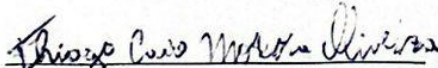
Área de Concentração: Máquinas e Mecanização Agrícola


Data da defesa: 19/11/2025

( X ) Aprovado  
( ) Reprovado


Banca Examinadora:

  
Prof. Dr. Rouverson Pereira da Silva  
UNESP – Faculdade de Ciências Agrárias e Veterinárias – Campus de Jaboticabal

  
Eng. Agrônomo Me. Thiago Caio Moura Oliveira  
UNESP – Faculdade de Ciências Agrárias e Veterinárias – Campus de Jaboticabal

  
Eng. Agrônomo Luís Alberto Rocha Rodrigues Jr  
UNESP – Faculdade de Ciências Agrárias e Veterinárias – Campus de Jaboticabal

Aprovado em reunião do Conselho do Departamento em: 25/11/2025

  
Prof. Dr. Luiz Fabiano Palaretti

Chefe do Departamento

Faculdade de Ciências Agrárias e Veterinárias – Seção Técnica de Graduação  
Via de Acesso Prof. Paulo Donato Castellane, s/n CEP 14884-900 Jaboticabal/SP - Brasil  
Tel (16) 3209 7106 e-mail: [graduacao.fcav@unesp.br](mailto:graduacao.fcav@unesp.br) - [www.fcav.unesp.br](http://www.fcav.unesp.br)

### **Dedicatória**

Dedico este trabalho aos meus pais Sérgio Luis Baptista e Delaine Bonadia Ripa Baptista, ao meu irmão Matheus Ripa Baptista e meus padrinhos Ednir Donizete de Oliveira e Denise Bonadia Ripa de Oliveira por sempre me incentivar e me apoiar em toda minha trajetória até aqui.

### **In memoriam**

Dedico este trabalho à memória de Leandro Bet, que partiu cedo demais e não pôde estar presente nesta conquista, mas cuja influência foi fundamental em minha trajetória.

## **Agradecimentos.**

A Deus, pela minha vida, e por me permitir ultrapassar todos os obstáculos encontrados ao longo da realização deste trabalho.

Aos meus pais e irmão, que me incentivaram nos momentos difíceis e compreenderam a minha ausência enquanto eu me dedicava à realização deste trabalho.

Aos meus familiares, por todo o apoio e pela ajuda, que muito contribuíram para a realização deste trabalho.

Ao meu professor orientador e amigo, Prof. Dr. Rouverson Pereira da Silva, pela dedicação e confiança depositada em mim para este trabalho, pela amizade incondicional e pelo apoio demonstrado ao longo de todo o período de tempo em que me dediquei a este trabalho.

A minha coorientadora, Dr. Samira Lins Hatum de Almeida, pelo total apoio e pelos ensinamentos que contribuíram significativamente para o desenvolvimento deste trabalho.

Ao Laboratório de Máquinas e Mecanização Agrícola (LAMMA), pela estrutura, pelo suporte técnico e pelo ambiente de aprendizado que foram cruciais para o andamento deste estudo.

A todos os integrantes do grupo Rouverson Silva Research Group (RSRG), por toda colaboração e ajuda a este trabalho.

À República Viracopos, pelo companheirismo, pelas amizades e pelas memórias construídas ao longo desta jornada.

Às Repúblicas Arapuka e Independência, pelas memórias e amizades criadas durante todo esse tempo.

À Faculdade de Ciências Agrárias e Veterinárias da UNESP – Campus de Jaboticabal, pela formação de excelência, pela oportunidade de aprendizado e por ser o espaço que marcou minha trajetória acadêmica.

Por fim, agradeço a todos que, direta ou indiretamente, contribuíram para a realização deste trabalho.

À Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP, pelo auxílio financeiro para desenvolvimento desta pesquisa - FAPESP: 2023/08119-9

Muito obrigado!

*Sonhos determinam o que você quer. Ação determina o que você conquista.*

Aldo Novak

## SUMÁRIO

RESUMO .....	10
ABSTRACT .....	11
LISTA DE FIGURAS .....	12
LISTA DE TABELAS .....	13
1 INTRODUÇÃO.....	14
2 OBJETIVOS .....	16
2.1 Geral .....	16
2.2 Específicos.....	16
3 REVISÃO DE LITERATURA.....	17
3.1 Cultura da batata.....	17
3.2 Monitoramento agrícola e a agricultura de precisão.....	18
3.3 Sensoriamento remoto aplicado à agricultura, índices de vegetação e parâmetros biofísicos ..	18
3.4 Modelagem preditiva em agricultura e Redes Neurais Artificiais (RNA).....	19
3.5 Integração entre sensoriamento remoto e inteligência artificial .....	20
4 METODOLOGIA .....	21
4.1 Caracterização do Local de Estudo.....	21
4.2 Variáveis de Campo .....	23
4.3 Dados espectrais e Índices de vegetação .....	24
4.4 Análise descritiva.....	26
4.4 Redes Neurais Artificiais para predição da produtividade da batata.....	26
4.4.1 Redes neurais Percptron multicamadas (MLP).....	28
4.4.2 Redes neurais de função de ativação de base radial (RBF) .....	29
5 RESULTADOS.....	30
5.1 Análise descritiva dos dados .....	30
5.2 Acurácia dos modelos.....	32
5.3 Análise de sensibilidade.....	35
6 DISCUSSÃO .....	38
6.1 Análise descritiva das variáveis.....	38
6.2 Acurácia dos modelos.....	39
6.3 Análise de sensibilidade.....	42
7 CONCLUSÃO.....	44
8 REFERÊNCIAS .....	44

## RESUMO

A cultura da batata possui elevada relevância econômica e social, sendo uma das hortaliças mais cultivadas e consumidas no mundo. No Brasil, estados como Minas Gerais, São Paulo e Paraná concentram parte expressiva da produção nacional, desempenhando papel estratégico tanto para o abastecimento interno quanto para a geração de renda agrícola. Diante da necessidade crescente de tecnologias que auxiliem na predição de produtividade e na adoção de práticas de manejo mais sustentáveis, o sensoriamento remoto aliado a técnicas de aprendizado de máquina apresenta-se como ferramenta promissora. O presente trabalho expõe os resultados e experiências obtidos no ano de 2025 no âmbito do projeto de monitoramento e predição de produtividade da batata. As atividades buscaram utilizar redes neurais para prever a produtividade da cultura antes da sua colheita. Ao longo do período, foram coletados dados espectrais provenientes de satélites de alta resolução e devidamente processados para a extração de índices de vegetação representativos da dinâmica do cultivo. Paralelamente, realizaram-se levantamentos agrônômicos em parcelas experimentais e áreas comerciais, sendo a variável produtividade a variável de interesse. Esses dados foram integrados em banco unificado e analisados por meio do software STATISTICA®, permitindo o desenvolvimento de modelos baseados em redes neurais artificiais (MLP e RBF). Na safra de 2025, com a cultivar Orchestra, a análise descritiva indicou produtividade média de 33,27 t ha<sup>-1</sup>, com distribuição normal e variabilidade moderada (CV = 16,75%). As redes MLP apresentaram erros médios absolutos (MAE) entre 5,29 e 8,48 t ha<sup>-1</sup>, enquanto as RBF se destacaram com valores entre 2,63 e 4,15 t ha<sup>-1</sup>, especialmente nos estágios intermediários (48–70 DAP), considerados os mais informativos para a predição da produtividade. A análise de sensibilidade reforçou essa superioridade, demonstrando que as RBF priorizaram variáveis espectrais fisiologicamente coerentes com cada fase do ciclo, em especial a borda vermelha (705 nm) e o NIR (865 nm) no auge do desenvolvimento da cultura. Assim, os avanços obtidos em 2025 confirmam o potencial das ferramentas de sensoriamento remoto e modelagem estatística no apoio à tomada de decisão no cultivo da batata. A integração de imagens orbitais de alta resolução e redes neurais artificiais mostrou-se eficaz na predição da produtividade, fornecendo subsídios para práticas de agricultura de precisão, manejo mais sustentável e consolidação da agricultura digital na cadeia produtiva da batata.

**Palavras-chave:** Batata, produtividade, sensoriamento remoto, processamento de dados, redes neurais.

### ABSTRACT

The potato crop has high economic and social relevance, being one of the most cultivated and consumed vegetables worldwide. In Brazil, states such as Minas Gerais, São Paulo, and Paraná concentrate a significant portion of the national production, playing a strategic role for both domestic supply and agricultural income generation. Given the growing need for technologies that aid in productivity estimation and the adoption of more sustainable management practices, remote sensing combined with machine learning techniques presents itself as a promising tool. This work presents the results and experiences obtained in the year 2025 within the scope of the potato crop monitoring and productivity prediction project. The activities aimed to utilize neural networks to predict crop productivity before harvest. Throughout the period, spectral data from high-resolution satellites were collected and properly processed to extract vegetation indices representative of the crop's dynamics. In parallel, agronomic surveys were conducted in experimental plots and commercial areas, with the productivity variable serving as the central reference for model calibration. This data was integrated into a unified database and analyzed using the STATISTICA® software, enabling the development of models based on Artificial Neural Networks (MLP and RBF). In the 2025 season, with the Orchestra cultivar, descriptive analysis indicated an average productivity of 33.27 t ha<sup>-1</sup>, with a normal distribution and moderate variability (CV = 16.75%). The MLP networks showed Mean Absolute Errors (MAE) between 5.29 and 8.48 t ha<sup>-1</sup>, while the RBF networks stood out with values between 2.63 and 4.15 t ha<sup>-1</sup>, especially in the intermediate stages (48–70 DAP), which are considered the most informative for productivity estimation. Sensitivity analysis reinforced this superiority, demonstrating that the RBF networks prioritized spectral variables that are physiologically coherent with each phase of the cycle, particularly the red edge (705 nm) and NIR (865 nm) at the peak of crop development. Thus, the advancements obtained in 2025 confirm the potential of remote sensing and statistical modeling tools in supporting decision-making in potato cultivation. The integration of high-resolution orbital images and artificial neural networks proved effective in productivity prediction, providing support for precision agriculture practices, more sustainable management, and the consolidation of digital agriculture in the potato production chain.

**Keywords:** Potato, Productivity, Remote Sensing, Data Processing, Neural networks.

## LISTA DE FIGURAS

Figura 1- Área experimental: Porto Ferreira, SP.....	20
Figura 2- Batata Orchestra em seu estágio vegetativo e colheita .....	21
Figura 3- 80 pontos amostrais. ....	<b>Error! Bookmark not defined.</b>
Figura 4- a) Coleta; b) Paisagem. ....	22
Figura 5- Equipamentos utilizados para aquisição das imagens: a) PhantomP4; b) base RTK. .....	23
Figura 6- Arquitetura de uma rede neural perceptron multicamadas.....	26
Figura 7- Arquitetura de uma rede neural de função de base radial.....	28
Figura 8- Gráfico de Probabilidade Normal.....	25
Figura 9- Gráfico de bolhas com o valor de MAE para RBF.....	27
Figura 10- Gráfico de bolhas com o valor de MAE para MLP .....	28

**LISTA DE TABELAS**

Tabela 1 - Índices de vegetação usados neste estudo .....	24
Tabela 2 - Estatística descritiva para as variáveis relacionadas à produtividade, em t ha <sup>-1</sup> .....	26
Tabela 3 - Análise de sensibilidade para as combinações com múltiplas entradas .....	31

## 1 INTRODUÇÃO

A batata (*Solanum tuberosum* L.) é uma das culturas alimentares mais antigas e relevantes do planeta. Originária da região andina da América do Sul, onde era cultivada por civilizações pré-colombianas há mais de 7.000 anos, a espécie foi disseminada mundialmente após o século XVI, tornando-se um dos principais pilares da segurança alimentar global (ZAHEER; AKHTAR, 2016). Atualmente, ocupa a quarta posição entre as culturas alimentares mais produzidas, atrás apenas do arroz, trigo e milho, com produção mundial superior a 370 milhões de toneladas anuais e cultivo em mais de 150 países (FAO, 2024).

A importância da batata transcende o aspecto econômico, refletindo também seu papel social e nutricional. O tubérculo apresenta alto valor energético e teores expressivos de carboidratos complexos, vitaminas e minerais essenciais. Segundo a FAO (2024), mais de um bilhão de pessoas consomem batata diariamente, tornando-a uma fonte alimentar fundamental em regiões de clima temperado e tropical. Além disso, sua versatilidade culinária e a possibilidade de processamento industrial para produtos como batata pré-frita, purê desidratado e fécula reforçam sua relevância no mercado global de alimentos (ZAHEER; AKHTAR, 2016).

No Brasil, a batata figura entre as principais hortaliças em termos de área cultivada e valor econômico, movimentando mais de R\$ 7 bilhões por ano e gerando milhares de empregos diretos e indiretos (IBGE, 2024). A produção nacional é concentrada nos estados de Minas Gerais, São Paulo, Paraná e Rio Grande do Sul, que juntos respondem por mais de 80 % da produção total (CONAB, 2025). A produtividade média nacional, atualmente em torno de 32 t ha<sup>-1</sup>, supera a média mundial, reflexo do avanço tecnológico e da adoção de práticas intensivas de manejo, mecanização e irrigação.

Apesar dos avanços produtivos, a cultura da batata enfrenta desafios agrônômicos consideráveis. Seu sistema radicular superficial e a alta demanda hídrica tornam a cultura extremamente sensível a déficits de água e variações de temperatura (JENNINGS et al., 2020). Além disso, doenças como a requeima (*Phytophthora infestans*) e pragas de solo, como nematoides e *Elateridae*, podem comprometer significativamente a produtividade e a qualidade dos tubérculos (EMBRAPA HORTALIÇAS [s.d.]). Tais fatores reforçam a necessidade de adoção de tecnologias que permitam o monitoramento detalhado do desenvolvimento da cultura e a tomada de decisões baseadas em informações precisas e tempestivas.

Nesse contexto, o uso do sensoriamento remoto e da agricultura de precisão tem se destacado como ferramenta essencial para o acompanhamento do crescimento das plantas e a avaliação de parâmetros fisiológicos e biofísicos, sem a necessidade de contato direto com o cultivo (ROUSE et al., 1974; GITELSON; MERZLYAK, 1996). O sensoriamento remoto, por

meio de sensores instalados em satélites, aeronaves e drones, possibilita o monitoramento contínuo de grandes áreas, permitindo identificar padrões de vigor vegetativo, estresse hídrico e anomalias de desenvolvimento. Quando combinado a técnicas analíticas avançadas, esses dados tornam-se valiosos indicadores do potencial produtivo das lavouras.

Nos últimos anos, a integração entre sensoriamento remoto e modelagem computacional tem revolucionado a agricultura de precisão. Métodos baseados em aprendizado de máquina, como as Redes Neurais Artificiais (RNA), vêm sendo amplamente empregados para prever a produtividade agrícola a partir de variáveis espectrais e meteorológicas (HAYKIN, 1999; KUREK et al., 2023). Essas ferramentas apresentam elevada capacidade de aprendizado e adaptação, sendo capazes de representar relações complexas e não lineares entre variáveis espectrais e atributos agronômicos.

O avanço dessas tecnologias permite prever a produtividade de culturas agrícolas com antecedência, reduzindo custos de monitoramento e otimizando o planejamento agrícola (Kulyal, Malika & Saxena, Parul, 2024). A aplicação do sensoriamento remoto e das redes neurais artificiais na cultura da batata, em especial, mostra-se promissora devido à natureza dinâmica do crescimento do dossel e à rápida resposta da planta a variações de manejo e ambiente.

Dessa forma, compreender a aplicação e o potencial dessas tecnologias é fundamental para o desenvolvimento de sistemas de produção mais eficientes, sustentáveis e alinhados às demandas da agricultura moderna. A integração entre dados espectrais de alta resolução e modelos inteligentes representa um avanço significativo na gestão agrícola e abre novas perspectivas para o monitoramento, planejamento e predição da produtividade da batata.

## **2 OBJETIVOS**

### **2.1 Geral**

Desenvolver e avaliar modelos de predição de produtividade da cultura da batata a partir da integração de dados de sensoriamento remoto orbital e técnicas de aprendizado de máquina baseadas em Redes Neurais Artificiais, visando aprimorar o monitoramento agrícola e a tomada de decisão no manejo da cultura.

### **2.2 Específicos**

Utilizar imagens multiespectrais de alta resolução provenientes da constelação PlanetScope para acompanhar o desenvolvimento fenológico da cultura da batata ao longo do ciclo produtivo.

Calcular e analisar índices de vegetação derivados das imagens orbitais (NDVI, NDRE, SAVI, EVI, entre outros), correlacionando-os com os dados reais de produtividade obtidos em campo.

Empregar modelos de Redes Neurais Artificiais do tipo MLP (Multilayer Perceptron) e RBF (Radial Basis Function) para prever a produtividade com base nas variáveis espectrais e agronômicas coletadas.

Avaliar o desempenho dos modelos desenvolvidos por meio de métricas estatísticas, como o erro médio absoluto (MAE).

Realizar análises de sensibilidade das variáveis de entrada, a fim de identificar os índices e bandas espectrais com maior influência sobre a produtividade da cultura.

### 3 REVISÃO DE LITERATURA

#### 3.1 Cultura da batata

A batata (*Solanum tuberosum* L.) é reconhecida mundialmente como um dos alimentos básicos mais importantes para a segurança alimentar, estando entre as quatro principais culturas alimentares em volume de produção global, atrás apenas de arroz, trigo e milho (FAO, 2024). Estima-se que a produção mundial ultrapasse 370 milhões de toneladas por ano, cultivadas em aproximadamente 17 milhões de hectares, distribuídos em mais de 150 países (FAO, 2024). Sua versatilidade culinária, elevado valor nutricional e ampla adaptabilidade climática a tornam essencial tanto para o consumo humano direto quanto para a indústria alimentícia e a exportação (ZAHEER; AKHTAR, 2016).

No contexto brasileiro, a batata apresenta papel estratégico tanto do ponto de vista econômico quanto social. Segundo o IBGE (2024), a produção nacional atingiu cerca de 3,7 milhões de toneladas em 2024, com produtividade média superior a 32 t ha<sup>-1</sup>, resultado de avanços tecnológicos e práticas intensivas de manejo. Os principais polos de cultivo concentram-se em Minas Gerais, São Paulo, Paraná e Rio Grande do Sul, responsáveis por mais de 80% da produção nacional (CONAB, 2025). Além disso, a cadeia produtiva da batata é uma das mais complexas entre as hortaliças, envolvendo produtores, processadores, distribuidores e mercados consumidores em ampla escala, gerando empregos diretos e indiretos em todas as regiões produtoras (ZAHEER; AKHTAR, 2016; IBGE, 2024).

Do ponto de vista agrônômico, trata-se de uma cultura exigente em fertilidade e manejo hídrico, com sistema radicular superficial e sensibilidade elevada a variações de temperatura e umidade do solo (JENNINGS et al., 2020). A ocorrência de doenças como a requeima (*Phytophthora infestans*) e o ataque de pragas de solo e nematoides podem ocasionar reduções significativas na produtividade e na qualidade dos tubérculos (EMBRAPA HORTALIÇAS [s.d.]). Assim, a adoção de técnicas modernas de monitoramento e manejo é essencial para aumentar a eficiência produtiva e reduzir as perdas.

Nos últimos anos, a intensificação tecnológica no cultivo da batata, associada ao uso de irrigação e à mecanização, permitiu o avanço da produtividade, mas também elevou os custos de produção e o risco ambiental. Diante desse cenário, torna-se fundamental o uso de ferramentas de gestão agrícola e tecnologias de agricultura de precisão, que possibilitam otimizar o uso de insumos, melhorar o diagnóstico das condições da cultura e garantir sustentabilidade à produção.

### **3.2 Monitoramento agrícola e a agricultura de precisão**

O conceito de agricultura de precisão (AP) surgiu como resposta à necessidade de compreender e manejar a variabilidade espacial e temporal presente nos sistemas agrícolas. Essa abordagem baseia-se na aplicação de tecnologias que permitem identificar diferenças de produtividade, fertilidade, umidade e vigor vegetativo dentro de uma mesma área, proporcionando um manejo localizado e eficiente (SISHODIA et al., 2020).

O monitoramento agrícola, elemento central da AP, é viabilizado pelo uso de sensores remotos, sistemas de informação geográfica (SIG), receptores GNSS e ferramentas de análise espacial. Tais tecnologias possibilitam o acompanhamento contínuo do desenvolvimento das plantas, permitindo a identificação precoce de deficiências nutricionais, estresses hídricos e incidências de pragas e doenças.

Nos últimos anos, a evolução da Internet das Coisas (IoT), da automação e da análise de dados em nuvem consolidou o conceito de Agricultura 4.0, que integra máquinas inteligentes, drones, satélites e algoritmos de aprendizado de máquina em um mesmo ecossistema digital (KUMAR et al., 2021). Essa integração tecnológica tem possibilitado o uso de dados em tempo real para decisões operacionais e estratégicas, otimizando a aplicação de fertilizantes, defensivos e água de irrigação (GAMAGE et al., 2024).

De acordo com Liakos et al. (2018) o uso de sistemas de monitoramento remoto e modelos preditivos tem contribuído para uma redução média de 20% no uso de insumos e aumento de até 15% na eficiência produtiva de culturas de ciclo curto, como a batata. Além dos ganhos econômicos, a agricultura de precisão reduz impactos ambientais, promove sustentabilidade e melhora o rastreamento de práticas agrícolas, o que é essencial em cadeias produtivas intensivas como a da batata.

Portanto, a agricultura de precisão representa uma mudança de paradigma na forma de conduzir a produção agrícola, promovendo o uso racional dos recursos e a tomada de decisão baseada em dados. A associação de sensores, imagens orbitais e modelos de análise de dados cria as bases para uma agricultura inteligente, capaz de responder aos desafios de produtividade, sustentabilidade e competitividade.

### **3.3 Sensoriamento remoto aplicado à agricultura, índices de vegetação e parâmetros biofísicos**

O sensoriamento remoto é uma das ferramentas mais eficazes no monitoramento agrícola, permitindo a obtenção de informações sobre o desenvolvimento das culturas de maneira contínua, precisa e não destrutiva (ROUSE et al., 1974). Essa tecnologia se baseia na

captação da energia eletromagnética refletida ou emitida pelos alvos terrestres, o que possibilita identificar diferenças de comportamento espectral relacionadas ao estado fisiológico das plantas, à cobertura vegetal e à umidade do solo (GITELSON; MERZLYAK, 1996).

A aplicação de imagens orbitais na agricultura se consolidou nas últimas décadas com o avanço dos sensores de alta resolução espacial e temporal, como os das plataformas Landsat 8, Sentinel-2 e PlanetScope. Estes fornecem bandas espectrais na faixa do visível, infravermelho próximo (NIR) e borda vermelha (Red Edge), fundamentais para a análise de variáveis biofísicas (Lin et al., 2023).

Entre as principais métricas extraídas de imagens multiespectrais estão os índices de vegetação (IVs), que combinam diferentes bandas espectrais para realçar características da vegetação, como biomassa e teor de clorofila. Os índices mais utilizados incluem o NDVI (Normalized Difference Vegetation Index), SAVI (Soil Adjusted Vegetation Index), EVI (Enhanced Vegetation Index) e NDRE (Normalized Difference Red Edge), cada um com sensibilidade diferenciada à densidade foliar e interferência do solo (HUETE, 1988; GITELSON, 2003).

Estudos recentes demonstram a eficácia dos índices espectrais no monitoramento da cultura da batata, especialmente na predição da produtividade. Tedesco et al. (2021) verificaram que índices derivados do infravermelho próximo (NIR) apresentam forte correlação com biomassa e rendimento em batata-doce. Salvador et al. (2020) reforçam que o uso de imagens de alta resolução, como as da constelação PlanetScope, permite identificar variações sutis de vigor e prever a produtividade da cultura com elevada precisão.

Os IVs também são ferramentas essenciais na avaliação de estresses hídricos e nutricionais, permitindo a tomada de decisões antecipadas no manejo agrícola. Assim, o sensoriamento remoto não apenas viabiliza o acompanhamento da dinâmica temporal das culturas, mas também fornece a base de dados indispensável para a integração com técnicas de modelagem preditiva e aprendizado de máquina.

### **3.4 Modelagem preditiva em agricultura e Redes Neurais Artificiais (RNA)**

A modelagem preditiva tem assumido papel central na agricultura moderna, permitindo transformar grandes volumes de dados em informações aplicáveis ao manejo e à tomada de decisão. Inicialmente, as predições de produtividade eram realizadas por modelos lineares simples, que apresentavam limitações diante da complexidade e da não linearidade das

interações entre variáveis agronômicas e ambientais (Van Klompenburg; Kassahun; Sikma, 2020).

Com o avanço da inteligência artificial, as Redes Neurais Artificiais (RNA) surgiram como uma alternativa robusta para lidar com dados complexos e não lineares. Inspiradas no funcionamento do cérebro humano, as RNAs são compostas por camadas interconectadas de neurônios artificiais, capazes de aprender e generalizar padrões a partir de exemplos (HAYKIN, 1999). Entre as principais arquiteturas utilizadas na agricultura destacam-se a Multilayer Perceptron (MLP) e a Radial Basis Function (RBF), ambas com grande aplicabilidade em problemas de predição e classificação.

Kamilaris e Prenafeta-Boldú (2018) ressaltam que a aplicação de RNAs na agricultura vem crescendo devido à sua capacidade de integrar dados heterogêneos, como informações espectrais, meteorológicas e de solo. No caso da cultura da batata, essas redes têm sido utilizadas para prever produtividade com base em índices de vegetação e variáveis meteorológicas, apresentando resultados mais consistentes que métodos estatísticos convencionais (KUREK et al., 2023; Kulyal, Malika & Saxena, Parul. 2024).

Estudos realizados por Gómez et al. (2019) demonstram que a combinação de dados multitemporais de sensoriamento remoto com modelos de RNA é capaz de antecipar a produtividade da batata em até 30 dias antes da colheita. Tais modelos alcançam altos coeficientes de determinação ( $R^2 > 0,85$ ) e baixos erros médios absolutos ( $MAE < 4 \text{ t ha}^{-1}$ ), evidenciando o potencial dessa abordagem. Além disso, modelos RBF apresentam melhor estabilidade e velocidade de treinamento, enquanto as redes MLP oferecem maior capacidade de ajuste em conjuntos de dados complexos (HAYKIN, 1999).

Dessa forma, a modelagem preditiva baseada em inteligência artificial representa um avanço significativo para a agricultura de precisão, pois permite antecipar resultados, otimizar o planejamento e aumentar a eficiência operacional.

### **3.5 Integração entre sensoriamento remoto e inteligência artificial**

A integração entre o sensoriamento remoto e a inteligência artificial representa o estágio mais avançado da agricultura digital contemporânea. Essa combinação alia a capacidade observacional das imagens orbitais à capacidade analítica dos modelos de aprendizado de máquina, resultando em sistemas preditivos altamente precisos e escaláveis (Kulyal, Malika & Saxena, Parul, 2024).

De acordo com Kurek et al. (2023), a fusão de dados espectrais e temporais provenientes de satélites, drones e sensores de campo tem permitido a criação de modelos dinâmicos capazes

de identificar padrões fenológicos, detectar anomalias e prever a produtividade de diferentes culturas agrícolas. Essa abordagem é especialmente útil para a batata, cuja produtividade depende de pequenas variações ambientais ao longo do ciclo.

Estudos recentes indicam que modelos baseados em deep learning e redes convolucionais (CNNs) têm alcançado resultados promissores na detecção automática de doenças, predição de área foliar e mapeamento de produtividade (Lin et al., 2023). A combinação de dados multiespectrais com aprendizado supervisionado permite que sistemas inteligentes ajustem automaticamente os parâmetros de previsão conforme as mudanças climáticas e de manejo (NOSRATABADI et al., 2020).

Além disso, o avanço das plataformas de Agricultura 5.0, que integram big data, computação em nuvem e inteligência artificial, tem ampliado o acesso a ferramentas analíticas para pequenos e médios produtores, democratizando o uso da tecnologia no campo (GAMAGE et al., 2024). Nesse contexto, o sensoriamento remoto, aliado às RNAs, consolida-se como uma estratégia eficiente e sustentável para o monitoramento e a gestão agrícola, contribuindo para o aumento da produtividade e a redução dos impactos ambientais.

## 4 METODOLOGIA

### 4.1 Caracterização do Local de Estudo

O experimento foi conduzido em área agrícola comercial localizada no município de Porto Ferreira – SP, pertencente à região centro-leste do estado de São Paulo.

O cultivo foi implantado em área total de aproximadamente 15 hectares, situada sob as coordenadas centrais 21°52'24.83" de latitude Sul e 47°24'10.00" de longitude Oeste, com altitude de 560 metros (Figura 1).



Figura 1. Área experimental: Porto Ferreira, SP.

De acordo com a classificação climática de Köppen-Geiger, o clima da região é do tipo Cwa, caracterizado como tropical úmido com inverno seco e verão chuvoso. A precipitação média anual é de aproximadamente 1297 mm, e a temperatura média anual situa-se em torno de 22 °C, condições típicas de regiões produtoras de batata no interior paulista. O relevo é suave ondulado, e o solo predominante na área experimental é classificado como Latossolo Vermelho eutroférico, de textura média a argilosa, bem drenado e com boa capacidade de retenção de água características adequadas para o cultivo da cultura.

A cultivar utilizada foi Orchestra, de origem holandesa, com um ciclo de 100 a 120 dias, amplamente adotada em sistemas intensivos de produção pela elevada qualidade dos tubérculos e estabilidade produtiva (Figura 2). O plantio foi realizado em maio de 2025, sob sistema mecanizado, com espaçamento médio de 0,75 m entre linhas. O manejo seguiu o padrão técnico da propriedade, incluindo adubação de base com formulação NPK 06-21-12, aplicações de cobertura e controle fitossanitário periódico, além de irrigação por aspersão convencional, conduzida conforme as necessidades hídricas da cultura. A colheita ocorreu em agosto de 2025, ao final do ciclo fisiológico, quando as plantas apresentavam senescência completa.




Figura 2. Batata Orchestra em seu estágio vegetativo e colheita.

#### 4.2 Variáveis de Campo

Foram definidos 80 pontos amostrais espaçados em 25 metros, georreferenciados distribuídos ao longo da lavoura (Figura 3). Em cada ponto, a produtividade real foi determinada por colheita manual em quadros de 2 m<sup>2</sup> (Figura 4a), seguida de pesagem em balança de precisão e conversão dos valores para toneladas por hectare (t ha<sup>-1</sup>) (Figura 4b). Esses dados constituíram a variável dependente utilizada no treinamento e teste dos modelos preditivos de produtividade.



Figura 3. 80 pontos amostrais.



(a)



(b)

Figura 4. a) Coleta; b) Pesagem.

### 4.3 Dados espectrais e Índices de vegetação

O monitoramento espectral da cultura foi realizado a partir de imagens orbitais da constelação PlanetScope, cuja resolução espacial é de aproximadamente 3 metros. Além disso, a localização dos pontos foi georreferenciada com auxílio de receptores GNSS de alta precisão, associados a aeronave remotamente pilotada (ARP), um drone multirrotor multiespectral DJI P4 (Figura 5). Foram utilizadas sete datas de aquisição, correspondentes a 30, 38, 48, 57, 70, 78 e 85 dias após o plantio (DAP). As imagens foram selecionadas com base na menor interferência de nuvens e processadas para o recorte da área de estudo.




Figura 5. Equipamentos utilizados para aquisição das imagens: a) PhantomP4; b) base RTK.

As bandas espectrais utilizadas compreenderam o azul costeiro (B1), azul (B2), verde I (B3), verde (B4), amarelo (B5), vermelho (B6), borda vermelha (B7) e NIR (B8). As cenas foram recortadas com base no polígono da área experimental e sobrepostas aos pontos amostrais (com buffer de 3 metros de raio) para posterior extração dos valores espectrais e cálculo dos índices de vegetação.

A utilização combinada de múltiplos IVs buscou reduzir limitações individuais de cada índice, explorando diferentes regiões do espectro eletromagnético para capturar variações relacionadas tanto à fisiologia da planta quanto às condições do solo (GITELSON et al., 2003; TEDESCO et al., 2021). Dessa forma, os dados extraídos e organizados via QGIS constituíram a base para a etapa posterior de calibração e validação dos modelos de redes neurais artificiais.

Neste trabalho foram utilizados os IVs apresentados na Tabela 1, por se tratarem de índices amplamente encontrados na literatura para análises em cultura subterrâneas como batata-doce e amendoim (Tedesco et al., 2021) e (Souza et al., 2023).

Tabela 1. Índices de vegetação usados neste estudo.

IV	Região da banda	Equação
NDVI	Índice de vegetação por diferença normalizada	$\frac{NIR - Red}{NIR + RED}$

NDRE	Índice da borda do vermelho por diferença normalizada	$\frac{NIR - RedEdge}{NIR + RedEdge}$
SR	Índice da Simples Razão (Simple Ratio)	$\frac{NIR}{RED}$
GNDVI	Índice de atividade verde	$\frac{NIR - Green}{NIR + Green}$
SAVI	Índice de vegetação ajustado ao solo *	$\frac{(1 + L)(NIR - RED)}{(L + NIR + RED)}$
EVI	Índice de vegetação melhorado*	$\frac{G(NIR - RED)}{(L + NIR + C1RED - C2Blue)}$

Fonte: Rouse et al. (1974); Gitelson (2003); Jordan (1969); Gitelson e Merzlyak (1996); Huete (1988); Justice et al. (1998). \* L=0,5; G= 2,5, C1=6, C2= 7,5.

#### 4.4 Análise descritiva

Os dados referentes a cultivar foram submetidos a procedimentos de análise descritiva, com o intuito de fornecer uma visão geral de seu comportamento estatístico. Nessa etapa, os valores foram tratados como independentes, sem considerar o efeito da posição das parcelas ou da localização dos pontos de amostragem. Conforme destacado por Vieira et al. (2002), a utilização de parâmetros como média, variância, coeficiente de variação, assimetria e curtose possibilita uma interpretação abrangente da distribuição dos dados. A análise foi conduzida no software Minitab 15, contemplando o cálculo de média, desvio-padrão, amplitude, assimetria, curtose, coeficiente de variação e o teste de normalidade de Anderson–Darling. Este último foi empregado para verificar a aderência dos dados à distribuição normal, por meio da comparação entre os pontos observados e a reta de probabilidade, garantindo maior rigor às conclusões (ESPINOSA et al., 2004).

#### 4.4 Redes Neurais Artificiais para predição da produtividade da batata

Com o objetivo de prever a produtividade da cultivar Orchestra a partir dos índices de vegetação calculados, foram utilizados modelos de Redes Neurais Artificiais (RNA's). Esse tipo de abordagem computacional busca simular, de forma matemática, a capacidade de aprendizado e reconhecimento de padrões dos neurônios biológicos, permitindo estabelecer

relações não lineares entre variáveis de entrada e saída (Jiang et al., 2004; SAVEGNAGO et al., 2011; SOARES et al., 2015).

No presente estudo, foram aplicadas duas arquiteturas: a rede Perceptron Multicamadas (MLP) e a rede de Função de Base Radial (RBF). Ambas foram implementadas no software STATISTICA® 7.0, utilizando o módulo Neural Networks.

Para as redes MLP, o treinamento foi conduzido pelo algoritmo de retropropagação do erro (backpropagation), com otimização dos parâmetros de arquitetura e de treinamento pelo recurso Intelligent Problem Solver (IPS) do STATISTICA. Essa ferramenta permitiu testar automaticamente diferentes combinações de número de neurônios, camadas ocultas e funções de ativação, assegurando maior eficiência na definição da topologia da rede.

As redes RBF, por sua vez, foram estruturadas com uma camada oculta composta por funções de base radial, com ativação gaussiana. Esse modelo é reconhecido pela maior robustez frente a ruídos e pela rapidez no processo de treinamento (HAYKIN, 1999). No caso da Orchestra, os parâmetros de suavização e o número de neurônios da camada oculta foram definidos também pelo IPS, garantindo uniformidade metodológica entre os modelos testados.

O banco de dados foi dividido em 70% para treinamento e 30% para validação, e as variáveis de entrada foram compostas pelos índices de vegetação calculados nas sete datas de avaliação (30 a 85 DAP). Como variável de saída, foi considerada a produtividade estimada em toneladas por hectare.

A avaliação de desempenho dos modelos foi realizada por meio do Erro Médio Absoluto (MAE). Adicionalmente, foi conduzida uma análise de sensibilidade para identificar os índices espectrais que mais contribuíram para a predição, possibilitando compreender o peso relativo de cada variável no desempenho final da rede.

As avaliações em termo de acurácia foram realizadas pelo cálculo do erro médio absoluto (MAE), e estão representadas pela Equação 1.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (1)$$

Em que,

$n$  é o número de dados,  $Y_i$  é o valor da variável observada, e,  $\hat{Y}_i$  é o valor da variável estimada pela rede.

Para responder qual o melhor modelo para predição da produtividade foi considerado o melhor aquele que apresentou o menor valor de MAE.

#### 4.4.1 Redes neurais Perceptron multicamadas (MLP)

As redes do tipo Perceptron Multicamadas (MLP) foram configuradas com uma camada de entrada composta pelas bandas espectrais e índices de vegetação obtidos, uma ou mais camadas ocultas e uma camada de saída representando a produtividade da cultura (Figura 6). A função de ativação utilizada foi a hiperbólica tangencial, amplamente empregada em problemas de regressão não linear. O número de neurônios utilizados foi de 1 a 20 para as redes MLP.




Figura 6. Arquitetura de uma rede neural perceptron multicamadas. Fonte: Fath et al. (2020)

Para geração dos modelos foram utilizadas todas as bandas das imagens orbitais acima mencionadas e os IVs (Tabela 1). Para evitar o risco de sobreajuste, foi estabelecida a divisão do banco de dados em conjuntos de treinamento (70%) e validação (30%), garantindo que as redes fossem avaliadas em situações independentes daquelas utilizadas no aprendizado. Os valores usados nas camadas de entrada foram normalizados de acordo com a Equação 2.

$$Y = \frac{x_i + X_{max}}{X_{max} - X_{min}} \quad (2)$$

Em que:

i é o valor do vetor de entrada (exemplo: bandas), x<sub>min</sub> é o mínimo valor, x<sub>max</sub> é o máximo valor observado.

O valor de saída de cada neurônio na cama k é expresso por y<sub>k</sub>= g(a<sub>k</sub>) em que g é a função de ativação de a<sub>k</sub> e a<sub>k</sub> é a função sináptica, a qual é uma combinação linear dos valores de entrada normalizada e os pesos sinápticos como mostrado na Equação 3.

$$ak = \sum_j y_j w_{kj} \quad (3)$$

Em que:

$w_{kj}$  são os pesos sinápticos ligando os  $y_j$  valores de entrada com cada  $k$  neurônio.

A transferência ou função de ativação nos neurônios de cada camada foi a função hiperbólica Equação 4.

$$g(ak) = \frac{e^{ak} - e^{-ak}}{e^{ak} + e^{-ak}} \quad (4)$$

#### 4.4.2 Redes neurais de função de ativação de base radial (RBF)

As redes RBF são compostas por três níveis principais: a camada de entrada, uma camada oculta responsável por realizar a transformação não linear dos dados e a camada de saída, de natureza linear, que gera a resposta final a partir dos padrões processados na etapa intermediária (Figura 7). A definição de sua topologia exige a configuração de alguns parâmetros, em menor número quando comparada às redes MLP. Para este tipo de rede, é necessário estabelecer apenas o algoritmo de treinamento e o parâmetro de suavização (smoothing factor), ambos determinados automaticamente pela ferramenta IPS do software STATISTICA.

O modelo RBF destaca-se por sua elevada tolerância a ruídos e pela eficiência do treinamento, que ocorre de maneira rápida e abrangente. Embora compartilhem a estrutura multicamadas com as redes MLP, diferenciam-se pela função de ativação utilizada: no lugar da função sigmoide tradicional, a RBF emprega funções radiais cujo valor depende da distância em relação a um centro definido. Neste estudo, adotou-se a função Gaussiana (Equação 5) como base para a ativação dos neurônios da camada oculta, conforme descrito por Haykin (1999).




Figura 7. Arquitetura de uma rede neural de função de base radial. Fonte: Fath et al. (2020)

$$\Phi = \exp\left(-\frac{v^2}{2\sigma^2}\right) \quad (5)$$

Em que,

$n = \|x - \mu\|$ , é a distância Euclidiana entre o vetor de entrada e o centro  $\mu$  da função Gaussiana, e,

$\sigma$  é a largura. A distância Euclidiana do vetor de entrada para o centro  $\mu$  é a entrada para função Gaussiana, a qual fornece o valor de ativação da unidade radial.

## 5 RESULTADOS

### 5.1 Análise descritiva dos dados

Os dados foram tabulados e analisados por meio da estatística descritiva (Tabela 2) e gráfico de Probabilidade Normal (Figura 8), que nos permitiu observar algumas variações da produtividade.

A variável produtividade real da cultivar *Orchestra* apresentou comportamento estatístico consistente com os pressupostos de normalidade, indicando homogeneidade adequada para as análises posteriores. O teste de Anderson–Darling resultou em valor de  $p = 0,598$ , não rejeitando a hipótese nula de normalidade ao nível de 5% de significância. Esse resultado é reforçado pela inspeção visual do gráfico de probabilidade normal, que demonstrou alinhamento satisfatório dos pontos em relação à reta teórica, evidenciando ausência de caudas alongadas e de valores discrepantes significativos. A distribuição unimodal e simétrica da variável confirma a representatividade da amostra, garantindo que os dados obtidos retratem adequadamente o comportamento produtivo da lavoura sob as condições analisadas.

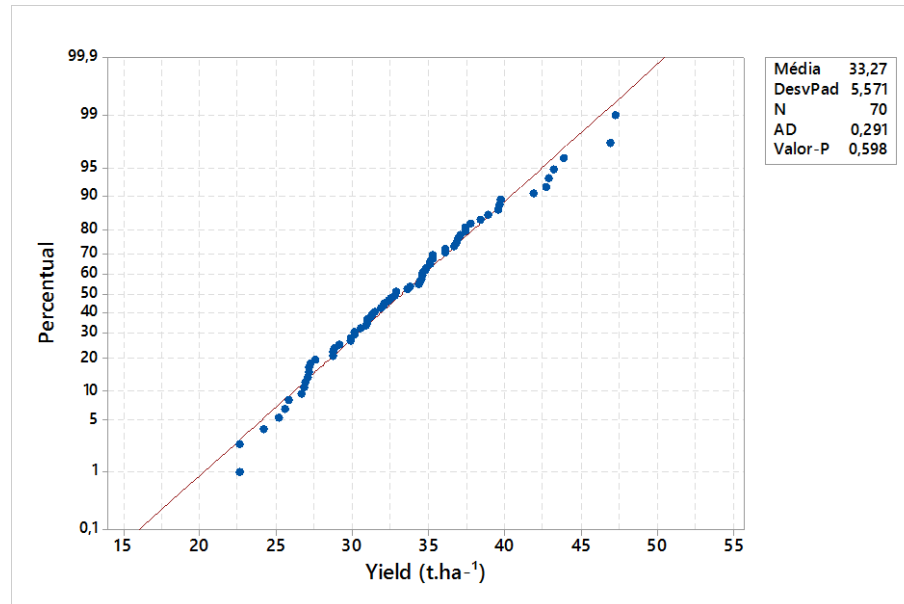


Figura 8. Gráfico de Probabilidade Normal

A produtividade média observada foi de 33,27 t ha<sup>-1</sup>, com desvio-padrão de 5,57 t ha<sup>-1</sup> e coeficiente de variação (CV) de 16,75%, valor considerado de magnitude moderada para experimentos agrícolas realizados em campo comercial. Esse nível de dispersão indica variação natural entre os pontos amostrados, associada às diferenças de fertilidade, umidade do solo, relevo e eficiência local de manejo, porém sem comprometer a representatividade da amostra. Em experimentos agrônômicos, valores de CV inferiores a 20% são geralmente interpretados como indicativos de homogeneidade experimental satisfatória, permitindo inferências estatísticas robustas (Gomes 2009).

TABELA 2. Estatística descritiva para as variáveis relacionadas à produtividade, em t ha<sup>-1</sup>.

Variável	Média	Ep Média	DesvPad	Mínimo	Q1
Prod (t.ha <sup>-1</sup> )	33,27	0,666	5,571	22,56	29,05
Variável	Mediana	Q3	Máximo	Curtose	Assimetria
Prod (t.ha <sup>-1</sup> )	32,80	36,85	47,22	-0,12	0,37

Q1: primeiro quartil; Q3 terceiro quartil.

A ausência de assimetrias acentuadas e de curtose excessiva na distribuição dos dados confirma o comportamento aproximadamente normal da variável produtividade, o que viabiliza o uso de medidas paramétricas de tendência central e dispersão. Com base na amostragem de 80 pontos georreferenciados, o erro-padrão da média foi reduzido, resultando em um intervalo

de confiança de 95% estimado entre 32,03 e 34,51 t ha<sup>-1</sup>. Esse intervalo relativamente estreito demonstra a precisão da média amostral e reforça a confiabilidade dos dados obtidos.

A análise conjunta das medidas de posição e dispersão evidencia que a lavoura apresentou desempenho produtivo elevado e consistente, refletindo o adequado manejo agrônomico empregado durante a safra. A produtividade média de 33,27 t ha<sup>-1</sup> está em conformidade com os valores relatados por estudos recentes conduzidos em sistemas intensivos de cultivo de batata no estado de São Paulo, cujos rendimentos médios variam entre 30 e 35 t ha<sup>-1</sup> (CONAB, 2025). O coeficiente de variação, expressa pelo CV de 16,75%, é desejável do ponto de vista analítico, pois fornece amplitude suficiente para que os modelos de predição identifiquem padrões espectrais e relações significativas entre as variáveis explicativas e a produtividade real.

A distribuição normal, a ausência de outliers e a coerência estatística dos dados garantem estabilidade aos modelos de aprendizado de máquina utilizados nas etapas posteriores deste estudo. Dessa forma, a base amostral apresenta características adequadas tanto para o ajuste das redes neurais artificiais quanto para a validação cruzada dos resultados, assegurando confiabilidade às interpretações e às comparações realizadas entre arquiteturas.

## 5.2 Acurácia dos modelos

A avaliação da acurácia dos modelos foi realizada com base no Erro Médio Absoluto (MAE, em t ha<sup>-1</sup>), calculado sobre o conjunto de validação (30% dos dados) para cada uma das sete datas de aquisição de imagens. Essa estratégia permite comparar, de forma isonômica, o desempenho das arquiteturas MLP (Multilayer Perceptron) e RBF (Radial Basis Function) ao longo do ciclo fenológico, bem como identificar a janela temporal de maior previsibilidade da produtividade. Em todos os cenários, manteve-se a mesma base amostral, o mesmo procedimento de pré-processamento espectral e a mesma regra de separação treino/validação, de modo que as diferenças observadas são atribuíveis às arquiteturas e às datas avaliadas, e não a variações no desenho experimental.

Os resultados indicam contrastes nítidos entre as arquiteturas e entre as fases do ciclo. De forma geral, a RBF apresentou menores valores de MAE e maior estabilidade temporal quando comparada à MLP. Na RBF, os erros oscilaram entre 2,63 e 4,15 t ha<sup>-1</sup> (Figura 9), com os melhores desempenhos concentrados entre 48 e 70 DAP, período que corresponde ao auge do vigor do dossel. Nessa janela, a estrutura foliar encontra-se estabelecida e a reflectância no red-edge e no NIR traduz, com maior fidelidade, atributos biofísicos diretamente relacionados ao rendimento (área foliar, biomassa e status de clorofila), o que aumenta a relação sinal-ruído e

favorece a discriminação das variações produtivas. Nas datas mais precoces (30–38 DAP) e tardias (78–85 DAP), observou-se incremento do erro, coerente com a maior influência de fatores externos ao acúmulo produtivo, no início, o contraste solo-planta e o fechamento incompleto do dossel; no final, a senescência e a perda de atividade fotossintética.




Figura 9. Gráfico de bolhas com o valor de MAE ( $t \cdot ha^{-1}$ ) para RBF.

A MLP, por sua vez, apresentou MAE entre 5,29 e 8,48  $t \cdot ha^{-1}$  (Figura 10), com maior sensibilidade à data de aquisição e maior variância entre execuções. Ainda que parte dessa oscilação seja esperada em modelos paramétricos com muitas conexões treináveis, a diferença de desempenho em relação à RBF sugere que, para este conjunto de dados, a colinearidade entre bandas e índices e a dimensionalidade efetiva das entradas favoreceram uma arquitetura de base radial, cuja função de ativação local tende a estabilizar o aprendizado em cenários com redundância espectral. Em termos práticos, a MLP capturou tendências gerais de produtividade, mas com erro relativo médio superior a 15% da média amostral, o que reduz seu poder discriminativo para decisões operacionais mais finas (por exemplo, segregação de talhões por classes estreitas de rendimento ou definição de escalas de colheita muito granulares).




Figura 10. Gráfico de bolhas com o valor de MAE para MLP.

A consistência temporal é um ponto central para interpretação. Ao longo das sete datas, a RBF manteve um bom desempenho no meio do ciclo (48–70 DAP), com variações de MAE pequenas entre essas datas adjacentes, o que é desejável do ponto de vista operacional: ainda que uma imagem seja parcialmente comprometida por nuvens ou ângulo solar, outra imagem próxima, dentro da mesma janela fenológica, tende a produzir previsões equivalentes. Na MLP, observou-se maior heterogeneidade entre datas, sobretudo quando as entradas incorporam índices fortemente correlacionados; pequenos desvios na composição das variáveis de entrada se traduziram em redistribuição de pesos e, por consequência, em flutuações de erro entre execuções. Essa diferença de comportamento é compatível com a literatura que descreve RBF como mais tolerante a ruído de entrada e MLP como mais sensível à escolha de hiperparâmetros e à regularização em conjuntos com correlações internas elevadas.

Do ponto de vista agrônomo, a janela 48–70 DAP configura-se como um período de informações dominantes, pois coincide com o pico fisiológico do dossel. Nesse intervalo, índices que exploram a região do red-edge (transição entre o vermelho e o NIR) e o próprio NIR maximizam a sensibilidade à variação do conteúdo de clorofila e à estrutura do dossel, atributos intimamente ligados ao potencial de produção de fotoassimilados e ao enchimento de tubérculos. O fato de a menor faixa de MAE da RBF concentrar-se nesse período reforça que o sinal espectral é mais impactante e que o modelo consegue separar áreas de menor e maior produtividade com maior robustez. Já nas fases iniciais e finais, a informação espectral está mais contaminada por efeitos de solo exposto, geometria do dossel ainda em formação e

processos de senescência, que têm relação indireta com o rendimento final, reduzindo a capacidade preditiva de ambas as arquiteturas, ainda que em magnitudes distintas.

Quando os erros são interpretados em termos relativos à média amostral de 33,27 t ha<sup>-1</sup>, a RBF frequentemente se mantém entre 8% e 12%, patamar que já permite antecipação confiável de produtividade para planejamento de colheita, logística e contratos. Em contrapartida, a MLP permanece majoritariamente acima de 15%, o que, embora útil como indicador de tendência, é menos adequado para decisões que exijam classificação por faixas estreitas de rendimento. É importante salientar que, como as avaliações foram conduzidas sobre o conjunto de validação e repetidas por data, as conclusões sobre desempenho não decorrem de sobreajuste pontual, mas de um padrão consistente observado ao longo das sete aquisições.

Em síntese, os resultados demonstram que, para a safra e a cultivar analisadas, a arquitetura RBF é mais adequada a predição da produtividade a partir de variáveis espectrais multitemporais, por combinar menor MAE, maior estabilidade entre datas e coerência fisiológica com a janela de maior vigor do dossel. A MLP apresentou desempenho inferior e mais variável, o que não invalida seu uso, mas sugere a necessidade de maior esforço de regularização e seleção de variáveis, por exemplo, redução de colinearidade via seleção de índices ou projeções, para alcançar níveis de erro comparáveis aos da RBF. Esses achados orientam a etapa seguinte deste trabalho, dedicada à análise de sensibilidade, em que se investiga a contribuição relativa de bandas e índices em cada fase do ciclo, buscando alinhar a interpretação espectral com a fisiologia da cultura e, eventualmente, reduzir o espaço de características para arquiteturas mais sensíveis à redundância das entradas.

### **5.3 Análise de sensibilidade**

A análise de sensibilidade teve como objetivo identificar quais bandas e índices espectrais exerceram maior influência sobre o desempenho dos modelos de predição de produtividade. Essa etapa foi essencial para compreender a relação fisiológica entre os parâmetros espectrais e o desenvolvimento da cultura, além de fornecer elementos interpretativos sobre o comportamento das redes neurais durante o processo de aprendizado. A abordagem utilizada baseou-se na variação da magnitude dos pesos sinápticos de cada variável de entrada, permitindo quantificar a contribuição relativa de cada banda e índice na formação das predições geradas pelos modelos.

Os resultados demonstraram que a relevância das variáveis espectrais varia de acordo com a fase fenológica da cultura, refletindo as mudanças morfológicas e fisiológicas do dossel ao

longo do ciclo. Nos estágios iniciais, correspondentes a 30 e 38 dias após o plantio (DAP), as bandas azul e amarela apresentaram maior peso relativo nas predições. Esse comportamento está associado à maior sensibilidade dessas faixas ao conteúdo de pigmentos fotossintéticos iniciais e à presença de solo exposto, uma vez que o dossel ainda se encontra em fase de fechamento. Nessas datas, os índices de vegetação baseados em bandas visíveis mostraram maior variabilidade, refletindo as diferenças de emergência e estabelecimento das plantas nas distintas microcondições da área.

À medida que o cultivo evolui para a fase de crescimento vegetativo pleno, entre 48 e 70 DAP, observa-se uma mudança substancial na importância das variáveis espectrais. Nesse intervalo, as bandas da borda vermelha e do infravermelho próximo (NIR) passam a dominar as predições, sendo responsáveis por mais de 60% da variância explicada nos modelos. Essa predominância decorre do fato de que o aumento da área foliar e da densidade do dossel intensifica a refletância na faixa do NIR, ao mesmo tempo em que reduz a refletância na faixa do vermelho. A borda vermelha, por sua vez, apresenta alta correlação com o teor de clorofila e o índice de área foliar (IAF), variáveis diretamente relacionadas à taxa fotossintética e, conseqüentemente, à produtividade final (GITELSON; MERZLYAK, 1996; HUETE, 1988). Essa fase representa, portanto, o ponto de maior eficiência espectral do ciclo, e corresponde ao período em que os modelos obtiveram os menores valores de erro médio absoluto (MAE), conforme observado anteriormente.

Nos estágios finais do ciclo, entre 78 e 85 DAP, ocorre uma inversão parcial na importância relativa das variáveis. As bandas verde e vermelha voltam a ganhar relevância, refletindo a degradação dos pigmentos fotossintéticos e a senescência natural das plantas. O enfraquecimento da refletância na faixa do NIR e a redução do contraste entre o dossel e o solo tornam as variáveis espectrais menos eficazes na diferenciação produtiva. Conseqüentemente, os modelos apresentaram aumento gradual no MAE nessa fase, comportamento coerente com a perda de vigor fisiológico observada na cultura.

Comparando-se as duas arquiteturas, nota-se que a RBF apresentou padrão de sensibilidade mais estável entre as diferentes datas, com predominância das mesmas famílias espectrais ao longo das fases consecutivas (Tabela 2). Isso indica que a rede de base radial manteve coerência fisiológica nas relações entre variáveis de entrada e produtividade, sendo menos suscetível à colinearidade entre índices. A MLP, por outro lado, apresentou maior dispersão na importância relativa das variáveis, com redistribuição de pesos entre execuções e datas próximas. Essa instabilidade é atribuída à sua maior flexibilidade estrutural e à sensibilidade a pequenas variações nos dados de entrada, fenômeno amplamente reportado em modelagens

multiespectrais de culturas agrícolas (Kulyal, Malika & Saxena, Parul, 2024); KUREK et al., 2023).

Tabela 3. Análise de sensibilidade para as combinações com múltiplas entradas.

Entradas	RBF						
	30 DAP	38 DAP	48 DAP	57 DAP	70 DAP	78 DAP	85 DAP
B2	1	1	5	5	2		
B1*		2		3		9	2
B3	10		1	4		5	
B4	11	4	6			2	5
B5	2	5	3	7		1	
B6	5	6	4	6		3	
B7	12	3	2	1		8	6
B8*	9	8		2	1		
NDVI	6					6	
NDRE		9	7				7
SAVI	8	10				4	
EVI	4					7	1
SR	7		8				3
GNDVI	3	7					4

Entradas	MLP						
	30 DAP	38 DAP	48 DAP	57 DAP	70 DAP	78 DAP	85 DAP
B2		10	4			7	9
B1*	6	14		7	9	8	8
B3	7	12	5	3	4		7
B4	5	3	1		5	3	6
B5	2	4	8				
B6		9	2	2	3	6	3
B7		7	6	6	8	5	5
B8*	4	5			7	9	
NDVI		2	9		1		4
NDRE		1	7	5			
SAVI	3	11	3				
EVI		8		4	6	1	
SR	1	13	10	1	10	2	1
GNDVI		6	11		2	4	2

\* B1...B8= Bandas multiespectrais.

Os resultados da análise de sensibilidade confirmam a coerência fisiológica das relações espectrais captadas pelos modelos. As variáveis mais influentes, especialmente aquelas associadas às bandas red-edge e NIR, estão intimamente ligadas aos parâmetros biofísicos de interesse, como biomassa, teor de clorofila e estrutura do dossel, que determinam o potencial

produtivo da cultura. Essa convergência entre a interpretação espectral e o comportamento agrônomo reforça a confiabilidade dos modelos desenvolvidos, evidenciando que o aprendizado das redes não foi meramente empírico, mas sustentado por fundamentos fisiológicos consistentes.

De modo geral, a análise de sensibilidade demonstra que a janela temporal entre 48 e 70 DAP constitui o período mais informativo do ciclo, pois coincide com o máximo desenvolvimento vegetativo e o pico do sinal espectral relacionado à produtividade. A identificação dessa fase crítica é particularmente relevante do ponto de vista operacional, uma vez que permite direcionar o monitoramento e a aquisição de imagens para os momentos de maior previsibilidade. Além disso, o reconhecimento das variáveis espectrais mais relevantes fornece subsídios para o aprimoramento futuro dos modelos, seja pela seleção otimizada de índices de vegetação, seja pela redução do número de variáveis redundantes, o que tende a diminuir o tempo de processamento e aumentar a estabilidade das previsões em aplicações práticas.

## 6 DISCUSSÃO

### 6.1 Análise descritiva das variáveis

A produtividade média observada para a cultivar *Orchestra* (33,27 t ha<sup>-1</sup>) encontra-se dentro do intervalo reportado em estudos conduzidos sob condições semelhantes de clima e manejo em regiões produtoras do estado de São Paulo. Embrapa Hortaliças, (2022) verificou rendimentos médios entre 30 e 36 t ha<sup>-1</sup> em áreas irrigadas de batata no município de Itapetininga. Esses resultados demonstram que o desempenho produtivo obtido neste estudo é representativo e condizente com a realidade da cultura em sistemas intensivos de produção.

O coeficiente de variação (CV = 16,75%) é outro aspecto que reforça a consistência da base experimental. Em estudos de sensoriamento remoto aplicados a culturas agrícolas, coeficientes de variação entre 15 e 25% são comuns e indicam heterogeneidade suficiente para capturar diferenças espectrais relevantes sem comprometer a homogeneidade estatística (TEDESCO et al., 2021). Em experimentos conduzidos com batata-doce, Tedesco et al. (2021) observaram CV médio de 18%, enquanto Jennings et al. (2020) reportaram 20% para batata irrigada sob clima subtropical. Dessa forma, o valor encontrado neste trabalho garante uma amplitude adequada para que os modelos de predição possam discriminar níveis de produtividade com base em diferenças reais no vigor vegetativo e na estrutura do dossel.

O padrão de normalidade dos dados produtivos ( $p = 0,598$ ) também foi consistente com relatos anteriores. Vieira et al. (2002) e Espinosa et al. (2004) destacam que distribuições normais ou aproximadamente normais são desejáveis em estudos de variabilidade agrícola, pois reduzem a influência de outliers e aumentam a precisão das inferências paramétricas. Em trabalhos similares envolvendo culturas de batata e cana-de-açúcar, a normalidade foi observada em mais de 80% dos casos, o que permite utilizar métricas como média e desvio-padrão como descritores confiáveis da produtividade (NOSRATABADI et al., 2020).

Do ponto de vista agrônomo, os valores médios de produtividade obtidos refletem o bom manejo da cultura durante a safra avaliada. A adoção de irrigação controlada, o uso de cultivares modernas e a aplicação criteriosa de insumos contribuíram para minimizar a variabilidade decorrente de estresses hídricos e nutricionais. Isso indica que a variabilidade observada neste trabalho está mais associada a fatores microambientais, diferenças de fertilidade, compactação e relevo local, do que a deficiências de manejo, o que é um cenário ideal para a calibração de modelos espectrais.

Além disso, o nível produtivo alcançado corrobora dados de trabalhos internacionais realizados em condições de clima temperado. Kurek et al. (2023), ao modelarem a produtividade de batata na Polônia utilizando redes neurais e dados de sensoriamento remoto, reportaram médias entre 31 e 35 t ha<sup>-1</sup>, valores praticamente equivalentes aos obtidos neste estudo. Tatsumi e Usami (2024), no Japão, reportaram produtividades médias próximas de 33 t ha<sup>-1</sup>, com coeficiente de variação em torno de 17%, reforçando a consistência dos resultados obtidos neste estudo e demonstrando o potencial do uso de imagens multiespectrais de UAV associadas a técnicas de aprendizado de máquina na predição da produtividade da batata.

Portanto, a análise descritiva da produtividade evidencia não apenas a qualidade e representatividade da base experimental, mas também a adequação das condições agrônomicas e metodológicas empregadas. A coerência entre os resultados observados e aqueles reportados na literatura nacional e internacional reforça a validade externa do estudo e garante que as análises subsequentes de modelagem e sensibilidade sejam realizadas sobre um conjunto de dados sólido e comparável a outras pesquisas científicas recentes.

## **6.2 Acurácia dos modelos**

O desempenho das redes neurais artificiais (RNAs) no processo de predição da produtividade da cultura da batata apresentou resultados expressivos e coerentes com o comportamento fisiológico da planta ao longo do ciclo. As análises realizadas indicaram que as

redes do tipo RBF (Radial Basis Function) superaram as MLP (Multilayer Perceptron) tanto em termos de acurácia quanto de estabilidade temporal, apresentando valores de MAE entre 2,63 e 4,15 t ha<sup>-1</sup>, enquanto as MLP variaram entre 5,29 e 8,48 t ha<sup>-1</sup>. Esses valores correspondem, respectivamente, a erros relativos de 8–12% e 15–25% da média amostral, o que demonstra a maior capacidade das RBF em capturar as relações não lineares entre as variáveis espectrais e a produtividade real.

Kurek et al. (2023) também observaram desempenho superior de modelos RBF em relação às MLP ao trabalharem com séries temporais de imagens para batata na Polônia, destacando que a RBF tende a apresentar menor variância de erro entre datas por empregar funções de ativação locais, o que reduz a sensibilidade ao ruído espectral e à colinearidade entre variáveis. Essa característica explica o comportamento mais estável das RBF observadas neste trabalho, especialmente dentro da janela fenológica entre 48 e 70 DAP, onde a correlação entre vigor vegetativo e produtividade é maximizada.

A superioridade das RBF também é corroborada por estudos realizados com outras culturas. Kulyal, Malika & Saxena, Parul, (2024), ao revisarem 40 experimentos envolvendo técnicas de aprendizado de máquina aplicadas à previsão de produtividade agrícola, concluíram que modelos de base radial costumam superar as MLP em cenários com alta correlação entre entradas espectrais, por apresentarem menor suscetibilidade a sobreajuste e maior robustez em amostras pequenas. No presente estudo, essa tendência foi confirmada: as RBF apresentaram menores oscilações do erro entre datas consecutivas, comportamento considerado desejável para aplicações práticas de monitoramento, nas quais fatores ambientais, como cobertura de nuvens ou ângulo solar podem comprometer parcialmente uma ou mais aquisições.

A análise temporal do desempenho evidencia ainda que o período entre 48 e 70 dias após o plantio concentrou os melhores resultados, coincidindo com o pico de desenvolvimento vegetativo da cultura. Nesse intervalo, a estrutura foliar encontra-se plenamente desenvolvida, e a reflectância na região do infravermelho próximo (NIR) e da borda vermelha (red-edge) torna-se altamente sensível à variação do índice de área foliar (IAF) e ao teor de clorofila, parâmetros diretamente associados ao acúmulo de biomassa e, conseqüentemente, à produtividade final (HUETE, 1988; GITELSON; MERZLYAK, 1996). Essa relação entre resposta espectral e condição fisiológica da planta foi também relatada por Tatsumi e Usami (2024), que observaram desempenho máximo dos modelos de aprendizado de máquina na faixa de 50 a 70 DAP, período que denominam de *informational peak window* ou janela espectral de máxima informatividade.

Em contrapartida, nos estágios iniciais (30–38 DAP) e finais (78–85 DAP), os erros aumentaram substancialmente. Esse comportamento é explicado pela menor correlação entre os índices de vegetação e a produtividade nos momentos em que o dossel ainda está em expansão ou em processo de senescência. Tedesco et al. (2021) observou comportamento semelhante ao avaliarem índices espectrais batata-doce destacando que a precisão das predições tende a diminuir nas extremidades do ciclo devido à interferência do solo exposto e à degradação dos pigmentos fotossintéticos. Assim, o aumento do erro nas datas iniciais e finais encontrado neste trabalho é fisiologicamente coerente e reforça a importância da escolha adequada da janela temporal para modelagem.

Outro aspecto relevante diz respeito à magnitude do erro absoluto médio obtido. Os valores observados para a RBF (2,6–4,1 t ha<sup>-1</sup>) são comparáveis aos relatados por Kurek et al. (2023) e Gómez et al. (2019). Isso indica que, sob condições experimentais controladas e com homogeneidade moderada, as RBF podem atingir níveis de precisão operacional suficientes para a previsão antecipada da produtividade, com erros relativos inferiores a 10%. Essa acurácia é considerada adequada para aplicações em agricultura de precisão, como o planejamento da colheita e a definição de zonas de manejo (Kulyal, Malika & Saxena, Parul, 2024).

Além da acurácia, a robustez temporal observada nas RBF tem relevância prática. Em sistemas de monitoramento baseados em sensoriamento remoto, é comum que fatores como nebulosidade, ângulo solar e interferências atmosféricas limitem a disponibilidade de imagens. Modelos que mantêm desempenho estável entre datas próximas, como observado nas RBF, são mais adequados para integração operacional, pois permitem substituir aquisições comprometidas sem perda substancial de precisão. Essa característica é destacada também por Nosratabadi et al. (2020), que identificaram menor variabilidade do erro em redes de base radial aplicadas à previsão de rendimento de trigo sob condições meteorológicas variáveis.

Em síntese, os resultados obtidos neste trabalho estão em consonância com a literatura recente e confirmam a eficiência das redes neurais artificiais na previsão de produtividade agrícola a partir de dados espectrais multitemporais. A superioridade das RBF sobre as MLP, observada tanto na acurácia quanto na estabilidade, reforça a adequação desse tipo de arquitetura para o monitoramento da cultura da batata em sistemas de produção intensiva. Esses resultados também demonstram que a integração entre sensoriamento remoto e aprendizado de máquina é uma abordagem promissora para o desenvolvimento de ferramentas preditivas de apoio à tomada de decisão no campo, contribuindo para a consolidação da agricultura digital e de precisão.

### 6.3 Análise de sensibilidade

A análise de sensibilidade das variáveis espectrais, associada aos resultados obtidos pelos modelos de aprendizado de máquina, evidenciou padrões consistentes de resposta fisiológica da cultura ao longo do ciclo de desenvolvimento. Observou-se que os índices de vegetação (IVs) e bandas espectrais empregados apresentaram diferentes níveis de correlação com a produtividade, de acordo com a fase fenológica da batata. Essa variação está diretamente relacionada à dinâmica do crescimento do dossel, ao acúmulo de biomassa e às modificações na estrutura foliar, fatores que influenciam de forma direta a refletância nas regiões do visível, red-edge e infravermelho próximo (NIR).

Durante as fases iniciais do ciclo, compreendidas entre 30 e 38 dias após o plantio (DAP), os índices NDVI (Normalized Difference Vegetation Index) e SAVI (Soil Adjusted Vegetation Index) apresentaram sensibilidade intermediária em relação à produtividade, uma vez que a cultura ainda se encontrava em estágio de estabelecimento, com o dossel parcialmente fechado e presença significativa de solo exposto. O NDVI, amplamente utilizado em estudos de monitoramento agrícola, combina as bandas do vermelho e do infravermelho próximo, sendo eficiente em fases de crescimento vegetativo pleno (ROUSE et al., 1974). No entanto, em estágios iniciais, o sinal espectral é afetado pelo contraste entre solo e vegetação, resultando em menor capacidade discriminatória (HUETE, 1988). O SAVI, por sua vez, incorpora um fator de correção para o solo, ajustando a influência da reflectância do fundo e oferecendo desempenho superior nessas condições. Trabalho de Tedesco et al. (2021) reporta comportamento semelhante em culturas de batata-doce em que o SAVI apresentou maior correlação com a produtividade nas fases iniciais do ciclo, quando o dossel ainda não havia atingido fechamento completo.

À medida que o cultivo evolui para o pico vegetativo (48 a 85 DAP), observou-se aumento expressivo da importância de índices que incorporam a banda red-edge (NDRE) e o EVI (Enhanced Vegetation Index), além da própria refletância no NIR. O NDRE (Normalized Difference Red Edge Index) utiliza a região espectral intermediária entre o vermelho e o infravermelho próximo, sensível a variações no teor de clorofila e no índice de área foliar (GITELSON; MERZLYAK, 1996). Nesse período, o dossel já se encontra completamente formado, e pequenas diferenças na fisiologia das plantas relacionadas à nutrição nitrogenada, disponibilidade hídrica e eficiência fotossintética são refletidas em variações sutis na região da borda vermelha. Esse comportamento foi amplamente documentado por SALVADOR et al. (2020) e KUREK et al. (2023), que identificaram forte correlação entre o NDRE e a

produtividade em cultivares de batata sob diferentes manejos nutricionais. De modo semelhante, Gitelson e Merzlyak (1996) verificaram que índices que exploram a banda red-edge apresentam maior estabilidade temporal e precisão preditiva em comparação aos índices tradicionais baseados apenas no vermelho e NIR, destacando sua relevância para o monitoramento de culturas de ciclo curto.

O EVI, outro índice relevante nesta fase, mostrou boa sensibilidade ao vigor vegetativo, especialmente em áreas de alta densidade foliar. Diferentemente do NDVI, o EVI inclui correções atmosféricas e de saturação da banda do vermelho, tornando-se mais eficiente para detectar variações sutis em dosséis densos (HUETE et al., 2002). Essa característica foi observada neste estudo, em que o EVI apresentou comportamento estável e forte associação com a produtividade durante o auge do crescimento vegetativo, coincidindo com o período em que as redes neurais do tipo RBF alcançaram erros médios absolutos relevantes no final do ciclo. Esses resultados corroboram os achados de Gómez et al. (2019), que reportaram desempenho superior de modelos baseados em EVI e NDRE para previsão de produtividade de batata utilizando dados multitemporais de alta resolução.

Nos estágios finais do ciclo, entre 78 e 85 DAP, verificou-se redução da importância relativa das bandas do red-edge e do NIR, acompanhada do aumento da influência das bandas verde e vermelha. Essa mudança está associada à degradação dos pigmentos fotossintéticos e à senescência foliar, que reduzem a absorção de luz nas faixas do vermelho e do azul. O enfraquecimento da correlação entre índices de vegetação e produtividade nesse período é um comportamento amplamente descrito na literatura, refletindo o declínio fisiológico da planta e a perda de associação entre vigor vegetativo e rendimento potencial (TEDESCO et al., 2021; JENNINGS et al., 2020).

Comparando-se os resultados obtidos com estudos prévios, nota-se coerência com os padrões espectrais reportados em diferentes contextos de cultivo. Tedesco et al. (2021), em batata-doce, observou que a maior sensibilidade dos índices espectrais à produtividade ocorre na fase de máximo vigor vegetativo, com declínio na predição durante a senescência. Os achados do presente trabalho, portanto, alinham-se a essas evidências, confirmando que a janela espectral entre 48 e 70 DAP constitui o período de maior informatividade espectral e preditiva para a cultura da batata.

De forma geral, os resultados demonstram que a variabilidade da produtividade é explicada majoritariamente por variáveis espectrais ligadas ao vigor vegetativo e à atividade fotossintética, o que evidencia a forte dependência entre os parâmetros biofísicos captados pelos sensores e o desempenho agrônomo da cultura. A convergência entre os padrões observados

neste estudo e os relatados na literatura nacional e internacional reforça a confiabilidade das predições obtidas e comprova a robustez da integração entre sensoriamento remoto e aprendizado de máquina como ferramenta para o monitoramento e previsão de produtividade agrícola.

## 7 CONCLUSÃO

O presente estudo permitiu aprimorar o sistema de monitoramento remoto e reforçou o potencial do uso de sensoriamento remoto orbital aliado a redes neurais artificiais para a predição da produtividade da batata cultivar Orchestra. A análise descritiva dos dados de campo evidenciou produtividade média de 33,27 t ha<sup>-1</sup>, com variabilidade moderada e distribuição próxima da normalidade, o que conferiu robustez ao conjunto de informações utilizado no treinamento das redes.

Os modelos de RNA apresentaram desempenhos distintos. As redes RBF se destacaram por apresentar maiores acurácias, com erros médios absolutos variando entre 2,63 e 4,15 t ha<sup>-1</sup>, enquanto as redes MLP apresentaram erros mais elevados, entre 5,29 e 8,48 t ha<sup>-1</sup>, sobretudo nas fases iniciais da cultura. Além da superioridade quantitativa, as RBF também mostraram maior consistência na análise de sensibilidade, priorizando variáveis espectrais fisiologicamente relevantes em cada estágio fenológico, especialmente as bandas da borda vermelha e do NIR nos estágios de pleno desenvolvimento.

## 8 REFERÊNCIAS

CONAB – COMPANHIA NACIONAL DE ABASTECIMENTO. *Acompanhamento da safra brasileira de grãos: safra 2024/25, 1º levantamento*. Brasília, 2025.

EMBRAPA HORTALIÇAS. *Sistema de Produção da Batata – Região Sudeste*. Brasília: Embrapa Hortaliças, 2022. Disponível em: <https://www.embrapa.br/hortalicas>.

EMBRAPA HORTALIÇAS. Batata: doenças. Brasília, DF: Embrapa Hortaliças, [s.d.]. Disponível em: <https://www.embrapa.br/hortalicas/batata/doencas>

ESPINOSA, M. M.; CALIL JÚNIOR, C.; LAHR, F. A. R. Métodos paramétricos e não paramétricos para determinar o valor característico em resultados de ensaio de madeira. *Scientia Forestalis*, n. 66, p. 76–83, 2004.

FAO – FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS. *FAOSTAT Database: Crops and livestock products*. Rome: FAO, 2024. Disponível em: <https://www.fao.org/faostat>. Acesso em: 25 set. 2025.

GAMAGE, A., GANGAHAGEDARA, R., SUBASINGHE, S., GAMAGE, J., GURUGE, C., SENARATNE, S., RANDIKA, T., RATHNAYAKE, C., HAMEED, Z., MADHUJITH, T., MERAH, O. Advancing sustainability: the impact of emerging technologies in agriculture. *Curr. Plant Biol.* 40, 100420. 2024 <https://doi.org/10.1016/j.cpb.2024.100420>.

GITELSON, A. A. Remote estimation of leaf area index and green leaf biomass in maize canopies. *Geophysical Research Letters*, v. 30, n. 5, p. 1248, 2003.

GITELSON, A. A.; MERZLYAK, M. N. Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. *Journal of Plant Physiology*, v. 148, p. 494–500, 1996. [ScienceDirect](#)

GOMES, F. P. Curso de estatística experimental. 15. ed. Piracicaba: Degaspari, 2009. 468 p.

GÓMEZ, D.; SALVADOR, P.; SANZ, J.; CASANOVA, J. L. Potato yield prediction using machine learning techniques and Sentinel-2 data. *Remote Sensing*, v. 11, n. 15, p. 1745, 2019. DOI: 10.3390/rs11151745

HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2. ed. Upper Saddle River: Prentice Hall, 1999. [Google Livros+1](#)

HUETE, A. R. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, v. 25, p. 295–309, 1988. [ScienceDirect+1](#)

HUETE, A. R. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, v. 83, n. 1–2, p. 195–213, 2002.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. *Produção Agrícola Municipal – 2024*. Rio de Janeiro: IBGE, 2024. Disponível em: <https://www.ibge.gov.br>. Acesso em: 25 set. 2025.

JENNINGS, STEWART & KOEHLER, ANN-KRISTIN & NICKLIN, KATHRYN & DEVA, CHETAN & SAIT, STEVEN & CHALLINOR, ANDREW. (2020). Global Potato Yields Increase Under Climate Change With Adaptation and CO2 Fertilisation. *Frontiers in Sustainable Food Systems*. 4. 10.3389/fsufs.2020.519324.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: a survey. *Computers and Electronics in Agriculture*, v. 147, p. 70–90, 2018. (preprint disponível) [arXiv](#)

KULYAL, MALIKA & SAXENA, PARUL. (2024). Machine Learning approaches for Crop Yield Prediction: A Review.

KUMAR, LALIT & AHLAWAT, PRASHANT & RAJPUT, PRADEEP & NAVSARE, RAHUL & SINGH, PRADEEP. (2021). INTERNET OF THINGS (IOT) FOR SMART PRECISION FARMING AND AGRICULTURAL SYSTEMS PRODUCTIVITY: A

REVIEW. *International Journal of Engineering Applied Sciences and Technology*. 5. 10.33564/IJEAST.2021.v05i09.022.

KUREK, J. et al. Prediction of potato (*Solanum tuberosum* L.) yield based on machine learning methods. *Agriculture* (MDPI), v. 13, n. 12, 2259, 2023. [MDPI+1](#)

LIAKOS KG, BUSATO P, MOSHOU D, PEARSON S, BOCHTIS D. Machine Learning in Agriculture: A Review. *Sensors*. 2018; 18(8):2674. <https://doi.org/10.3390/s18082674>

LIN, Y. et al. Methodological evolution of potato yield prediction. *Frontiers in Plant Science*, v. 14, 1214006, 2023. [PMC](#)

NOSRATABADI, SAEED & FELDE, IMRE & SZÉLL, KÁROLY & ARDABILI, SINA & BESZEDES, BERTALAN & MOSAVI, AMIR. (2020). Hybrid Machine Learning Models for Crop Yield Prediction. 10.48550/arXiv.2005.04155.

ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. In: *Proceedings of the Third Earth Resources Technology Satellite Symposium*. Washington, D.C.: NASA, 1974. p. 309–317. [Servidor de Relatórios Técnicos da NASA+1](#)

SALVADOR, P. et al. Estimation of potato yield using satellite data at a municipal scale. *ISPRS International Journal of Geo-Information*, v. 9, n. 6, 343, 2020. [MDPI](#)

SISHODIA RP, RAY RL, SINGH SK. Applications of Remote Sensing in Precision Agriculture: A Review. *Remote Sensing*. 2020; 12(19):3136. <https://doi.org/10.3390/rs12193136>

TATSUMI, K., USAMI, T. Plant-level prediction of potato yield using machine learning and unmanned aerial vehicle (UAV) multispectral imagery. *Discov Appl Sci* **6**, 649 (2024). <https://doi.org/10.1007/s42452-024-06362-7>

TEDESCO, D. et al. Use of remote sensing to characterize phenological development and predict sweet potato yield in two growing seasons. *European Journal of Agronomy*, v. 129, 126337, 2021. [ResearchGate+1](#)

VAN KLOMPENBURG, T.; KASSAHUN, A.; SIKMA, P. Crop yield prediction using machine learning: a systematic literature review. *Computers and Electronics in Agriculture*, v. 177, 105709, 2020. [WUR Research](#)

VIEIRA, S. R. et al. Handbook for geostatistical analysis of variability in soil and climate data. In: ALVAREZ, V. H. et al. (org.). *Tópicos em ciência do solo*. Viçosa: SBCS, 2002. v. 2. p. 1–45.

ZAHEER, K.; AKHTAR, S. Potato production, usage, and nutrition—A review. *Critical Reviews in Food Science and Nutrition*, v. 56, n. 5, p. 711–721, 2016.