UNIVERSIDADE ESTADUAL PAULISTA

FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS

CÂMPUS DE JABOTICABAL

APRIMORANDO A ACURÁCIA DA PREDIÇÃO DE PRODUTIVIDADE DO MILHO POR MEIO DE SENSORIAMENTO REMOTO E REDES NEURAIS ARTIFICIAIS

JOÃO GABRIEL QUERIDO DIAS

Jaboticabal – SP

2025

UNIVERSIDADE ESTADUAL PAULISTA

FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS

CÂMPUS DE JABOTICABAL

APRIMORANDO A ACURÁCIA DA PREDIÇÃO DE PRODUTIVIDADE DO MILHO POR MEIO DE SENSORIAMENTO REMOTO E REDES NEURAIS ARTIFICIAIS

JOÃO GABRIEL QUERIDO DIAS

Orientador: Prof. Dr. Rouverson Pereira da Silva

Coorientador: MSc. Thiago Caio Moura Oliveira

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

Jaboticabal – SP

2025

D541a

Dias, João Gabriel Querido

Aprimorando a acurácia da predição da produtividade do Milho por meio de Sensoriamento remoto e Redes neurais artificiais / João Gabriel Querido Dias. -- Jaboticabal, 2025

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

Trabalho de conclusão de curso (Bacharelado - Engenharia Agronômica) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientador: Rouverson Pereira da Silva

Coorientador: Thiago Caio Moura Oliveira

1. Milho. 2. Sensoriamento remoto. 3. Redes neurais (Computação). 4. Predição. 5. Agricultura. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Dados fornecidos pelo autor(a).

unesp UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
Câmpus Jaboticabal

JOÃO GABRIEL QUERIDO DIAS

APRIMORANDO A ACURÁCIA DA PREDIÇÃO DE PRODUTIVIDADE DO MILHO POR MEIO DE SENSORIAMENTO REMOTO E REDES NEURAIS ARTIFICIAIS:

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 Agronômica.

Orientador: Prof. Dr. Rouverson Pereira da Silva
Coorientador: Me. Thiago Caio Moura Oliveira

Área de Concentração: Agricultura de precisão

Data da defesa: 06/11/2025

(X) Aprovado
( ) Reprovado

Banca Examinadora:

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

Airton Andrade da Silva
Eng. Agrônomo Me. Airton Andrade da Silva
UNESP – Faculdade de Ciências Agrárias e Veterinárias – Campus de Jaboticabal

Pedro Henrique Nogueira Gusmão
Eng. Agrônomo Pedro Henrique Nogueira Gusmão
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 - www.fcav.unesp.br

DEDICATÓRIA

Aos meus pais, Paulo Roberto Dias Júnior e Mara Brigida Theodoro Querido Dias, por me ensinarem o valor da humildade e do amor, por dedicarem suas vidas aos filhos e por me permitirem voar e sonhar sempre mais alto.

Às minhas irmãs, Mariana Querido Dias e Maria Laura Querido Dias, e à minha namorada, Letícia Gabriele da Silva. Por serem meu alicerce e a força que me mantém de pé.

AGRADECIMENTOS

Primeiramente agradeço a Deus, Jesus Cristo e Nossa Senhora Aparecida, pela força, saúde e pelas boas pessoas que colocaram em meu caminho.

À minha família, em especial àqueles a quem dedico este trabalho, mas também de forma extensa à minha avó Edmeria de Jesus Theodoro Querido, meus tios e primos, de sangue e de consideração, por serem meu alicerce e apoio incondicional.

Ao meu orientador, Prof. Dr. Rouverson Pereira da Silva, pela confiança, acolhida em seu grupo e pelos ensinamentos que me permitiram um imenso crescimento profissional e pessoal.

Ao meu coorientador, Me. Thiago Caio Moura Oliveira, pela grande parceria, amizade e pelas contribuições críticas que foram fundamentais para o resultado deste trabalho.

Aos meus amigos e irmãos de jornada: Gabriel Akio Hiraoka Dalmolin, pela parceria e amizade inestimáveis ao longo de todos esses anos de faculdade e de projeto; e Diogo Augusto Dias Theodoro Querido, meu irmão de vida e futuro colega de profissão, pelo apoio e parceria incondicionais de sempre.

Ao RSRG, LAMMA, pelo acolhimento, amizade e crescimento. Um agradecimento especial ao PET-AGRO, por ter sido não apenas um grupo de excelência, mas uma verdadeira família.

À República Arapuka, minha segunda casa, por todo o acolhimento, apoio, amizade e pelas histórias inesquecíveis vividas ao longo desses anos, que também me fizeram crescer.

À FCAV - UNESP Jaboticabal, pela formação de excelência, e à FEPE, pela fundamental disponibilidade da área experimental, profissionais e máquinas.

A todos os meus amigos, pela paciência infinita nos momentos de ausência, pelo apoio incondicional e por tornarem toda esta jornada muito mais leve.

A todos que, de alguma forma, fizeram parte desta conquista e tornaram este sonho possível, o meu muito obrigado.

SUMÁRIO

RESUMO 8
ABSTRACT 9
1. INTRODUÇÃO 12
2. REVISÃO BIBLIOGRÁFICA 15
2.1 Cultura do Milho 15
2.1.1 Importância socioeconômica 16
2.1.2 Colheita mecanizada 21
2.2 Sensoriamento remoto na agricultura 23
2.3 Não linearidade dos dados 25
2.4 Aprendizado de máquinas 26
3. MATERIAL E MÉTODOS 27
3.1 Área experimental 27
3.2 Aquisição de dados em campo 28
3.3 Aquisição das imagens de satélites 29
3.5 Análise dos dados 32
3.5 Predição de produtividade 32
3.5.1 Multilayer Perceptron (MLP) 33
3.5.2 Radial Basis Function (RBF) 34
3.5.3 Métrica de desempenho 34
4. RESULTADOS 35
4.1 Análise Descritiva dos Dados de Produtividade 35
4.2 Análise de Multicolinearidade das Variáveis 36
4.3 Desempenho dos Modelos de Redes Neurais Artificiais 37
5. DISCUSSÃO 38
6. CONCLUSÃO 41
7. REFERÊNCIAS 42

RESUMO

Como o milho sustenta cadeias globais de alimentos, rações e bioenergia, prever sua produtividade é vital para planejar insumos e reduzir perdas, contudo, a elevada variabilidade espacial e a não normalidade dos dados limitam métodos convencionais. Diante desse cenário, com este trabalho, visamos suavizar o efeito da não normalidade dos dados e predizer a produtividade do milho usando sensoriamento remoto e redes neurais artificiais. O estudo foi conduzido na Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal, São Paulo, Brasil, safra 2023/2024, a área abrange 10 hectares com avaliação de 80 pontos de produtividade georreferenciados que foram usados como saída no modelo preditivo. As variáveis espectrais, usadas de entrada para o modelo de predição, sete bandas e dez índices, foram obtidas de imagens do sensor orbital PlanetScope. Para avaliar a normalidade dos dados de produtividade foi usado um histograma e um boxplot, e após entender seu comportamento, foi aplicado o método Método do Intervalo Interquartílico (IQR) para remover pontos discrepantes e homogeneizar a distribuição. Em seguida, foi realizada a análise do Fator de Inflação da Variância (VIF <5), para selecionar as variáveis com menor multicolinearidade entre si. Para análise da predição da produtividade empregou-se duas arquiteturas de redes neurais, a Multilayer Perceptron (MLP) e Radial Basis Function (RBF), sendo utilizado o Erro Médio Absoluto (MAE) para avaliar o desempenho dos modelos e o banco de dados dividido em 80% para treinamento e 20% para teste. O método VIF selecionou quatro variáveis de entrada (NIR, Verde, CVI e SCCCI) assim, diminuindo a multicolinearidade e mostrando que quatro variáveis de entradas já são o suficiente para predizer a produtividade do milho. A MLP apresentou melhor desempenho (MAE 715 kg ha^{-1}) em relação a RBF (MAE 731 kg ha^{-1}). Apesar da grande variabilidade nos dados, que resultou em um erro estimado de 20% em relação a produtividade real, coletada na área, os resultados indicam avanços significativos na aplicação do sensoriamento remoto para a predição de produtividade do milho.

Palavras-chave: Zea mays L., Predição de Produtividade, Redes Neurais Artificiais, Sensoriamento Remoto, Agricultura de Precisão.

ABSTRACT

Because maize underpins global supply chains for food, feed, and bioenergy, forecasting its yield is vital for planning inputs and reducing losses; however, high spatial variability and non-normal data distributions limit conventional methods. In this context, this study aimed to mitigate the effect of non-normality on error and to predict maize yield using remote sensing and artificial neural networks. The study was conducted at the Faculty of Agricultural and Veterinary Sciences in Jaboticabal, São Paulo, Brazil, during the 2023/2024 season. The experimental area covered 10 hectares, with 80 georeferenced yield points. Spectral variables were derived from PlanetScope imagery (seven bands and ten vegetation indices). To characterize yield behavior, we first examined a histogram and a boxplot; based on this exploration, we applied the interquartile range (IQR) method to remove outliers and make the distribution more homogeneous. We then calculated the variance inflation factor (VIF < 5), and for yield prediction we employed two neural-network architectures: Multilayer Perceptron (MLP) and Radial Basis Function (RBF). Model performance was evaluated using mean absolute error (MAE). Among the 17 candidate input variables, the VIF procedure selected four inputs, thereby reducing multicollinearity and indicating that four predictors are sufficient for yield prediction. The dataset was split into 80% for training and 20% for testing. The MLP achieved a lower MAE (715 kg ha^{-1}) than the RBF (731 kg ha^{-1}). Despite the substantial variability in the data, which resulted in an estimated error of 20%, the results indicate meaningful advances in applying remote sensing to yield prediction, with potential to improve forecasting in maize.

Keywords: Zea mays L., Yield Prediction, Artificial Neural Networks, Remote Sensing, Precision Agriculture.

LISTA DE FIGURAS

Figura 1. Evolução das Exportações Brasileiras de Milho (2016–2024), em Volume e Valor. 17
Figura 2. Usos do milho no Brasil: 24/25. 18
Figura 3. Produção de milho (2023/24), principais regiões produtoras, em milhão de toneladas. Fonte: Autores, 2025; Conforme dados da ABIMILHO (2025). 19
Figura 4. Distribuição geográfica principais regiões produtoras de milho (2023/24). Fonte: Autores, 2025; Conforme dados da ABIMILHO (2025). 19
Figura 5. Produção nacional por região, safra (2024/25). Fonte: Conab, 2025. 21
Figura 6. Mapa de localização da área, no campus, em Jaboticabal, no estado São Paulo, onde foi conduzido o estudo. Fonte: Autores, 2025. 28
Figura 7. Croqui da área 29

LISTA DE TABELAS

Tabela 1. Resolução espectral do satélite PlanetScope..... 30
Tabela 2. Datas de coleta em campo e das imagens orbitais após a semeadura. 30
Tabela 3. Índices de Vegetação (IVs) usados como dados de entrada no modelo preditivo 31
Tabela 4. Arquiteturas das redes neurais artificiais utilizadas: Radial Basis Function (RBF) e Multilayer Perceptron (MLP). 33
Tabela 5. Comparação dos dados antes de depois da aplicação do método IQR. 36
Tabela 6. Variáveis preditoras selecionadas para a predizer a produtividade de milho após a análise de multicolinearidade..... 37

1. INTRODUÇÃO

O milho (*Zea mays* L.) é uma das culturas agrícolas de maior relevância global, com um papel central no abastecimento das cadeias de alimentação humana e animal, além de ser matéria-prima para a produção de bioenergia. Logo, a busca por eficiência produtiva é constante. No entanto, o grande desafio para otimizar o manejo e a rentabilidade da cultura reside na elevada variabilidade espacial da produtividade. Segundo dados da ABIMILHO (2025), o Brasil se encontra entre os três maiores produtores mundiais dessa cultura, e apresenta a produção anual em aproximadamente 130 milhões de toneladas, atrás dos Estados Unidos como o maior produtor, com aproximadamente 390 milhões de toneladas, seguido pela China, com cerca de 280 milhões. Sendo no Brasil, o uso dessa cultura mais de 40% para o consumo animal, e mais de 30% para exportação, segundo dados da ABIMILHO (2025).

Diante desse cenário, o Sensoriamento Remoto (SR) consolidou-se como uma ferramenta eficiente na Agricultura de Precisão para avaliar a variabilidade espacial, a qual é um grande problema, pois diferentes produtividades, requer diferentes manejos, desde o preparo de solo, investigação de pragas, e doenças, mato competição, e regulagens de colheita. E é um aliado na avaliação da variabilidade temporal de área agrícolas, principalmente pelo uso de dados orbitais obtidos por sensores ópticos abordo de satélites que capturam a energia eletromagnética refletida pelo dossel das culturas. O SR orbital, entrega uma resolução excelente, e com muita eficiência, consegue cobrir grandes áreas, armazenar um histórico da área, sem ter a necessidade de ir até ela, por exemplo, a constelação de satélite PlanetScope, apresenta uma excelente resolução espacial de 3 metros, e uma resolução temporal diária, com sensores multiespectrais fornecendo dados de 8 bandas.

Os Índices de Vegetação (IVs) são equações algébricas que levam em consideração as bandas espectrais obtidas pelos sensores ópticos, que possibilitam avaliar a variabilidade da produtividade da área. Esses índices são, mais especificamente, algoritmos derivados da transformação espectral da reflectância em dois ou mais comprimentos de onda, usados para avaliar a cobertura vegetal ou biomassa e o estado de saúde da planta (Oliveira, 2024). Porém, mesmo avaliando a produtividade do milho por IV, esta apresenta alta variabilidade (Barzin et al., 2020), muitas vezes devido à inconsistência de nutrientes no solo, disponibilidade de água e outros parâmetros ambientais que afetam o crescimento. Essa complexidade resulta em um comportamento

não linear entre os IVs e a produtividade, além de uma distribuição não normal dos dados (Kumar et al., 2025), o que desafia a precisão de modelos estatísticos tradicionais.

Assim, métodos que visem suavizar o efeito da não normalidade dos dados e uso de Redes Neurais Artificiais que observam a não linearidade entre os dados de produtividade e índices de vegetação são ferramentas eficazes para aprimorar a acurácia no processo de predição de produtividade do milho. As RNAs são ferramentas de inteligência artificial capazes de modelar sistemas complexos e não lineares, identificando padrões que métodos convencionais não capturam (SILVA et al., 2016).

Teve-se como objetivo melhorar a qualidade dos dados de produtividade, a partir da suavização da distribuição não normal dos dados, e assim predizer a produtividade do milho utilizando Redes Neurais Artificiais que observam a não linearidade entre os dados de entrada e os dados de saída.

Apesar dos avanços no uso de SR, persiste uma lacuna significativa no tratamento dos dados agronômicos. Os dados de produtividade coletados em campo, são essenciais para calibrar os modelos, são caracteristicamente complexos, apresentando alta variabilidade, distribuição não normal e, principalmente, a presença de dados discrepantes (outliers). Esses pontos discrepantes, muitas vezes gerados por erros operacionais da colhedora ou manobras no campo, distorcem as análises e comprometem a precisão dos modelos estatísticos tradicionais (TRIOLA, 2008). Além disso, a grande quantidade de variáveis espectrais obtidas (diversas bandas e IVs) gera alta multicolinearidade, um problema que precisa ser tratado antes da modelagem.

Para além da questão dos dados agronômicos, outra lacuna refere-se à plataforma de aquisição de dados. Muitos trabalhos recentes focam no uso de Aeronave Remotamente pilota (ARP), que, embora ofereçam altíssima resolução, possuem limitações de cobertura de área e custo operacional (SHIRATSUCHI et al., 2023). Existe, portanto, a necessidade de validar metodologias que sejam eficazes utilizando dados de satélite de alta frequência e resolução, como os da constelação PlanetScope. O uso de imagens orbitais de alta resolução tem se mostrado uma abordagem de alta precisão para a criação de modelos, como demonstrado por Oliveira (2024), que obteve alta acurácia na estimativa da maturação do amendoim. A validação de plataformas como o PlanetScope neste trabalho, que oferece um balanço prático entre resolução temporal,

resolução espacial e cobertura de área, é, portanto, um passo relevante para a aplicação dessas tecnologias em larga escala pelo produtor.

Para superar as limitações dos modelos estatísticos lineares e lidar com a complexidade das relações entre os dados espectrais e a produtividade, as Redes Neurais Artificiais (RNAs) surgem como uma alternativa robusta.

Diante disso, o trabalho partiu de uma hipótese metodológica sequencial: A primeira hipótese foi que, dada a natureza complexa dos dados de campo, a aplicação de um método estatístico robusto (o Intervalo Interquartílico - IQR) seria eficaz para tratar a não normalidade e os outliers dos dados de produtividade, permitindo que um padrão agronômico real fosse identificado.

A segunda hipótese foi que, trabalhando esses dados estatisticamente, e diminuindo a variabilidade, seria possível predizer a produtividade do milho com alta precisão. Isso seria alcançado utilizando Redes Neurais Artificiais (arquiteturas MLP e RBF), alimentadas por um conjunto enxuto e otimizado de variáveis espectrais orbitais, rigorosamente selecionadas pela análise VIF para evitar a multicolinearidade.

Objetivou-se neste trabalho foi suavizar o efeito da não normalidade dos dados e predizer a produtividade do milho usando sensoriamento remoto orbital e Redes Neurais Artificiais. Para isso, foram definidos os seguintes objetivos específicos: (I) Aplicar o método do Intervalo Interquartílico (IQR) para identificar e remover pontos discrepantes, homogeneizando a distribuição dos dados de produtividade; (II) Selecionar as variáveis espectrais (bandas e índices de vegetação) mais relevantes e com menor multicolinearidade para a modelagem, através da análise do Fator de Inflação da Variância (VIF); (III) Treinar e comparar o desempenho das arquiteturas de redes neurais artificiais Multilayer Perceptron (MLP) e Radial Basis Function (RBF) na predição da produtividade do milho; (IV) Avaliar a acurácia dos modelos utilizando a métrica do Erro Médio Absoluto (MAE), identificando a arquitetura mais adequada para as condições do estudo.

2. REVISÃO BIBLIOGRÁFICA

2.1 Cultura do Milho

O milho é considerado uma das culturas agrícolas de maior relevância originadas no continente americano, com registros históricos que indicam sua domesticação há cerca de cinco mil anos, e há evidências arqueológicas e análises por datação radioativa as quais apontam que sua origem possivelmente se deu nas regiões do México, América Central ou Sudoeste dos Estados Unidos (DUARTE; MATTOSO; GARCIA, 2021). Após a chegada dos europeus ao continente americano, o cereal foi introduzido na Europa, onde inicialmente era cultivado em jardins. Com o reconhecimento de seu valor nutricional e produtivo, o cultivo do milho expandiu-se significativamente, sendo adotado em diversas regiões do planeta, alcançando desde altas latitudes do Hemisfério Norte, como a antiga União Soviética, até áreas do Hemisfério Sul, como a Argentina (DUARTE; MATTOSO; GARCIA, 2021).

O milho (Zea mays L.) é uma gramínea anual amplamente cultivada no Brasil, cuja morfologia e fisiologia conferem grande adaptabilidade e potencial produtivo. A planta apresenta sistema radicular fasciculado, com raízes adventícias que se originam dos nós do colmo, possibilitando maior ancoragem e eficiência na absorção de água e nutrientes. O colmo é cilíndrico, ereto, formado por entrenós e nós, e atua tanto como estrutura de sustentação quanto como reserva de compostos essenciais ao desenvolvimento. As folhas são largas, alternadas e paralelinérveas, compostas por bainha, lâmina e lígula, favorecendo a interceptação da luz solar. A arquitetura da planta também inclui inflorescências unissexuais: o pendão, masculino, posicionado no ápice do colmo, e a espiga, feminina, que se desenvolve nas axilas das folhas medianas (EMBRAPA, 2020).

Do ponto de vista fisiológico, o milho possui metabolismo fotossintético do tipo C4, o que lhe proporciona alta eficiência na conversão de energia solar em biomassa, especialmente em regiões de clima quente. Essa característica, aliada à disposição foliar estratégica e ao sistema radicular desenvolvido, contribui para um aproveitamento eficiente dos recursos ambientais. A sincronia entre o florescimento das inflorescências masculina e feminina é essencial para o sucesso da polinização e, consequentemente, para a formação de grãos. A combinação entre os aspectos morfológicos e fisiológicos da planta garante sua expressiva produtividade, sendo fundamental compreender essas

características para a adoção de manejos agronômicos mais eficientes (EMBRAPA, 2020).

2.1.1 Importância socioeconômica

A relevância econômica do milho está evidenciada pela ampla variedade de suas aplicações, que abrangem desde a alimentação animal até setores industriais avançados. A maior parte do consumo global do milho em grão é destinada à nutrição animal, representando aproximadamente 70% do total consumido mundialmente, por exemplo, nos Estados Unidos, esse percentual é cerca de 50%, enquanto no Brasil varia entre 60% e 80%, conforme diferentes fontes e oscilações anuais (DUARTE; MATTOSO; GARCIA, 2021).

A Figura 1 apresenta a evolução das exportações brasileiras de milho entre os anos de 2016 e 2024, em milhões de toneladas e bilhões de dólares, conforme dados da ABIMILHO (2025). Observa-se uma oscilação significativa ao longo do período, com destaque para os anos de 2019, 2022 e 2023, quando os volumes exportados superaram 40 milhões de toneladas, atingindo o pico de 55,89 milhões de toneladas em 2023. Em termos de valor, o maior faturamento ocorreu também em 2023, com US$ 13,63 bilhões, reflexo tanto do elevado volume exportado quanto de melhores preços no mercado internacional. Por outro lado, 2024 apresentou uma forte retração nas exportações, com apenas 7,02 milhões de toneladas e um faturamento de US$ 1,65 bilhão, indicando possível queda na produção, mudança na demanda externa ou maior competitividade de outros países exportadores. Essa variabilidade evidencia a sensibilidade do mercado de milho às condições climáticas, políticas comerciais e dinâmicas da oferta e demanda global.

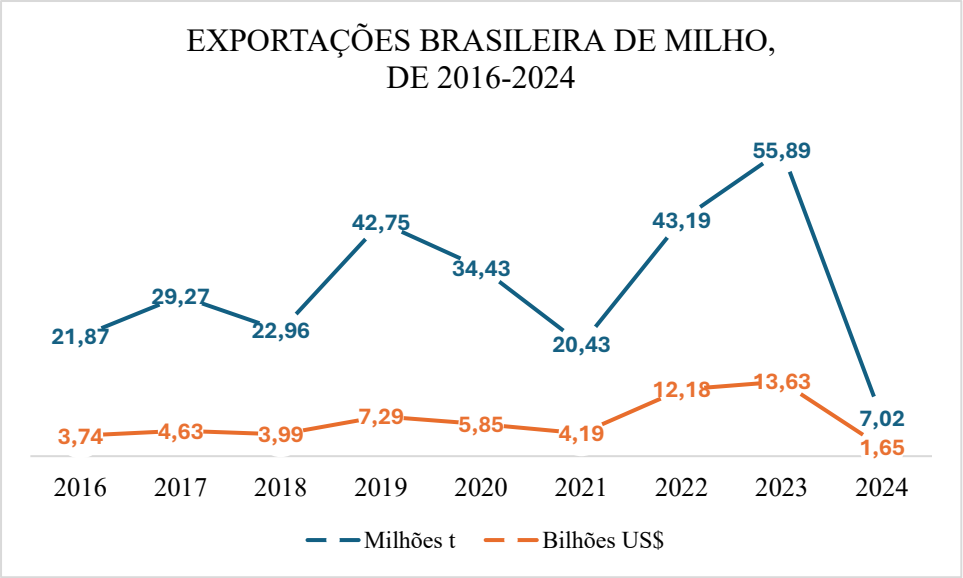


Figura 1. Evolução das Exportações Brasileiras de Milho (2016–2024), em Volume e Valor.
Fonte: Autores, 2025; Conforme dados da ABIMILHO (2025).

Embora o consumo de milho em grão para alimentação humana represente uma parcela menor em comparação ao uso na alimentação animal, seus derivados desempenham papel fundamental em regiões de menor poder aquisitivo. Em certas localidades, o milho compõe a base da dieta diária da população. Isso é observado, por exemplo, no semiárido nordestino do Brasil, onde o milho é uma importante fonte de energia alimentar, assim como no México, onde o cereal é ingrediente essencial na culinária tradicional (DUARTE; MATTOSO; GARCIA, 2021).

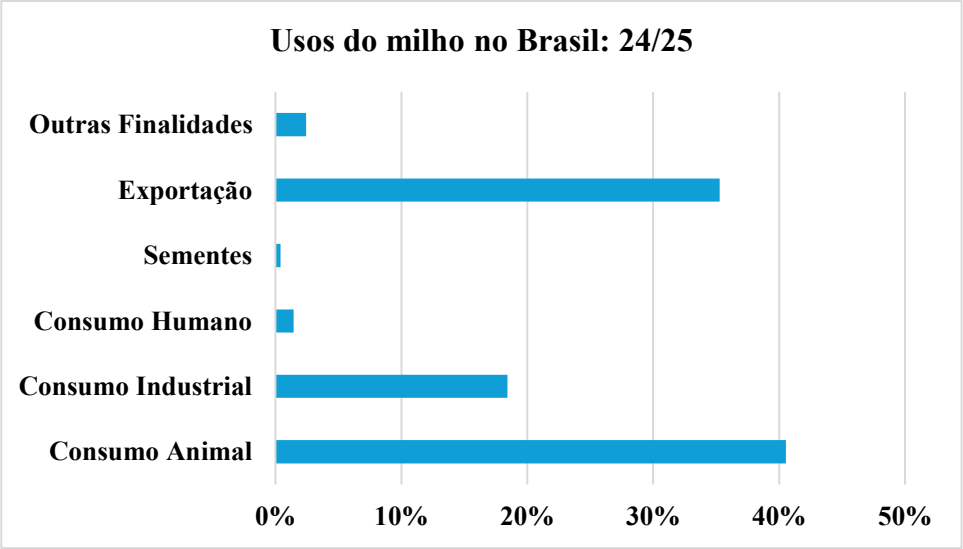


Figura 2. Usos do milho no Brasil: 24/25.
Fonte: Autores, 2025; Conforme dados da ABIMILHO (2025).

A Figura 2, com dados da ABIMILHO (2025), apresenta a distribuição percentual do consumo de milho no Brasil para o período de 2024/2025. Observa-se que a maior parte do milho é destinada ao consumo animal, representando pouco mais de 40% do total. Em seguida, destaca-se a exportação, com aproximadamente 35% da utilização. O consumo industrial aparece em terceiro lugar, com cerca de 18%, demonstrando a relevância do milho como matéria-prima em diversos setores. Já o consumo humano direto, a utilização como sementes e outras finalidades correspondem a uma parcela significativamente menor, todas abaixo de 5%. Esses dados evidenciam a importância do milho principalmente na cadeia produtiva animal e no comércio exterior brasileiro.

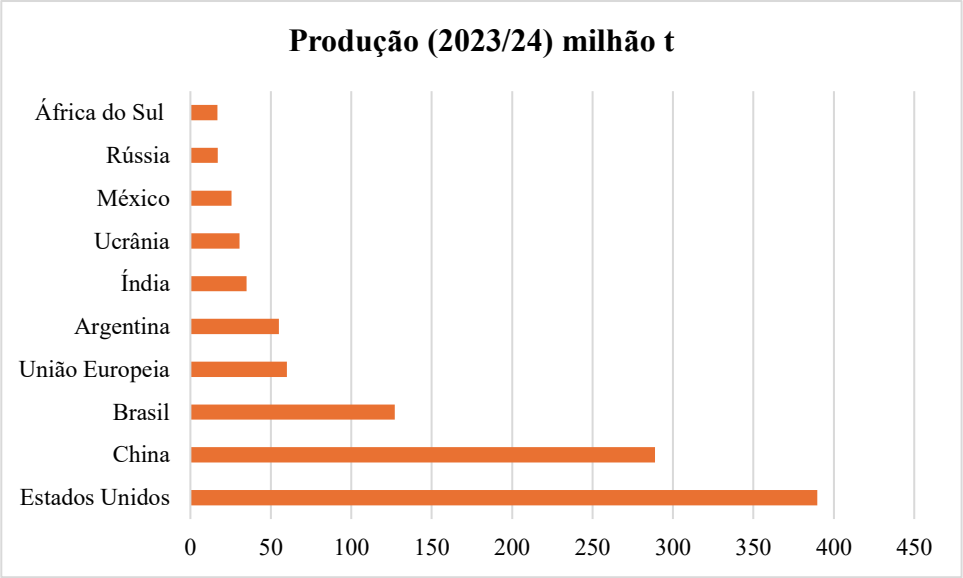


Figura 3. Produção de milho (2023/24), principais regiões produtoras, em milhão de toneladas. Fonte: Autores, 2025; Conforme dados da ABIMILHO (2025).

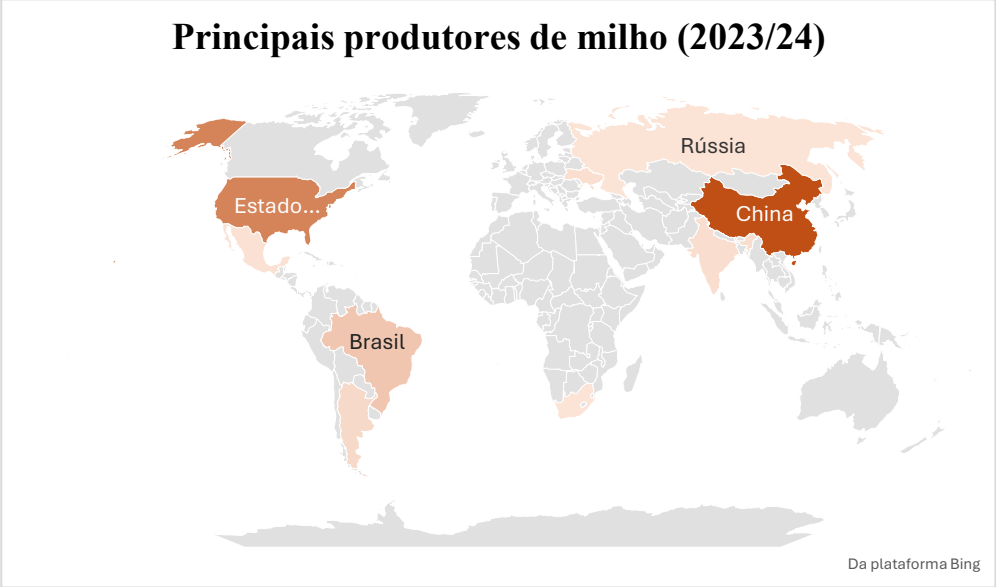


Figura 4. Distribuição geográfica principais regiões produtoras de milho (2023/24). Fonte: Autores, 2025; Conforme dados da ABIMILHO (2025).

As Figuras 3 e 4, baseadas em dados da ABIMILHO (2025), ilustram os principais produtores mundiais de milho no ciclo 2023/2024, tanto em termos quantitativos quanto geográficos. A Figura 3 apresenta a produção anual de milho em milhões de toneladas, destacando os Estados Unidos como o maior produtor, com aproximadamente 390 milhões de toneladas, seguido pela China, com cerca de 280 milhões, e o Brasil, com pouco menos de 130 milhões. Esses três países lideram a produção global, superando

significativamente os demais produtores, como a União Europeia, Argentina e Índia, que produzem menos de 60 milhões de toneladas cada. A Figura 4 complementa essa informação ao mapear geograficamente esses principais produtores, reforçando a concentração da produção nas Américas e na Ásia, evidenciando a relevância estratégica desses países no abastecimento mundial de milho.

A produção de milho no Brasil para a safra 2024/25 é estimada em aproximadamente 126,9 milhões de toneladas, apresentando um crescimento significativo de 9,9% em relação ao ciclo anterior. Segundo dados da Companhia Nacional de Abastecimento (Conab, 2025), a primeira safra de milho já alcançou 77,6% da colheita, com uma produção prevista de 24,7 milhões de toneladas, enquanto a segunda safra, com a semeadura finalizada, deve atingir cerca de 99,8 milhões de toneladas. Essa alta produção está associada à ampliação da área cultivada, à melhoria nas técnicas agrícolas e às condições climáticas mais favoráveis observadas neste ciclo.

Assim sendo, a área cultivada vem crescendo ao longo dos anos, segundo o 7º Levantamento de Grãos da Conab, para a safra 2024/25, nota-se uma grande crescente na área de produção do milho, na safra 2020/21, a produção em área de milho era de 70,1 milhões de hectares, e nessa atual safra (2024/25), a área produzida é de 81,7 milhões de hectares.

De forma complementar, o Instituto Brasileiro de Geografia e Estatística (IBGE, 2025) destaca que a produção nacional de milho se mantém em patamares próximos ao recorde histórico de 132 milhões de toneladas registrado em 2023, consolidando o milho como um dos principais grãos no agronegócio brasileiro. A importância econômica da cultura é evidenciada pela ampla participação de estados como Mato Grosso, Paraná e Goiás na produção total, que respondem por grande parte do volume nacional. Esses dados refletem uma recuperação da produtividade e reforçam o papel do milho no abastecimento interno e nas exportações, fundamental para o equilíbrio do mercado agrícola brasileiro (CONAB,2025; IBGE, 2025).

Na Figura 5, está ilustrada a distribuição regional da produção de milho, com grande destaque ao Centro-Oeste, e com destaque ao sul, ambas regiões onde se encontram os estados citados acima, como o Mato Grosso, Goiás e o Paraná, os quais se destacam na produção do grão (CONAB, 2025).

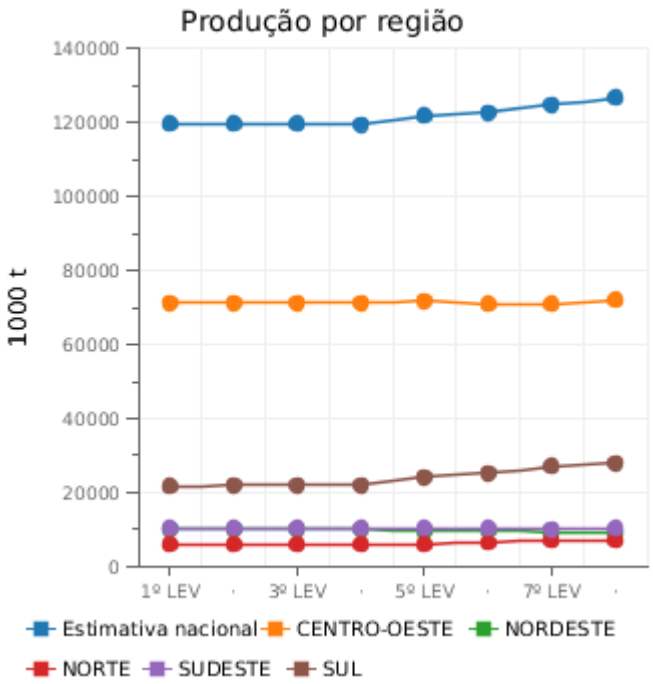


Figura 5. Produção nacional por região, safra (2024/25). Fonte: Conab, 2025.

Diante dos dados apresentados, mostra-se que o milho possui um papel central na dinâmica socioeconômica global, tanto como base da alimentação animal quanto como recurso estratégico no enfrentamento da fome. Sua ampla produção, destacando-se Estados Unidos, China e Brasil como líderes mundiais (Figuras 3 e 4), associada à sua versatilidade e valor nutricional, consolida o cereal como um dos pilares da segurança alimentar. No Brasil, embora grande parte do milho seja destinada à exportação e ao setor pecuário (Figura 2), sua relevância vai além do mercado, alcançando também impactos sociais significativos. Segundo a UNICEF (2024), milhões de crianças em situação de vulnerabilidade enfrentam a desnutrição aguda, realidade que demanda políticas públicas voltadas ao fortalecimento das cadeias produtivas de alimentos acessíveis e nutritivos. Nesse contexto, o milho se destaca como insumo estratégico para programas de alimentação escolar, políticas de subsídio agrícola e desenvolvimento rural sustentável, contribuindo de forma indireta e estruturante para o combate à fome e à insegurança alimentar.

2.1.2 Colheita mecanizada

A colheita é a última etapa de campo em uma produção agrícola, e para que o produto chegue mais rápido ao consumidor, esse processo foi mecanizado, utilizando-se as colhedoras, além do último, a colheita, é um dos mais importantes processos, pois é

um processo com muitos riscos envolvidos, e diretamente ligado ao lucro ou prejuízo do produtor (SILVA, e FRANCETO, 2025).

Nos dias de hoje, muitas vantagens são atribuídas as colhedoras, como maior capacidade de trabalho, e otimização do serviço, usando menos tempo, e liberando mais espaço, porém a dificuldade de se obter colhedoras, está relacionada com o alto investimento inicial necessário (SILVA, e FRANCETO, 2025).

Essa operação demanda atenção e cuidados técnicos, uma vez que perdas significativas podem ocorrer se não houver uma condução adequada da atividade, assim sendo os principais fatores que influenciam negativamente essa etapa, destacam-se as regulagens incorretas da colhedora, a velocidade operacional elevada e a umidade inadequada dos grãos no momento da colheita (MANTOVANI, 2021).

Em diversas situações, as regulagens e a velocidade operacional, são fundamentais para o sucesso da colheita. Como a resistência ao acamamento, a qual influência direto na velocidade de deslocamento da colhedora, e a regulagem da máquina, por exemplo a altura da plataforma, que em casos de menores resistências, devem trabalhar em menor altura (SILVA, e FRANCETO, 2025).

A umidade, e a maturação dos grãos, são fatores cruciais para as perdas, com teores de água mais elevados, a qualidade é prejudicada, e as perdas aumentam, e em teores menores de umidade, as perdas se elevam, devido à queda de grãos no solo, e tanto as plantas, como os grãos se tornam mais quebradiços (SILVA, e FRANCETO, 2025).

Para redução dessas perdas exige uma grande atenção durante a operação de colheita, pois qualquer descuido pode comprometer todo o investimento e esforço aplicados nas fases anteriores do cultivo, como a semeadura e os tratos culturais. Dessa forma, aspectos como a correta regulagem da colhedora, a habilidade do operador, as características da lavoura e a condução técnica da operação tornam-se fundamentais para garantir a eficiência do processo produtivo (ZERBATO et al., 2013).

As perdas durante a colheita são determinadas tanto por fatores próprios da cultura quanto por variáveis ligadas à máquina colhedora. No caso específico do milho, um dos elementos mais determinantes é a plataforma de corte, responsável por realizar a etapa inicial do processo, o despigue, recolhimento e transporte das espigas até o interior da colhedora, onde ocorre a trilha (ZERBATO et al., 2013).

Segundo a Embrapa, perdas durante a colheita mecanizada do milho podem atingir valores consideráveis se práticas inadequadas forem adotadas, sendo classificadas em perdas visíveis, como espigas ou grãos derrubados ao solo, e perdas invisíveis, como grãos danificados que não são separados adequadamente pela colhedora. A realização de avaliações periódicas de perdas durante a operação é fundamental para identificar e corrigir eventuais falhas no processo, assegurando maior eficiência e rentabilidade (MANTOVANI, 2021).

Portanto, a colheita mecanizada não deve ser tratada apenas como uma etapa final, mas como parte integrante e estratégica do sistema de produção do milho (MANTOVANI, 2021). Para que uma unidade de produção agrícola alcance viabilidade econômica, é imprescindível que apresente elevada produtividade aliada ao uso de tecnologias eficientes, especialmente na etapa de colheita, que deve ser ágil e eficaz na retirada dos grãos. Nesse contexto, o avanço da colheita mecanizada tem sido constante, buscando não apenas acelerar o processo, mas também minimizar as perdas de grãos no campo (ZERBATO et al., 2013).

2.2 Sensoriamento remoto na agricultura

O sensoriamento remoto (SR) é definido como a obtenção de informações sobre objetos ou superfícies sem a necessidade de contato físico direto, utilizando sensores capazes de registrar a energia eletromagnética refletida ou emitida pelos alvos. Inicialmente, essas medições eram feitas com câmeras instaladas em balões ou aeronaves; hoje, os dados podem ser coletados por satélites, aeronave remotamente pilotada (ARP), sensores acoplados a tratores ou equipamentos terrestres (SHIRATSUCHI et al., 2023).

Essa ferramenta tem se consolidado na agricultura, ao permitir a obtenção de informações valiosas sobre a superfície terrestre por meio da detecção da energia eletromagnética refletida ou emitida pelos alvos, ela viabiliza o monitoramento de grandes áreas agrícolas com agilidade, precisão e menor custo, reduzindo a necessidade de coletas de dados intensivas em campo (BERNARDI et al., 2014). Com o auxílio de sensores instalados em plataformas orbitais, como satélites, é possível acompanhar o desenvolvimento das culturas ao longo do ciclo produtivo, identificar variações espaciais e temporais e tomar decisões mais fundamentadas no manejo.

Entre os principais produtos extraídos do sensoriamento remoto, destacam-se os índices de vegetação, que têm sido amplamente utilizados para estimar variáveis biofísicas, como biomassa e vigor vegetativo. Essas métricas auxiliam na avaliação do potencial agrícola de uma região, fornecendo respostas rápidas e confiáveis quanto ao desempenho das lavouras, mesmo em áreas extensas e de difícil acesso (SARTORI; MORAES, 2010).

Na agricultura, o uso do sensoriamento remoto, unido aos índices de vegetação, permitem a análise de características da vegetação de forma rápida, não destrutiva e com ampla cobertura espacial. Ele possibilita, por exemplo, estimativas de produtividade, identificação de estresse hídrico e nutricional, mapeamento fenológico e até o monitoramento de pragas e doenças (SHIRATSUCHI et al., 2023).

Essas aplicações se baseiam em propriedades de refletância das plantas em diferentes bandas do espectro eletromagnético. A clorofila, por exemplo, reflete fortemente na faixa do verde e no infravermelho próximo (NIR) e absorve nas faixas azul e vermelha. A partir dessa resposta espectral, são desenvolvidos os chamados índices de vegetação (IVs), como o NDVI, SAVI, MSAVI, entre outros, que permitem avaliar o vigor, área foliar, biomassa e conteúdo nutricional das culturas (BRANDÃO et al., 2008; HUETE, 1988).

Com o avanço tecnológico, os sensores utilizados no sensoriamento remoto foram categorizados como passivos que dependem da luz solar, como os satélites Landsat, MODIS e CBERS e ativos, que possuem fonte própria de energia, como os sensores LiDAR, Crop Circle e GreenSeeker. Esses últimos se destacam por sua eficiência em qualquer horário do dia e independência das condições atmosféricas (SHIRATSUCHI et al., 2023).

Os satélites oferecem grande cobertura territorial e boa resolução espectral, porém apresentam limitações quanto à resolução espacial e temporal, além da interferência de nuvens, o que pode comprometer a aquisição de dados em épocas críticas do ciclo das culturas. Em contrapartida, os ARPs surgem como alternativa eficaz, com imagens de altíssima resolução e maior frequência de coleta, o que favorece o uso em áreas menores e com exigência de monitoramento contínuo (SHIRATSUCHI et al., 2023).

Além disso, os sensores ativos de dossel permitem não apenas o diagnóstico do estado nutricional das plantas, especialmente quanto ao nitrogênio, mas também

viabilizam a aplicação de insumos em taxas variáveis em tempo real, otimizando o uso de fertilizantes e reduzindo custos e impactos ambientais (SHIRATSUCHI et al., 2011a).

O sensoriamento remoto também permite o delineamento de zonas de manejo (ZM) dentro dos talhões, por meio de algoritmos de segmentação espacial baseados em dados espectrais, estruturais e biofísicos. Essas zonas refletem a variabilidade espacial do solo e da vegetação, sendo fundamentais para a adoção de práticas agrícolas site-específicas (OLIVEIRA; WHELAN; MCBRATNEY, 2013).

A eficácia de um sistema orbital para fins agrícolas, como o utilizado neste trabalho, é definida pela combinação de quatro resoluções fundamentais. A Resolução Espacial, que define o nível de detalhe da imagem, ou seja, o tamanho do pixel no terreno (ex: 3 metros). A Resolução Temporal, que é o tempo de revisita do satélite ao mesmo local. Para a agricultura, uma alta frequência (ex: diária, como a do PlanetScope) é crucial para superar a limitação das nuvens mencionada por Shiratsuchi et al. (2023) e capturar eventos críticos. A Resolução Espectral, que é a capacidade do sensor de capturar a energia em faixas (bandas) estreitas e específicas, como a Borda do Vermelho (Red Edge), permitindo o cálculo de índices fisiológicos robustos como o CVI e o SCCCI. Por fim, a Resolução Radiométrica, que é a sensibilidade do sensor para diferenciar "tons" de energia, permitindo detectar variações sutis no vigor da lavoura.

Dessa forma, o sensoriamento remoto torna-se uma ferramenta essencial no contexto da agricultura de precisão, contribuindo significativamente para o aumento da produtividade, a sustentabilidade dos sistemas agrícolas e a tomada de decisão fundamentada em dados objetivos.

2.3 Não linearidade dos dados

A complexidade da modelagem de produtividade agrícola impõe desafios significativos relacionados à natureza dos dados, tanto nas variáveis de entradas quanto nas variáveis de saída.

Primeiramente, observa-se a não linearidade intrínseca entre os Índices de Vegetação (IVs) e a produtividade das culturas. Conforme apontam Jensen (2009) e Pinter et al. (2003), embora exista correlação entre a resposta espectral e a biomassa, essa relação deixa de ser linear em estágios avançados de desenvolvimento ou em condições de alta

densidade foliar, ocorrendo o fenômeno de saturação do índice. Modelos de regressão linear simples tendem a subestimar a produtividade nessas condições, pois são incapazes de mapear a complexidade das interações biológicas e ambientais que definem o rendimento final dos grãos. É nesse contexto que as Redes Neurais Artificiais se destacam, pois, segundo Haykin (2001), elas atuam como aproximadores universais de funções, capazes de capturar padrões não lineares complexos que métodos estatísticos tradicionais não conseguem modelar.

Simultaneamente, a não normalidade dos dados de produtividade (saída) representa um obstáculo para a generalização do modelo. A variabilidade espacial das lavouras, influenciada por pragas, falhas de plantio ou manchas de solo, frequentemente gera distribuições de dados assimétricas e a presença de outliers. Hair et al. (2009) destacam que a violação do pressuposto de normalidade pode enviesar o processo de estimação de parâmetros, fazendo com que o algoritmo de aprendizado priorize o ajuste aos valores extremos (ruído) em detrimento do padrão geral dos dados. Isso impacta negativamente a acurácia da predição, resultando em um modelo com baixa capacidade de generalização para novos dados. Portanto, a remoção de outliers e a normalização dos dados tornam-se etapas críticas para garantir que a rede neural aprenda as características representativas da cultura, e não as anomalias locais.

2.4 Aprendizado de máquinas

O avanço das tecnologias digitais tem impulsionado o desenvolvimento de metodologias inovadoras para análise e tomada de decisão em diferentes setores, incluindo a agricultura. Dentre essas metodologias, destaca-se o Aprendizado de Máquina, uma subárea da Inteligência Artificial que possibilita que sistemas computacionais adquiram conhecimento a partir de dados e melhorem seu desempenho sem a necessidade de programação explícita (LUDERMIR, 2021).

O aprendizado de máquina baseia-se na construção de modelos matemáticos capazes de identificar padrões em grandes volumes de informações, realizando inferências e previsões. Os algoritmos podem ser classificados em três grupos principais: supervisionado, em que os dados de entrada são acompanhados por respostas conhecidas (ex.: classificação e regressão), não supervisionado, em que os dados não possuem rótulos e o objetivo é identificar agrupamentos ou estruturas ocultas, e por reforço, em que o

aprendizado ocorre por meio de recompensas ou penalidades em função das ações realizadas (MITCHELL, 1997; LUDERMIR, 2021).

Na agricultura, o uso de aprendizado de máquina tem ganhado espaço devido à sua capacidade de integrar informações de diferentes fontes, como imagens de satélite, dados climáticos e variáveis de campo, possibilitando maior eficiência na gestão produtiva. Estudos recentes demonstram que algoritmos como Support Vector Machine (SVM), Random Forest (RF), Redes Neurais Artificiais (ANN) e eXtreme Gradient Boosting (XGBoost) apresentam elevado potencial para prever a produtividade agrícola a partir de dados agrometeorológicos, como evidenciado em pesquisas com cana-de-açúcar e algodão no Brasil (MENESES, 2021).

Além disso, tecnologias de aprendizado de máquina têm sido utilizadas para o diagnóstico de doenças, categorização de estresses em plantas e apoio na tomada de decisão em tempo real. Empresas agrícolas já aplicam essas ferramentas para monitorar lavouras, otimizar recursos e reduzir perdas, aproximando o setor rural da chamada agricultura digital (SANTOS, 2020).

O aprendizado de máquina, portanto, surge como uma ferramenta complementar às técnicas de sensoriamento remoto e análise estatística, possibilitando maior robustez na modelagem de fenômenos complexos da agricultura. Sua aplicação conecta-se diretamente às demandas por agricultura inteligente e previsão de produtividade, constituindo-se em um elo entre a coleta massiva de dados e a transformação desses em informações estratégicas para a sustentabilidade e eficiência dos sistemas agrícolas.

3. MATERIAL E MÉTODOS

3.1 Área experimental

O experimento foi conduzido numa área experimental da Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal (SP) (Figura 6) de 10 hectares durante a safra 2023/2024. O solo foi classificado como Latossolo Vermelho Eutroférrico, conforme o Sistema Brasileiro de Classificação de Solos (EMBRAPA, 1999) e clima classificado como subtropical, segundo Köppen.

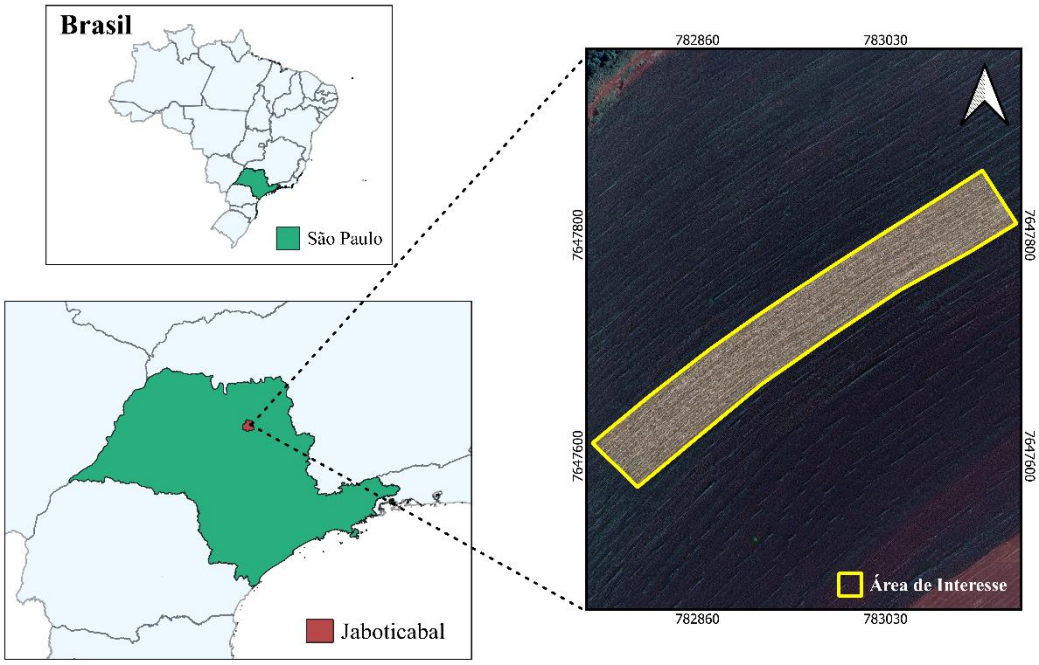


Figura 6. Mapa de localização da área, no campus, em Jaboticabal, no estado São Paulo, onde foi conduzido o estudo. Fonte: Autores, 2025.

A semeadura foi feita na data 12/12/2023, em sistema convencional, o qual envolve o revolvimento do solo antes da semeadura, com espaçamento de 0,45 metros entre linhas. A cultivar utilizada foi o híbrido de milho AG8701 PRO4, de grupo de maturação 136, com ciclo fenológico estimado entre 115 e 130 dias. A adubação de base foi composta por 300 kg/ha de formulação 04-28-08, 200 kg/ha de 19-04-19 e 200 kg/ha de 27-00-00, resultando em uma aplicação total de 108 kg/ha de nitrogênio para a cultura. O manejo fitotécnico conduziu-se conforme as recomendações técnicas para a cultura do milho, contemplando estratégias de controle de pragas, doenças e plantas daninhas, conforme a demanda ao longo do ciclo.

3.2 Aquisição de dados em campo

Foram estabelecidos 80 pontos de amostragem no campo, espaçados em intervalos de 40 metros, georreferenciados com drone modelo DJI Phantom 4 Multiespectral (Figura 7). Desses 80 pontos, extraímos a produtividade e as informações espectrais, que posteriormente foram utilizadas nas variáveis de entrada.

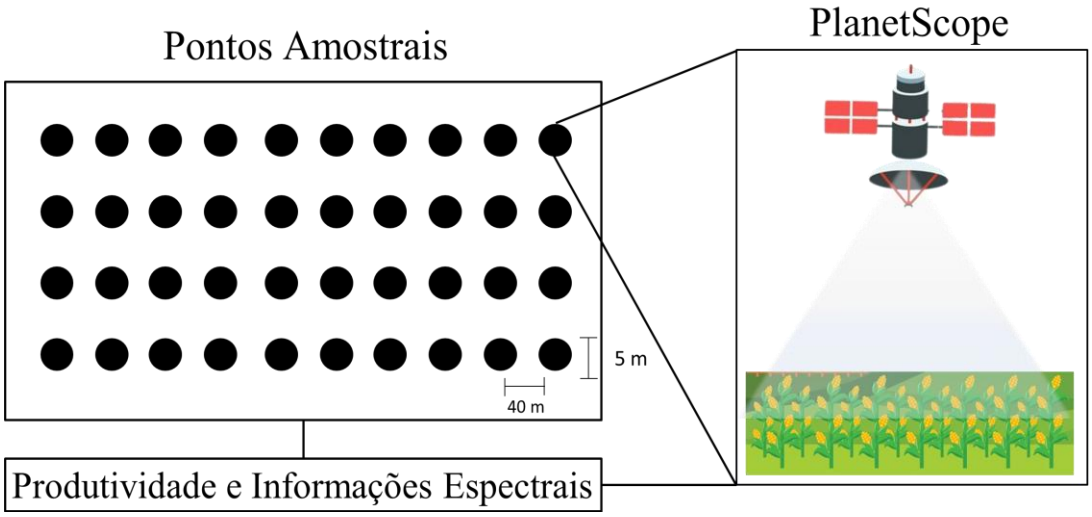


Figura 7. Croqui da área

A coleta de dados em cada ponto foi realizada um dia antes da colheita. com uma armação de área definida de 0,9m² O milho colhido foi debulhado e pesado para calcular a produtividade por unidade de área (Equação 1), com a correção da umidade.

$$\boldsymbol{Produtividade}\left(\frac{\boldsymbol{Sc}}{\boldsymbol{ha}}\right) = \frac{\left(\frac{\boldsymbol{Massa\ (kg)}}{\boldsymbol{0{,}9m^2}}\ \boldsymbol{x\ 10000m^2}\right)}{\boldsymbol{60kg}} \quad \textbf{(1)}$$

3.3 Aquisição das imagens de satélites

Foram obtidas 5 imagens (Tabela 1) da constelação de satélites planet que possui resolução espectral de 8 bandas (Tabela 2), resolução temporal de 1 dia, resolução espacial de 3 metros e radiométrica de 16 bits. Para cada ponto amostral da produtividade, delimitou-se um buffer dois metros de raio para a extração da refletância média de 7 bandas espectrais utilizando a ferramenta Zonal Statistics no QGIS, versão 3.28., visando capturar um número suficiente de pixels e mitigar efeitos de ruído local.

As sete bandas espectrais utilizadas, nesse caso não se utilizou a banda 1 (Azul Costeiro), tiveram seus valores divididos por 10.000 para obter a refletância real (em escala de 0 a 1) e foram usadas para cálculos de índice de vegetação (Tabela 3). A seleção desses índices considerou seu potencial em estimar a produtividade da cultura do milho, conforme evidências reportadas na literatura (BARZIN et al 2020; KUMAR et al., 2025).

Tabela 1. Resolução espectral do satélite PlanetScope.

Bandas	Nome	Comprimento de ondas (nm)
2	Azul	472
3	Verde 1	531
4	Verde	565
5	Amarelo	680
6	Vermelho	665
7	Borda do Vermelho	750
8	NIR	865

NIR: Infravermelho próximo, nm: nanômetro.

As imagens do satélite já são disponibilizadas com a correção da Refletância de Superfície, que proporciona maior consistência nas análises espectrais ao considerar as condições atmosféricas locais, reduzindo incertezas na resposta espectral. Esse processo aplica correções baseadas na refletância no topo da atmosfera (TOA – Top of Atmosphere), por meio de coeficientes específicos do produto Planet Radiance e Tabelas de Consulta (LUTs – Look-Up Tables) geradas pelo código de transferência radiativa 6SV2.1. Dessa forma, minimizam-se variações radiométricas e espaço-temporais que poderiam comprometer a interpretação dos dados (PlanetScope 2025).

Tabela 2. Datas de coleta em campo e das imagens orbitais após a semeadura.

DAS	Data dos imageamentos orbitais
42	23/01/2024
52	02/02/2024
62	12/02/2024
72	22/02/2024
79	29/02/2024

DAS: Dias após semeadura.

Tabela 3. Índices de Vegetação (IVs) usados como dados de entrada no modelo preditivo

Índices de Vegetação	**Equações**	**Referências**
CVI	(NIR / Yellow) x Red	Carter, G. A. (1994)
EVI	2.5 x (NIR - Red) / (L + NIR + C1 x Red - C2 x Blue)	Justice et al. (1998)
GNDVI	(NIR - Green) / (NIR + Green)	Gitelson e Merzlyak (1996)
MCARI	((RE - Red) - 0,2 x (RE - Green)) x (RE / Red)	Haboudane, D. et al. (2004)
NDRE	(NIR - RE) / (NIR + RE)	Filzgerald et al. (2010)
NDVI	(NIR - Red) / (NIR + Red)	Rouse et al. (1974)
OSAVI	(NIR - Red) / (NIR + Red +0,16)	Rondeaux, G. et al. (1996)
SAVI	(1 + L) x (NIR - Red) / (L + NIR + Red)	Huete (1988)
SCCCI	NDRE / NDVI	Fuchs, T. J., & Staenz, K. (2004)
SR	NIR / Red	Nascimento e McVey (1968)

CVI: Carter Visual Index; NIR: Near-Infrared; EVI: Enhanced Vegetation Index; GNDVI: Green Normalized Difference Vegetation Index; MCARI: Modified Chlorophyll Absorption in Reflectance Index; NDRE: Normalized Difference Red Edge Index; RE: Red Edge; NDVI: Normalized Difference Vegetation Index; OSAVI: Optimized Soil-Adjusted Vegetation Index; SAVI: Adjusted Vegetation Index; SCCCI: Soil and Chlorophyll Correction Index; SR: Simple Ratio; C1: 6 ; C2: 7,5; L: 0,5.

3.5 Análise dos dados

A caracterização estatística da produtividade de milho (kg ha^{-1}), foi feita a partir do cálculo da média, mediana, e do desvio padrão, e também utilizando um histograma, que permite visualizar a frequência e a distribuição dos valores de produtividade, e um boxplot que ofereceu um resumo estatístico robusto, evidenciando a tendência central, a dispersão e, a presença de pontos discrepantes (*outliers*). Na presença de outliers, estes foram removidos com o método do intervalo interquartílico (IQR) que definiu como discrepantes os pontos que se encontram abaixo de Q1 - 1.5 * IQR ou acima de Q3 + 1.5 * IQR, onde Q1 e Q3 são o primeiro e o terceiro quartil, respectivamente, e IQR foi a diferença entre eles (Q3 - Q1).

Para garantir a robustez do modelo preditivo e evitar distorções causadas pela redundância de informações, foi necessário tratar a alta correlação entre as 17 variáveis espectrais (sete bandas e dez índices de vegetação). Assim, as variáveis preditoras (7 bandas espectrais e 10 índices de vegetação) foram submetidas a uma análise de multicolinearidade usando o Fator de Inflação da Variância (VIF) (eq. 2), que mede o quanto a variância de um coeficiente de regressão está sendo aumentada devido à correlação entre variáveis independentes (Montgomery; Runger, 2016), tendo como critério de seleção de filtragem aquelas que apresentassem um valor de VIF inferior ao limiar de 5.

$$\boldsymbol{VIF = \frac{1}{1 - R_i^2}} \quad \textbf{(2)}$$

Onde, R_i^2 é o coeficiente de determinação da regressão da variável preditora *i* em relação a todas as outras variáveis preditoras.

3.5 Predição de produtividade

Após suavizar o efeito da não normalidade do dados de entrada e diminuir a multicolinearidade dos dados de saída, todas as variáveis do o banco de dados (entrada e saída) que não eram normalizadas foram normalizadas para padronizar as escalas, conforme a Equação 3 e, o banco de dados foi dividido em 80% dos dados para treinamento e 20% para teste.

$$\boldsymbol{y_i = \frac{X_i - X_{min}}{X_{max} - X_{min}}} \quad \textbf{(3)}$$

Em que: Xi representa o valor de entrada, e Xmin e Xmax são, respectivamente, os valores mínimo e máximo do conjunto de dados.

Os modelos preditivos da produtividade do milho foram baseados em duas arquiteturas de Redes Neurais Artificiais (RNAs), a *Multilayer Perceptron* (MLP) e *Radial Basis Function* (RBF). Os modelos foram rodados no software Statistica 7 (StatSoft, Inc., Tulsa, OK, EUA), utilizando a ferramenta *Intelligent Problem Solver* (IPS), que otimiza os hiperparâmetros e seleciona as variáveis de maior relevância.

O treinamento e o teste foram conduzidos automaticamente pelo IPS ao longo de 3000 iterações para cada arquitetura, utilizando o algoritmo de retropropagação do erro (*backpropagation*) uma técnica de aprendizado supervisionado que ajusta os pesos das conexões com base na diferença entre as saídas previstas e as desejadas (ZHANG et al., 2008). As arquiteturas utilizadas estão detalhadas na Tabela 4.

O IPS também forneceu a análise de sensibilidade, apontando a importância relativa de cada variável de entrada no desempenho dos modelos. Ao final do processo, foram retidos os dez melhores modelos de cada arquitetura, sendo o modelo com o melhor desempenho definido com base em métricas de acurácia como o MAE selecionado para a aplicação final na etapa de teste.

Tabela 4. Arquiteturas das redes neurais artificiais utilizadas: Radial Basis Function (RBF) e Multilayer Perceptron (MLP).

Arquitetura	Camadas ocultas	Saída
RBF	1 camada, 20 neurônios	Produtividade
MLP	2 camadas (20, 10 neurônios)	Produtividade

Legenda: RBF: Radial Basis Function; MLP: Multilayer Perceptron.

3.5.1 Multilayer Perceptron (MLP)

A arquitetura MLP é formada por neurônios organizados em camadas interligadas por conexões ponderadas conhecidas como pesos sinápticos, responsáveis por determinar a intensidade da comunicação entre os neurônios. O valor de saída de cada neurônio da camada K é dado por uma função de ativação $g(a_k)$, onde a_k corresponde à soma ponderada dos valores de entrada normalizados como expresso na Equação 4:

$$a_k = \sum_j y_j \cdot w_{kj} \quad (4)$$

Em que w_{kj} são os pesos que conectam cada entrada y_j ao neurônio k.

A função de ativação utilizada nas camadas ocultas foi a tangente hiperbólica, representada pela equação 5:

$$g(a_k) = \frac{e^{ak} - e^{-ak}}{e^{ak} + e^{-ak}} \quad (5)$$

Essa estrutura permite à MLP capturar padrões complexos nos dados, tornando-a adequada para tarefas de regressão e predição agrícola.

3.5.2 Radial Basis Function (RBF)

A arquitetura RBF, assim como a MLP, também possui múltiplas camadas, porém se diferencia pelo tipo de função de ativação utilizada. Enquanto a MLP emprega funções como a tangente hiperbólica ou sigmoide, a RBF utiliza funções de base radial em seus neurônios da camada oculta (BISHOP, 1995). A função mais comum é a gaussiana, que calcula a ativação de acordo com a distância entre o vetor de entrada e um ponto central, conforme a Equação 6:

$$\varphi = \exp\left(-\frac{v^2}{2\sigma^2}\right) \quad (6)$$

Em que $v = \|x - \mu\|$ representa a distância euclidiana entre o vetor de entrada e o centro μ da função, e σ corresponde à largura da base. Essa abordagem permite que as RBFs sejam altamente eficazes em problemas que envolvem relações não lineares complexas, como a previsão da produtividade agrícola (HAYKIN, 1998).

3.5.3 Métrica de desempenho

A avaliação do desempenho dos modelos foi realizada por meio do gráfico de barras com linha sobreposta do erro médio absoluto (MAE) calculado no software Statistica 7, conforme a Equação 7.

$$MAE = \frac{1}{n}\sum_{i=1}^{n}\left(Y_i - \hat{Y}_i\right) \quad (7)$$

Em que: n representa o número de observações, $\hat{Y}_i$ o valor estimado pelo modelo, e Y_i o valor observado em campo.

4. RESULTADOS

4.1 Análise Descritiva dos Dados de Produtividade

A análise dos 80 pontos amostrais revelou uma considerável variabilidade na produtividade de milho na área de estudo. A produtividade média observada foi de 3.517,6 kg ha^{-1}, com uma mediana de 3.234,2 kg ha^{-1}. O desvio padrão de 1.484,1 kg ha^{-1} confirma a alta dispersão dos dados em torno da média. A distribuição dos dados se mostrou assimétrica à direita (positiva), evidenciada tanto pelo histograma (Figura 8.a), que concentra a maior parte dos dados em valores mais baixos e apresenta uma "cauda" longa para valores mais altos, quanto pela mediana ser inferior à média. Os valores de produtividade variaram de um mínimo de 947,56 kg ha^{-1} a um máximo de 8.496,4 kg ha^{-1}. O boxplot (Figura 8.b) destacou visualmente a presença de 7 pontos discrepantes (outliers), localizados acima do limite superior.

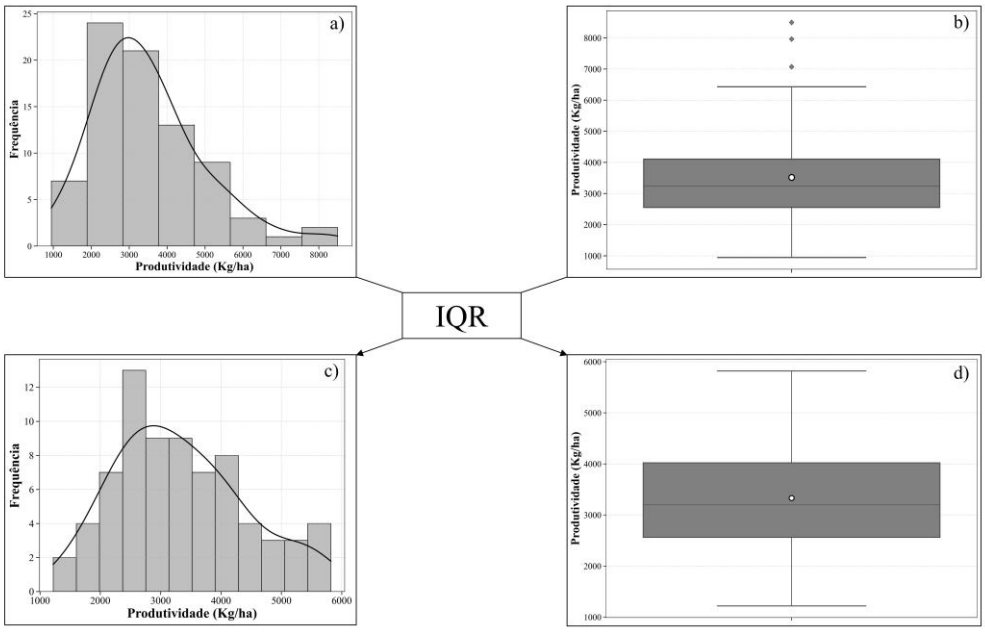


Figura 8. Análise descritiva da produtividade de milho. A) histograma das amostras da produtividade e B) boxplot de amostras da produtividade do milho.

O método do intervalo interquartílico (IQR), removeu, os outliers tornando os dados com uma distribuição adequada (Figura 8.cd), resultando em um novo conjunto de dados com 73 pontos amostrais. Essa filtragem tornou o conjunto de dados mais homogêneo, como pode ser observado pela alteração das estatísticas descritivas (Tabela 5), em que a produtividade média que era 3517,6 kg ha^{-1} foi ajustada para 3.330,7 kg ha^{-1}, valor agora mais próximo da nova mediana de 3.196,2 kg ha^{-1}, indicando uma distribuição mais simétrica. O desvio padrão foi reduzido para 1.082,1 kg ha^{-1}, refletindo a menor variabilidade dos dados. O valor máximo de produtividade foi reduzido para 5.820 kg ha^{-1}, eliminando os picos que poderiam enviesar a capacidade de generalização dos modelos de Redes Neurais Artificiais.

Tabela 5. Comparação dos dados antes de depois da aplicação do método IQR.

Métrica Estatística	Dados Originais (n=80)	Dados Pós-IQR (n=73)
Média	3.517,6 kg ha^{-1}	3.330,7 kg ha^{-1}
Mediana	3.234,2 kg ha^{-1}	3.196,2 kg ha^{-1}
Desvio Padrão	1.484,1 kg ha^{-1}	1.082,1 kg ha^{-1}
Mínimo	947,6 kg ha^{-1}	1.220,22 kg ha^{-1}
Máximo	8.496,4 kg ha^{-1}	5.820 kg ha^{-1}

4.2 Análise de Multicolinearidade das Variáveis

Das 17 variáveis de entrada (bandas e índices de vegetações), o Fator de Inflação de Variância (VIF) selecionou quatro variáveis de entrada (Tabela 6). Era esperado que a análise VIF eliminasse grande parte das variáveis iniciais. Isso ocorre porque os índices de vegetação nada mais são do que equações matemáticas aplicadas sobre as bandas espectrais. Ao alimentar o modelo com a banda bruta e o índice derivado dela, cria-se uma repetição da mesma informação espectral. Essa multicolinearidade, se não tratada, confunde o modelo e reduz sua precisão, tornando a seleção de variáveis uma etapa obrigatória para garantir a robustez da predição.

Tabela 6. Variáveis preditoras selecionadas para a predizer a produtividade de milho após a análise de multicolinearidade.

Tipo de Variável	Nome da Variável
Banda Espectral	Verde (B4)
Banda Espectral	NIR (B8)
Índice de Vegetação	CVI
Índice de Vegetação	SCCCI

4.3 Desempenho dos Modelos de Redes Neurais Artificiais

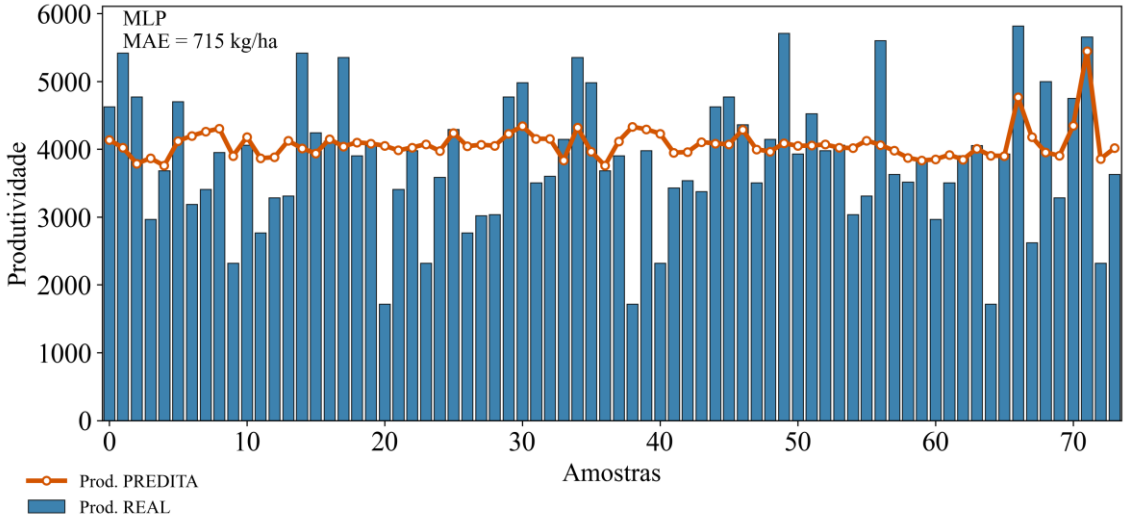


Figura 9. Gráfico de dispersão entre a produtividade (kg/ha) de milho observada e a predita pelo modelo de RNA com arquitetura MLP.

O modelo MLP demonstrou uma capacidade de predição moderada, alcançando um Erro Médio Absoluto (MAE) de 715 kg ha^{-1} (Figura 9). A análise do gráfico revela que, embora a produtividade predita (linha laranja) tenda a acompanhar o comportamento da produtividade real (Barra azul), há uma tendência do modelo a superestimar os valores de produtividade, evidenciada pela presença de um número considerável de pontos acima da linha, aproximadamente 62% dos dados. Além disso, observa-se uma maior dificuldade do modelo em predizer os valores extremos, tanto os mais baixos quanto os mais altos de produtividade, concentrando as predições em uma faixa mais central de valores.

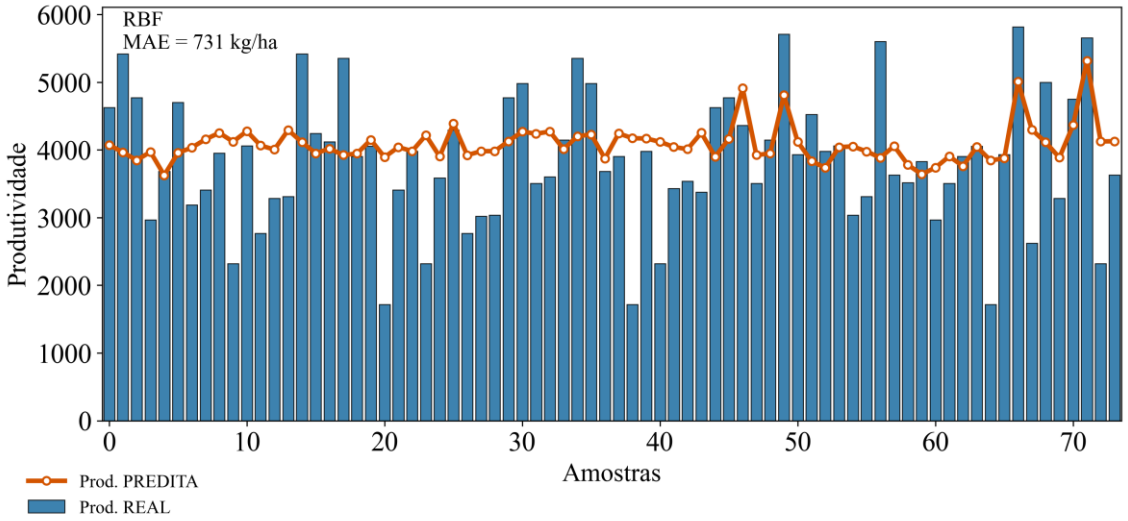


Figura 10. Gráfico de dispersão entre a produtividade (kg/ha) de milho observada e a predita pelo modelo de RNA com arquitetura RBF.

O modelo RBF apresentou um desempenho ligeiramente inferior ao MLP, alcançando um Erro Médio Absoluto (MAE) de 731 kg ha^{-1} (Figura 10). A principal característica observada no desempenho deste modelo foi também sua tendência a superestimar a produtividade, aproximadamente 60%. O modelo tenta acompanhar a produtividade real, apesar dos dados e aplicações dos métodos ainda assim, apresenta-se um erro considerável. Assim como o MLP, o modelo RBF também demonstrou limitações na predição dos valores extremos de produtividade.

5. DISCUSSÃO

Os dados de produtividade coletados em campo apresentaram, inicialmente, alta variabilidade espacial e distribuição não normal. Esse comportamento é frequentemente observado em dados agrícolas devido a fatores heterogêneos como manchas de solo, competição de plantas e ataques localizados de pragas, que geram assimetria na curva de distribuição (SHIRATSUCHI et al., 2023). A aplicação do método do Intervalo Interquartílico (IQR) foi fundamental, pois possibilitou a remoção eficaz de outliers. Estatisticamente, outliers representam valores extremos que distorcem a média e inflacionam a variância, afastando a distribuição dos dados da curva normal (Gaussiana). Segundo Triola (2008), a presença desses valores viola os pressupostos básicos de muitos modelos estatísticos, inserindo ruído que prejudica o aprendizado de padrões. Ao filtrar esses extremos com o IQR, suavizou-se a não normalidade, permitindo que as redes

neurais treinassem sobre padrões agronômicos representativos e não sobre anomalias estocásticas.

No que tange aos dados de entrada (variáveis preditoras), compostos exclusivamente por dados espectrais, a alta multicolinearidade era esperada. A multicolinearidade ocorre quando duas ou mais variáveis independentes possuem forte correlação entre si, transmitindo informações redundantes ao modelo (HAIR et al., 2009). Isso torna a estimativa dos pesos da rede instável e dificulta a interpretação da importância de cada variável.

Neste contexto, a análise pelo Fator de Inflação da Variância (VIF) mostrou-se eficiente ao selecionar apenas as bandas do Verde e NIR, e os índices CVI e SCCCI. Respondendo à questão sobre a exclusão das demais variáveis: o limite rigoroso de VIF (< 5) forçou a retirada de bandas e índices que eram, essencialmente, combinações lineares dos selecionados. Por exemplo, o índice GNDVI [(NIR - Verde) / (NIR + Verde)] foi excluído justamente porque sua variância já é explicada pelas bandas isoladas do NIR e do Verde, que foram mantidas pelo modelo. A inclusão de ambos geraria redundância matemática, sem ganho de informação agronômica.

A permanência dessas quatro variáveis de entrada (Verde, NIR, CVI, SCCCI) se justifica fisiologicamente e explica a robustez do modelo:

Banda do Verde e NIR: São a base do sensoriamento. A banda do Verde é sensível ao conteúdo de pigmentos fotossintéticos, enquanto o Infravermelho Próximo (NIR) é governado pela estrutura do mesofilo foliar e pela densidade de biomassa (JENSEN, 2009).

CVI (Chlorophyll Vegetation Index): Selecionado por incorporar a banda do Amarelo (além do Vermelho e NIR). A banda do amarelo aumenta a sensibilidade a sutis alterações na clorofila que não são captadas apenas pelo verde ou vermelho, tornando-o um indicador preciso do estado nutricional, especialmente nitrogênio.

SCCCI (Soil-Adjusted Canopy Chlorophyll Index): Sua seleção foi estratégica e diferencial. Diferente do NDVI, que tende a saturar em altos índices de área foliar (comuns no milho em pleno desenvolvimento), o SCCCI incorpora a banda do Red Edge. Essa região espectral é crítica para monitorar a transição entre absorção de clorofila e espalhamento de biomassa, permitindo que o índice mantenha a sensibilidade mesmo em

dosséis densos, como observado também em estudos de Kumar et al. (2025) e Shiratsuchi et al. (2011).

Quanto à modelagem, a leve superioridade da arquitetura Multilayer Perceptron (MLP) sobre a Radial Basis Function (RBF) merece destaque. A diferença reside na estrutura de aprendizado: a RBF utiliza funções de ativação locais (Gaussianas) que agrupam dados por proximidade (clusters), o que pode ser limitante se a relação entre as variáveis não for estritamente local. Já a MLP realiza uma aproximação global através de produtos escalares e funções sigmoides em múltiplas camadas, o que lhe confere maior flexibilidade para traçar hiperplanos de decisão complexos (HAYKIN, 2001). Essa capacidade de modelar a não linearidade global dos dados permitiu à MLP capturar melhor as nuances entre a resposta espectral e a produtividade final do milho, corroborando resultados observados por Oliveira (2024) em outras culturas.

Ao comparar com a literatura recente, observa-se uma convergência de resultados, mesmo com diferentes plataformas. Kumar et al. (2025), utilizando VANTs (drones), também identificaram o SCCCI como preditor crucial entre 30 variáveis testadas. O fato de este estudo, utilizando dados orbitais (satélite PlanetScope), chegar à mesma conclusão reforça que o SCCCI é um biomarcador robusto da produtividade do milho, independente da escala de aquisição. Contudo, a metodologia aqui validada apresenta vantagem logística para grandes áreas, superando as limitações operacionais de cobertura dos VANTs.

Por fim, a validação de um modelo preditivo com erro controlado (MAE satisfatório) tem implicações práticas diretas para a Agricultura de Precisão. A variabilidade espacial mapeada permite:

Regulagem de Colhedoras: O conhecimento prévio da produtividade permite o ajuste automático da velocidade de avanço e da rotação do cilindro trilhador, reduzindo perdas na colheita (ZERBATO et al., 2014; SILVA; FRANCETTO, 2025).

Delineamento de Zonas de Manejo: A identificação de padrões estáveis de alta e baixa produtividade subsidia a criação de zonas para amostragem de solo dirigida e investigações de causas raiz (compactação, fertilidade) (SHIRATSUCHI et al., 2023).

Mapas de Prescrição: A predição antecipada possibilita a aplicação de adubação nitrogenada em taxa variável na safrinha subsequente ou correções localizadas, otimizando o uso de insumos (SHIRATSUCHI et al., 2011).

6. CONCLUSÃO

O processamento dos dados, através do método do Intervalo Interquartílico (IQR) e da análise do Fator de Inflação da Variância (VIF), demonstrou ser uma etapa metodológica eficaz para a suavização da não normalidade dos dados de saída e diminuição da multicolinearidade dos dados de entrada para os modelos preditivos.

Os modelos de Redes Neurais Artificiais desenvolvidos, utilizando as arquiteturas Multilayer Perceptron (MLP) e Radial Basis Function (RBF), conseguiram observar a não linearidade dos dados de entrada e de saída e alcançaram um desempenho preditivo satisfatório para o milho, alcançando baixos valores de Erro Médio Absoluto (MAE), tendo modelo MLP leve desempenho superior ao RBF.

Como recomendações para trabalhos futuros recomenda-se a validação desta metodologia em trabalhos futuros. Para aumentar a robustez dos modelos, recomenda-se ampliar o conjunto de dados por meio de novas coletas em campo, inclusão de áreas adicionais e de diferentes cultivares. A expansão do banco de dados tende a melhorar a acurácia e a capacidade de generalização, aumentando a confiabilidade na predição da produtividade de milho. Aumentar o número de amostras, utilizando outros híbridos de milho e abrangendo diferentes condições ambientais (outras safras e regiões), poderá aumentar a eficiência e a capacidade de generalização do modelo. Isso consolidaria a técnica como uma ferramenta prática e robusta para a agricultura de precisão, facilitando a tomada de decisão no manejo e na otimização da colheita.

7. REFERÊNCIAS

ABIMILHO – ASSOCIAÇÃO BRASILEIRA DAS INDÚSTRIAS DO MILHO. **Consumo de milho no Brasil: 24/25**. [S. l.], 2025. Disponível em: https://www.abimilho.com.br/estatisticas. Acesso em: 1 jun. 2025.

BARZIN, R. et al. Use of UAS multispectral imagery at different physiological stages for yield prediction and input resource optimization in corn. **Remote Sensing**, Basel, v. 12, n. 15, p. 2392, 2020.

BERNARDI, A. C. de C. et al. (Org.). **Agricultura de precisão**: resultados de um novo olhar. Brasília, DF: Embrapa, 2014.

BIRTH, G. S.; MCVEY, G. R. Measuring the color of growing turf with a reflectance spectrophotometer. **Agronomy Journal**, Madison, v. 60, n. 6, p. 640–643, 1968.

BRANDÃO, Z. N. et al. Agricultura de precisão para gerenciamento do algodão. In: AZEVÊDO, D. M. P.; BELTRÃO, N. E. M. (Org.). **O agronegócio do algodão no Brasil**. Brasília, DF: Embrapa Informação Tecnológica, 2008. v. 2, cap. 20.

CARTER, G. A. Ratios of leaf reflectances in narrow wavebands as indicators of plant stress. **International Journal of Remote Sensing**, London, v. 15, n. 3, p. 697–703, 1994.

EMBRAPA. **Características da planta**. Brasília, DF: Agência Embrapa de Informação Tecnológica, 2020. Disponível em: https://www.embrapa.br/en/agencia-de-informacao-tecnologica/cultivos/milho/pre-producao/caracteristicas-da-especie-e-relacoes-com-o-ambiente/caracteristicas-da-planta. Acesso em: 9 jun. 2025.

FITZGERALD, G. J. et al. Spectral and thermal sensing for nitrogen and water status in rainfed and irrigated wheat environments. **Precision Agriculture**, Dordrecht, v. 11, n. 6, p. 572–589, 2010.

FUCHS, T. J.; STAENZ, K. Spectral feature selection for classification of hyperspectral data. In: INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION, 17., 2004, Cambridge. **Proceedings** [...]. [S. l.]: IEEE, 2004. v. 2, p. 867–870.

GITELSON, A. A.; MERZLYAK, M. N. Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. **Journal of Plant Physiology**, Jena, v. 148, n. 3-4, p. 494–500, 1996.

HABOUDANE, D. et al. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture. **Remote Sensing of Environment**, New York, v. 90, n. 3, p. 337–352, 2004.

HAIR, J. F. et al. **Análise multivariada de dados**. 6. ed. Porto Alegre: Bookman, 2009.

HAYKIN, S. **Redes neurais**: princípios e prática. 2. ed. Porto Alegre: Bookman, 2001.

HUETE, A. R. A soil adjusted vegetation index (SAVI). **Remote Sensing of Environment**, New York, v. 25, n. 3, p. 295–309, 1988.

JENSEN, J. R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. Tradução de José Carlos Neves Epiphanio et al. 2. ed. São José dos Campos: Parêntese, 2009.

JUSTICE, C. O. et al. The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 36, n. 4, p. 1228–1249, 1998.

KUJAWA, S.; NIEDBAŁA, G. Artificial neural networks in agriculture. **Agriculture**, Basel, v. 11, n. 6, p. 497, 2021.

KUMAR, C. et al. Explainable machine learning models for corn yield prediction using UAV multispectral data. **Computers and Electronics in Agriculture**, Amsterdam, v. 231, art. 109990, 2025.

LUDERMIR, T. B. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, São Paulo, v. 35, n. 101, p. 85-104, 2021.

MANTOVANI, E. C. **Perdas na colheita**. Sete Lagoas: Embrapa Milho e Sorgo, 2021. (Agência Embrapa de Informação Tecnológica). Disponível em: https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/milho/producao/colheita-e-pos-colheita/perdas-na-colheita. Acesso em: 1 jun. 2025.

MENESES, K. C. de. **Rumo à agricultura inteligente**: previsão de produtividade agrícola com dados agrometeorológicos usando machine learning. 2021. 97 f. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista "Júlio de Mesquita Filho", Jaboticabal, 2021.

MITCHELL, T. M. **Machine Learning**. New York: McGraw-Hill, 1997.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística aplicada e probabilidade para engenheiros**. 6. ed. Rio de Janeiro: LTC, 2016.

OLIVEIRA, R. P.; WHELAN, B. M.; MCBRATNEY, A. A. A segmentation approach to delineate zones for differential nitrogen interventions. In: STAFFORD, J. V. (Ed.). **Precision agriculture '13**. Wageningen: Wageningen Academic Publishers, 2013. p. 411-418.

OLIVEIRA, T. C. M. **Combinação de informações e tecnologias para aperfeiçoar a estimativa da maturação remota de vagens de amendoim**. 2024. Dissertação (Mestrado em Agronomia) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista "Júlio de Mesquita Filho", Jaboticabal, 2024.

PINTER, P. J. et al. Remote sensing for crop management. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v. 69, n. 6, p. 647-664, 2003.

RONDEAUX, G.; SEGUY, L.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, New York, v. 55, n. 2, p. 95–107, 1996.

ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. In: EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM, 3., 1974, Washington, D.C. **Proceedings** [...]. Washington, D.C.: NASA, 1974. p. 309–317. (NASA SP-351).

SANTOS, R. Inteligência artificial em prol da agricultura. **Agroanalysis**, Rio de Janeiro, v. 40, n. 12, p. 30-31, dez. 2020.

SARTORI, A. A. C.; MORAES, D. A. C. **Inteligência dos satélites como suporte no monitoramento de cultivos agrícolas**. Botucatu: FCA/UNESP, 2010. (Nota: Verifique se este é um boletim técnico ou artigo de evento, a citação está genérica).

SHIRATSUCHI, L. S. et al. Desenvolvimento de um algoritmo baseado em sensores ativos de dossel para recomendação da adubação nitrogenada em taxas variáveis. In: INAMASU, R. Y. et al. (Org.). **Agricultura de precisão**: um novo olhar. São Carlos: Embrapa Instrumentação, 2011. p. 184–188.

SHIRATSUCHI, L. S. et al. Sensoriamento remoto: conceitos básicos e aplicações na Agricultura de Precisão. In: INAMASU, R. Y. et al. (Org.). **Agricultura de precisão**: um novo olhar na era digital. Brasília, DF: Embrapa, 2023. p. 58–72.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais**: para engenharias e ciências aplicadas. São Paulo: Artliber, 2016.

SILVA, R. P.; FRANCETTO, T. R. **Manual de máquinas agrícolas**: volume II. Jaboticabal: Funep, 2025.

TRIOLA, M. F. **Introdução à estatística**. 10. ed. Rio de Janeiro: LTC, 2008.

UNICEF – FUNDO DAS NAÇÕES UNIDAS PARA A INFÂNCIA. **Desnutrição infantil**: causas, consequências e ações urgentes. [S. l.], 2024. Disponível em: https://www.unicef.org. Acesso em: 1 jun. 2025.

ZERBATO, C. et al. Controle estatístico de processo aplicado à colheita mecanizada de milho. **Engenharia Agrícola**, Jaboticabal, v. 34, n. 2, p. 269-278, mar./abr. 2014.

ZHANG, L. et al. A new sub-pixel mapping algorithm based on a BP neural network with an observation model. **Neurocomputing**, Amsterdam, v. 71, n. 10-12, p. 2046–2054, 2008.