

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
CAMPUS DE CHAPADÃO DO SUL

MERITE RAYMONDE GBENANKPON SOHO

**PREDIÇÃO DA PRODUTIVIDADE DE LINHAGENS ENDOGÂMICAS
DE MILHO UTILIZANDO ÍNDICES DE VEGETAÇÃO E APRENDIZAGEM
DE MÁQUINA**

CHAPADÃO DO SUL-MS

2024

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
CAMPUS DE CHAPADÃO DO SUL

**PREDIÇÃO DA PRODUTIVIDADE DE LINHAGENS ENDOGÂMICAS
DE MILHO UTILIZANDO ÍNDICES DE VEGETAÇÃO E APRENDIZAGEM
DE MÁQUINA**

Trabalho de Conclusão de curso apresentado à
Universidade Federal de Mato Grosso do Sul,
como parte dos requisitos para obtenção do
título de Engenheiro Agrônomo.

Orientador: Prof(a). Dr(a). Larissa
PereiraRibeiro Teodoro

CHAPADÃO DO SUL-MS

2024



Serviço Público Federal
Ministério da Educação
Fundação Universidade Federal de Mato Grosso do Sul



CERTIFICADO DE APROVAÇÃO

AUTORA: **MÉRITE RAYMONDE GBENANKPON SOHO.**

ORIENTADORA: **Profa. Dra. Larissa Pereira Ribeiro Teodoro**

Aprovada pela Banca Examinadora como parte das exigências do Componente Curricular Não Disciplinar TCC, para obtenção do grau de BACHARELA EM AGRONOMIA, pelo curso de Bacharelado em Agronomia da Universidade Federal de Mato Grosso do Sul, Câmpus de Chapadão do Sul.

Profa. Dra. Larissa Pereira Ribeiro Teodoro
Presidente da Banca Examinadora e Orientador

Dra. Dthenifer Cordeiro Santana
Membro da Banca Examinadora

Prof. Dr. Paulo Eduardo Teodoro
Membro da Banca Examinadora

Chapadão do Sul, 21 de novembro de 2024.

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Larissa Pereira Ribeiro, Professora do Magistério Superior**, em 21/11/2024, às 16:33, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Paulo Eduardo Teodoro, Professor do Magisterio Superior**, em 21/11/2024, às 16:34, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

NOTA
MÁXIMA
NO MEC

UFMS
É 10!!!



Documento assinado eletronicamente por **Dthenifer Cordeiro Santana, Usuário Externo**, em 22/11/2024, às 14:53, conforme horário oficial de Mato Grosso do Sul, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufms.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **5263651** e o código CRC **1650B01D**.

COORDENAÇÃO DE GESTÃO ACADÊMICA DO CÂMPUS DE CHAPADÃO DO SUL

Câmpus de Chapadão do Sul - Rod

MS 306, Km 105, Caixa Postal 112

Fone:

CEP 79560-000 - Chapadão do Sul -
MS

Referência: Processo nº 23455.000700/2024-37

2

SEI nº5263651

2

https://sei.ufms.br/sei/controlador.php?acao=documento_imprimir_web&acao_origem=arvore_visualizar&id_documento=6046816&infra_sistema=100...

AGRADECIMENTOS

Agradeço a Deus pela oportunidade de realizar meu sonho de estudar em uma universidade estrangeira, em especial ao Campus de Chapadão do Sul da Universidade Federal de Mato Grosso do Sul, e aos seus colaboradores. Ao Programa de Estudantes-Convênio de Graduação (PEC-G) pelo qual ingressei na UFMS. E à política de auxílios estudantis que foram fundamentais à minha manutenção durante minha formação.

Agradeço aos meus pais que em meio a tantas dificuldades sempre apoiaram e investiram nos meus sonhos, na minha viagem e meus estudos, me incentivando, e sempre acreditando no meu potencial.

Agradeço, à minha orientadora Profa. Dra. Larissa Pereira Ribeiro Teodoro, que despertou meu interesse pelo melhoramento de plantas através da sua disciplina de genética aplicada a agronomia e a oportunidade de participar do grupo de estudos de Genética e Melhoramento de Plantas e a todos os integrantes do grupo de estudos que participarão dessa pesquisa.

Agradeço ao meu namorado, que sempre foi meu companheiro durante toda essa jornada desde o início, estando ao meu lado dia após dia. Seu apoio e incentivo foram valiosos.

Agradeço a todos os amigos que compartilharam desta jornada.

Por último, e de maior relevância, agradeço ao governo Brasileiro pela oportunidade.

SUMÁRIO

	Página
LISTA DE TABELAS	Vii
LISTA DE FIGURAS	viii
RESUMO	1
ABSTRACT	2
1. INTRODUÇÃO	3
2. MATERIAL E MÉTODOS	5
Condução do experimento	5
Aquisição e processamento das imagens multiespectrais.....	5
Processamento dos dados	7
3. RESULTADO	8
4. DISCUSSÃO	10
5. CONCLUSÕES	14
6. REFERÊNCIAS BIBLIOGRÁFICAS	15
7. MATERIAL SUPLEMENTAR.....	23

LISTA DE TABELAS

	Página
S1. Relação dos índices de vegetação	23

LISTA DE FIGURAS

	Página
1. Aeronave remotamente pilotada (RPA) de asa fixa Sensefly eBee RTK.....	6
2. Sensor multiespectral Parrot Sequoia.....	7
3. Gráfico de boxplot para métrica de correlação de Pearson (r) entre os inputs.....	8
4. Gráfico de boxplot para erro médio absoluto (MAE).....	9
5. Gráfico de boxplot para métrica Raiz quadrada do erro-médio (RMSE).....	9

PREDIÇÃO DA PRODUTIVIDADE DE LINHAGENS ENDOGÂMICAS DE MILHO UTILIZANDO ÍNDICES DE VEGETAÇÃO E APRENDIZAGEM DE MÁQUINA

Resumo

A predição produtividade de linhagem endogâmica de milho é crucial na agricultura moderna por auxiliar nas tomadas de decisões das empresas de melhoramento genético, dar suporte a gestão de culturas durante as pesquisas, proporcionar um monitoramento mais ágil das parcelas de ensaios. Entretanto, essa tarefa é desafiadora, já que a associação de dados espectrais com um tipo de algoritmo de Aprendizado de Máquina (ML) ideal para prever a produtividade das culturas ainda não é bem estabelecida. Desse modo, o objetivo deste trabalho foi prever a produtividade do milho usando bandas espectrais e a produtividade de grãos de duas safras como dados de base para testar o desempenho de seis algoritmos de ML diferentes. O experimento foi implementado nas safras 2023 e 2023/2024 na Universidade Federal de Mato Grosso do Sul (UFMS), Campus de Chapadão do Sul. O delineamento experimental adotado foi o de blocos aumentados, com 100 linhagens endogâmicas de milho e 10 variedades de polinização aberta utilizadas como testemunhas. A coleta de imagens espectrais foi realizada com auxílio de uma aeronave remotamente pilotada (RPA) e submetidas a análise estatística. Os valores de refletância foram obtidos nas seguintes bandas espectrais (SBs): azul (475 nm), vermelho (660 nm), verde (550 nm), Rededge (735 nm) e NIR (790 nm). As imagens foram processadas e foi feito o cálculo de 42 índices de vegetação (IVs). Os dados foram submetidos às análises de ML, testando três tipos de inputs: usando apenas IVs, usando apenas SBs e usando IVs+SBs como configuração de entrada. Os modelos de aprendizagem de máquina avaliados foram: Redes neurais artificiais (RNA), árvore de decisão REPTree (DT) e M5P; Floresta aleatória (RF); Máquina de vetor suporte (SVM) e ZeroR (utilizado como modelo controle). As acurácias dos modelos de predição foram avaliadas através das métricas coeficientes de correlação (r), erro médio absoluto (MAE) e raiz do erro quadrático médio (RMSE). Os algoritmos RNA, DT, M5P, RF e SVM tiveram acurácia superior a 0,6 mas M5P e SVM obtiveram as maiores precisões. Não houve diferença significativa de acurácia entre os inputs testados, possibilitando o uso de apenas SB.

Palavras-chave: *Zea mays*, árvore de decisão (M5P), máquina de vetor suporte (SVM), redes neurais artificiais (RNA)

PREDICTING THE PRODUCTIVITY OF CORN INBROOD LINES USING VEGETATION INDEXES AND MACHINE LEARNING

Abstracts

Predicting the productivity of inbred corn is crucial in modern agriculture because it helps genetic improvement companies make decisions, supports crop management during research, and provides more agile monitoring of trial plots. However, this task is challenging, since the association of spectral data with an ideal type of Machine Learning (ML) algorithm to predict crop productivity is not yet well established. Thus, the objective of this work was to predict corn yield using spectral bands and grain yield of two harvests as base data to test the performance of six different ML algorithms. The experiment was implemented in the 2023 and 2023/2024 harvests at the Federal University of Mato Grosso do Sul (UFMS), Chapadão do Sul Campus. The experimental design adopted was that of increased blocks, with 100 inbred corn lines and 10 open-pollinated varieties used as controls. The experiment was implemented in the 2023 and 2023/2024 harvests at the Federal University of Mato Grosso do Sul (UFMS), Chapadão do Sul Campus. The experimental design adopted was that of increased blocks, with 100 inbred corn lines and 10 open-pollinated varieties used as controls. Spectral image collection was performed with the aid of a remotely piloted aircraft (RPA) and subjected to static analysis. Reflectance values were obtained in the following spectral bands (SBs): blue (475 nm), red (660 nm), green (550 nm), Rededge (735 nm) and NIR (790 nm). The images were processed and 42 vegetation indices (VIs) were calculated. The data were subjected to ML analyses, testing three types of inputs: using only IVs, using only SBs and using IVs+SBs as input configuration. The machine learning models evaluated were: Artificial neural networks (ANN), REPTree decision tree (DT) and M5P; Random Forest (RF); Support vector machine (SVM) and ZeroR (used as a control model). The efficiency of the prediction models was evaluated through the metrics correlation coefficients (r), mean absolute error (MAE) and root mean square error (RMSE). The algorithms RNA, DT, M5P, RF and SVM had accuracy higher than 0.6 but M5P and SVM obtained the highest accuracies. There was no significant difference in accuracy between the inputs tested, allowing the use of only SB.

Keywords: *Zea mays*, decision tree (M5P), support vector machine (SVM), artificial neural networks (ANN)

Introdução

A evolução do melhoramento genético do milho representa um dos avanços mais importantes da agricultura moderna, sendo crucial para o aumento da produtividade e a adaptação das culturas em condições adversas de campo e demandas do mercado. Originário das Américas, especialmente da região central do México, o milho (*Zea mays* L.) é uma das culturas agrícolas mais importantes do mundo, desempenhando um papel fundamental não apenas na alimentação de milhões de pessoas, mas também na nutrição animal e na indústria como matéria-prima em diversas indústrias, como a de biocombustíveis, ração animal e produção de amido (CONTINI et al., 2019). O Brasil, sendo o terceiro maior produtor mundial da cultura, com estimativa de volume da produção de grãos para safra 2024/2025 de 119,74 milhões de toneladas disponibiliza principalmente dois tipos de cultivares comerciais de milho: variedades e híbridos de linhagem completamente endogâmica (Conab,2024).

Diversas pesquisas têm demonstrado que vários fatores, como a qualidade do solo, variações nos períodos de plantio, uso de fertilizantes e diferentes práticas de manejo, influenciam o metabolismo das plantas, resultando em uma produção de grãos maior ou menor. Devido ao aumento populacional no mundo, a demanda do mercado será cada vez maior, tornando a previsão de rendimento das safras futuras um fator de alta importância (SUN et al., 2020).

Prever a produtividade de linhagem endogâmica de milho é importante na agricultura moderna para auxiliar nas tomadas de decisões das empresas de melhoramento genética, dar suporte a gestão de culturas durante as pesquisas, proporcionar um monitoramento mais ágil das parcelas, apresentar sementes de qualidade aos produtores, assim como agregar valor adequado ao produto colhido, já que essa linhagem cresce muito menos devido à elevada depressão por endogamia no milho (MENDES et al., 2013). Na cultura do milho, a produção de linhagens endogâmicas consiste na autofecundação de plantas selecionadas por vários ciclos, visando obter genótipos homozigotos. As plantas obtidas conferem melhores características que são mantidas por contínuas autofecundações, mas produzem poucas sementes, o que lhes confere um alto valor de mercado. Visando aumentar as futuras produtividades das lavouras com antecedência, diferentes métodos como aprendizado de máquina (ML), modelos estatísticos e abordagens genômicas, estão sendo explorados para melhorar a precisão das previsões de rendimento do milho (MEDINA et al.,2021).

Para isso imagens espectrais são coletadas utilizando uma aeronave remotamente pilotada (RPA) acoplado a um sensor multiespectral que disponibilizam um universo vasto de informações, tornando o uso de técnicas de ML uma opção para o tratamento de dados espectrais (EUGÊNIO et al., 2020). Os algoritmos de Redes Neurais Artificiais (RNAs), Florestas Aleatórias (RFs), Máquinas de Vetores de Suporte (SVMs) e Árvores de Decisão são comumente empregados em estudos de predição de rendimento com imagens espectrais visando a melhoria da precisão.

Os Sensores multiespectrais acoplado ao RPA têm a capacidade de capturar informações espectrais das culturas em desenvolvimento de forma rápida em toda a área plantada (BARZIN et al., 2022). Ele realiza a medição simultânea da refletância em três comprimentos de onda de forma contínua, o que possibilita o cálculo de Índices de Vegetação (VIs). Um índice de vegetação é um valor único obtido por meio de combinações matemáticas de diferentes comprimentos de onda espectrais. Esses índices podem ser aplicados para estimar diversas características fisiológicas, como biomassa, área foliar, cobertura vegetal e conteúdo de clorofila foliar, em distintos estágios de crescimento e para diversas culturas (HATFIELD et al., 2010).

Atualmente, técnicas de ML visando a predição da produtividade com base em variáveis espectrais obtidas por sensores acoplados em aeronave remotamente pilotada (RPA) estão sendo aplicadas em diversas culturas, como algodão (SIEGFRIED et al.,2023, ASHAPURE et al.,2020), soja (DA SILVA et al.,2020), cana-de-açúcar (VANI et al.,2015); trigo (BIAN et al.,2022 ; DHAKAR et al., 2014 ; TANABE et al.,2023), batata (JEONG et al.,2016), sorgo (SANTANA et al.,2024), tomate (SENTHILNATH et al., 2016), arroz (BASCON et al.,2022; WAN et al.,2020; ZHOU et al., 2017; TIAN et al.,2020).

Além das várias vantagens existentes, os dados gerados por imagens espectrais são extremamente complexos e volumosos, tornando as técnicas de ML uma alternativa eficaz para o processamento desse tipo dados (EUGÊNIO et al., 2020). As imagens de sensoriamento remoto (RS) e suas características derivadas como bandas espectrais (SB) e índices de vegetação (IVs) podem ser utilizadas como substitutos para dados como fenologia, temperatura e teores nutricionais na previsão de rendimento das culturas. Essas bandas fornecem aos algoritmos informações diretas sobre o crescimento das plantas em etapas que influenciam o rendimento ou todo o ciclo fenológico. Por exemplo, a produtividade do trigo foi prevista com sucesso com o algoritmo SVM quando o Índice de Vegetação Melhorado (EVI) e o Índice de Vegetação por Diferença

Normalizada (NDVI) foram aplicados durante a fase de maturação (HAN et al.,2020; SHAFIEE et al.,2021).

Diante deste cenário, os objetivos do estudo foram identificar qual a configuração de entrada (utilizando somente SB, somente IVs ou ambos) e quais algoritmos de ML proporcionam maior acurácia na predição do rendimento de grãos de linhagem endogâmica de milho.

Material e métodos

Condução do experimento

O experimento foi realizado durante a segunda safra de 2023 e na primeira safra 2023/2024 na área experimental da Universidade Federal de Mato Grosso do Sul, situada na cidade de Chapadão do Sul-MS (18°41'33" S, 52°40'45" W, com altitude de 810 m). O delineamento adotado foi o de blocos aumentados, com 100 linhagens endogâmicas de milho disponibilizadas pelo programa de melhoramento genético da ESALQ e 10 variedades de polinização aberta como testemunhas (BRS 106, BRS 4103, BRS 4104, CATI VERDE, SCCS 154, SCS 156, SCS 155, GOROTUBA, AL. VARE, AL. PIRA). As parcelas foram constituídas por 3 linhas com 3 metros de comprimento, espaçadas a 0,45 m entre si, e com uma densidade de 3 plantas por metro.

O tratamento das sementes foi feito com fungicida (Piraclostrobina + Metil Tiofanato) e inseticida (Fipronil) na dosagem de 200 mL para cada 100g visando a proteção das sementes contra os fungos e pragas do solo. As práticas de manejo foram realizadas conforme a necessidade da cultura.

Aquisição e processamento das imagens multiespectrais

Após 60 dias da emergência (DAE), foram capturadas as imagens espectrais com o auxílio de uma aeronave remotamente pilotada (RPA) de asa fixa Sensefly eBee RTK equipado de um sensor multiespectral Parrot Sequoia. A calibração radiométrica foi efetuada para toda a cena, utilizando como base a superfície refletiva calibrada fornecida pelo fabricante e com o sensor de luminosidade embutido no equipamento.

O eBee realiza decolagem, plano de voo e aterrissagem de forma autônoma. As imagens foram capturadas às 09:00 da manhã (horário de mato do grosso do Sul), em um dia claro e sem nuvens, a uma altitude de 100 metros (altitude local) e com uma resolução espacial de 0,10 metros. Foram obtidos valores de refletância nas seguintes

bandas espectrais: azul (475 nm), vermelho (660 nm), verde (550 nm), Rededge (735 nm) e NIR (790 nm).

Essas informações espectrais permitiram o cálculo de índices de vegetação usando o software ArcGIS (Tabela S1). A tecnologia RTK (Real Time Kinematics) proporcionou o levantamento aéreo com acurácia de 2,5 no momento da coleta. Utilizando o software Pix4Dmapper, as imagens foram processadas em mosaico e ortorretificadas. A precisão geométrica das ortomagens resultantes foi validada por meio de pontos de controle em campo (GCP – *Ground Control Points*), coletados com tecnologia RTK (BAIO et al.,2023).



Figura 1: Aeronave remotamente pilotada (RPA) de asa fixa Sensefly eBee RTK.
Fonte: acervo pessoal.



Figura 2: Sensor multiespectral Parrot Sequoia. Fonte: acervo pessoal.

Processamento dos dados

Os dados processados a partir das informações espectrais, juntamente com a produtividade do milho nas duas safras avaliadas, foram submetidos a análises de ML, utilizando três configurações de entrada (inputs): usando apenas IVs, usando apenas SBs e usando IVs+SBs. Esses dados foram inicialmente tabulados e submetidos a análises estatísticas. Os algoritmos de ML testados na predição dos dados de produtividade (output) foram: Redes Neurais Artificiais (ANN), árvores de decisão REPTree (DT) e (M5P), Floresta Aleatória (RF), Máquina de Vetor de Suporte (SVM), e ZeroR, que foi utilizado como modelo controle. O zero é o algoritmo mais simples que não leva em consideração nenhuma informação sobre os dados de entrada, apenas fazendo previsões com base na classe mais frequente no conjunto de dados. Depois foi utilizada a configuração padrão (*default*) do software Weka 3.8.5 para estabelecer os parâmetros dos algoritmos. A predição foi efetuada por meio de validação cruzada estratificada com $k\text{-fold} = 10$ e dez repetições, totalizando 100 execuções para cada modelo.

Para avaliar o desempenho dos modelos de predição, foram utilizadas métricas como coeficiente de correlação de Pearson (r), erro absoluto médio (MAE) e raiz quadrada do erro médio (RMSE). A significância dos diferentes conjuntos de entrada e algoritmos foi verificada por meio de análise de variância. Quando significância foi detectada, foram gerados boxplots das médias de r , MAE e RMSE, agrupados pelo teste de Scott-Knott (Scott & Knott, 1974) com um nível de significância de 5%. O

agrupamento das médias e os boxplots foram criados usando os pacotes ggplot2 e ExpDes.pt do software R (R CORE TEAM., 2024).

Resultados

A Figura 3 apresenta o desempenho de todos os algoritmos usados (RNA, DT, M5P, RF, SVM, ZeroR) para as métricas de coeficiente de correlação de Pearson (r). Essa métrica avalia a correlação entre os dados de produtividade observados (reais) e avaliados nas duas safras e aqueles preditos pelos algoritmos de ML. Para o algoritmo RNA, o input SB destacou-se com a melhor acurácia em relação aos demais inputs. Enquanto para o algoritmo DT, os melhores resultados foram obtidos com os inputs IV e SB+IV. No caso do algoritmo M5P, todos os inputs (IV, SB e SB+IV) mostraram um bom desempenho. Para o algoritmo RF, os inputs IV e SB+IV foram mais acurados em relação ao SB. Por fim, para o algoritmo SVM, todos os inputs (IV, SB e SB+IV) foram estatisticamente iguais.

O input IV demonstrou um desempenho superior nos algoritmos DT, M5P, RF e SVM. Por outro lado, o input SB destacou-se nos algoritmos RNA, M5P e SVM. Por último, o input SB+IV apresentou os melhores resultados nos algoritmos DT, M5P, RF e SVM. Tais resultados indicam que utilizar somente SB como variável de entrada nos modelos é tão acurado quanto utilizar IVs ou ambas as informações na predição de milho, especialmente quando utilizando os algoritmos RNAs, M5P e SVM.

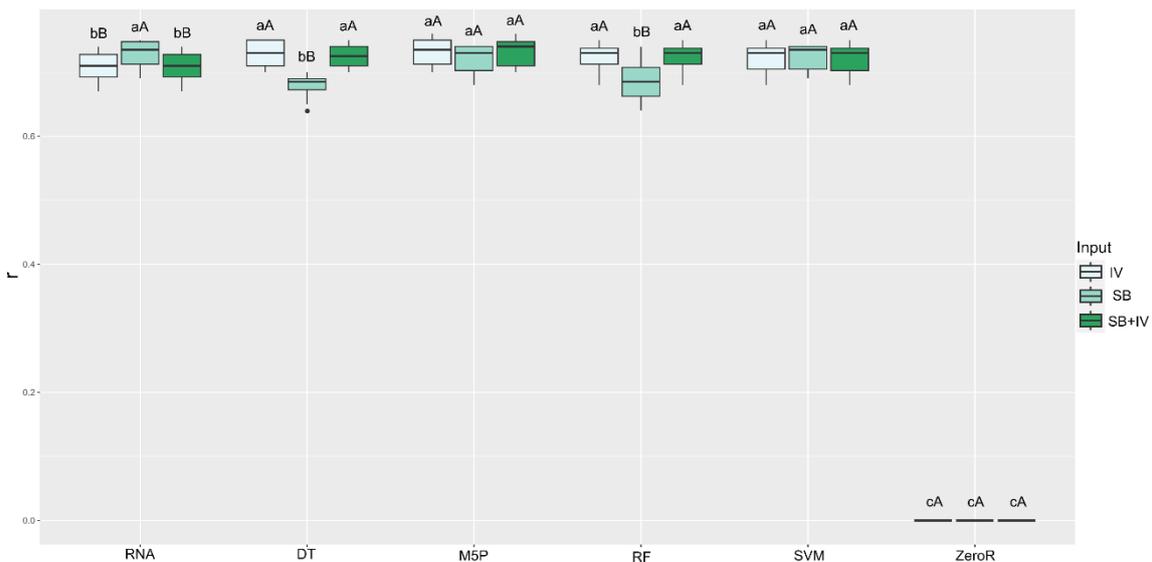


Figura 3. Gráfico de boxplot para as médias de correlação de Pearson (r) entre os inputs IV, SB, SB+IV e os algoritmos RNA, DT, M5P, RF, SVM, ZeroR na predição de

produtividade de milho. Letras maiúsculas comparam diferentes inputs, enquanto letras minúsculas comparam os modelos de aprendizagem de máquina.

As Figuras 4 e 5 apresentaram as médias de erro médio absoluto (MAE) e raiz quadrada do erro-médio (RMSE), respectivamente. O algoritmo ZeroR, nas duas métricas, teve o pior desempenho, apresentando as maiores taxas de erro para todos os inputs testados. De acordo com MAE e RMSE, os algoritmos DT, M5P, RF, SVM apresentaram os menores valores de erro. De um modo geral, os inputs IV, e SB+ IV proporcionaram menor erro para os algoritmos supracitados.

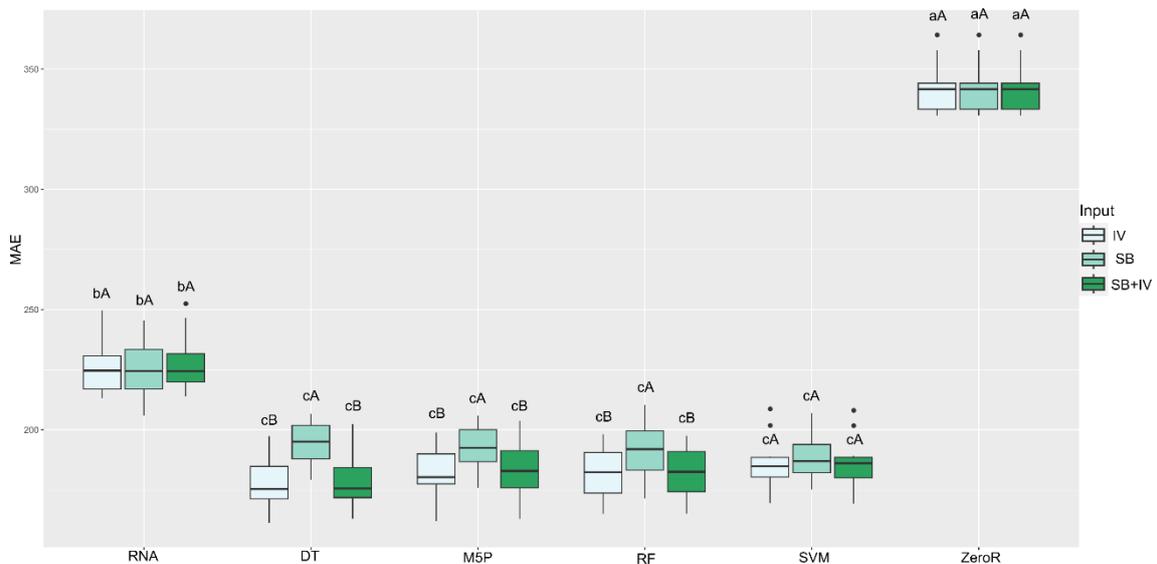


Figura 4. Gráfico de boxplot para as médias de erro médio absoluto (MAE) na predição de produtividade de milho. Letras maiúsculas comparam diferentes inputs, enquanto letras minúsculas comparam os modelos de aprendizagem de máquina.

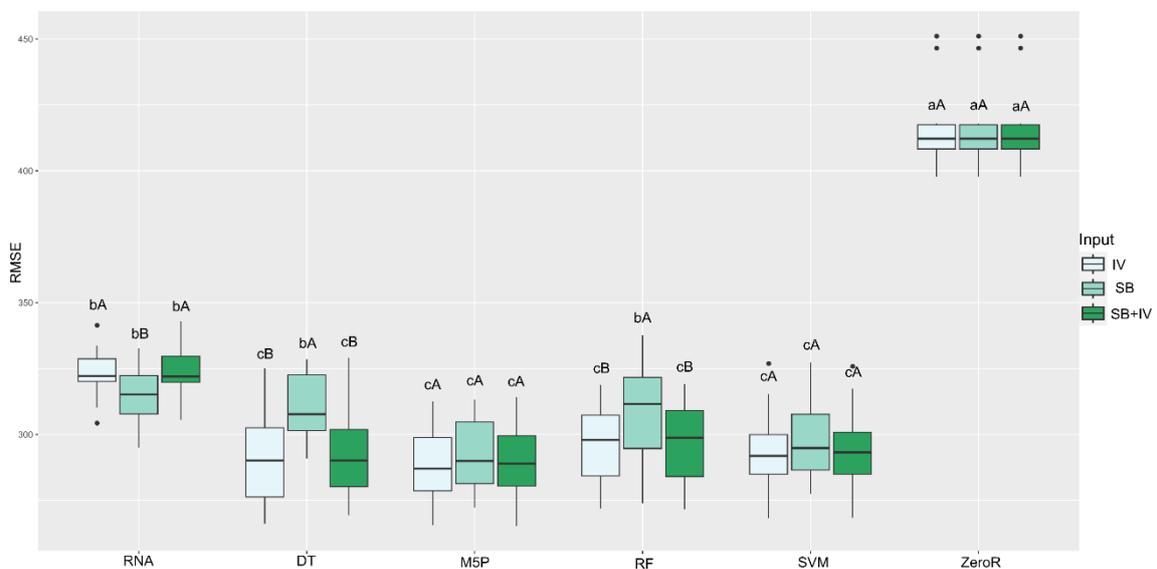


Figura 5. Gráfico de boxplot para médias de raiz quadrada do erro-médio (RMSE) na

predição de produtividade de milho. Letras maiúsculas comparam diferentes inputs, enquanto letras minúsculas comparam os modelos de aprendizagem de máquina.

De modo geral, todos os algoritmos testados, com exceção do ZeroR, tiveram uma boa acurácia tendo alta correlação (r) mas para o modelo DT e RF foi necessário o uso de apenas IV ou a combinação da mesma com SB para obter o melhor desempenho na previsão de produtividade do milho. Nesse sentido, os algoritmos que tiveram os melhores desempenhos foram M5P e SVM, sem diferença significativa de acurácia e com as menores médias de erro para todos os inputs testados. Portanto, utilizar apenas de bandas espectrais (SBs) é uma estratégia eficiente, pois proporciona acurácia de predição similar ao demais inputs testados e não requer o cálculo de índices de vegetação, tornando o processo de obtenção de informações espectrais mais prático.

Discussão

A predição de produtividade de linhagem endogâmica de milho é uma abordagem relevante na agricultura por produzirem sementes de alta qualidade mas com baixa produtividade de sementes o que faz com que prever a produtividade com antecedência seja importante para auxiliar nas tomadas de decisões das empresas de melhoramento genético, dar suporte a gestão de culturas durante as pesquisas, proporcionar um monitoramento mais ágil das parcelas de ensaios, apresentar sementes de qualidade aos produtores, assim como agregar valor adequado ao produto colhido. Prever acuradamente o rendimento das culturas usando técnicas de ML ainda é uma tarefa desafiadora. Levando em conta a relevância do milho no agronegócio brasileiro, monitorar o crescimento e a produtividade dessa cultura ajuda os participantes da cadeia produtiva a melhorar a produção sem precisar expandir a área plantada já que a partir das linhagens endogâmicas são produzidos híbridos comerciais de qualidade (SISHODIA et al.,2020; KAMATH et al.,2021; SURYA et al.,2018; BALA et al.,2020).

Nesse sentido, pesquisadores têm se dedicado a adotar tecnologias que os ajudem nessa missão, considerando que as áreas cultivadas são amplas demais para serem monitoradas apenas presencialmente. Imagens de satélite têm se tornado essenciais para acompanhar as culturas, desempenhando um papel crucial nas tomadas de decisões no campo e na avaliação dos retornos econômicos (VENANCIO et al.,2019; BARZIN et al., 2020; ZHOU et al.,2021). Entretanto, os dados de rendimento envolvem diversas variáveis relacionadas às condições da cultura, à gestão e ao clima. A aplicação

de tecnologias, como técnicas de aprendizado de máquina combinadas com dados espectrais, desempenha um papel fundamental na promoção da melhoria da produtividade nos sistemas agrícolas (RAMOS et al.,2020).

Na agricultura, os modelos de aprendizado de máquina estão sendo empregados em vários estudos de estimativa de produtividade, como o de Folberth et al., (2019) e Shahhosseini et al., (2020), que projetaram a produtividade do milho utilizando dados de solo e clima. Além disso, Kamir et al., (2020) conseguiram prever a produtividade do trigo com base em dados climáticos e séries temporais de imagens de satélite. Kumar et al., (2023) foram capazes de estimar o rendimento de milho em vários estágios usando dados multiespectrais de UAV de alta resolução e modelos de aprendizado de máquina.

Nesse estudo, foram aplicados seis algoritmos conforme mostrado na seção de resultados, todas as métricas avaliadas tiveram acurácia superior a 0,6, mas SVM e M5P se destacaram independentemente da configuração de entrada. O estudo de BAIO et al., (2023) ao predizer de produtividade do milho usando algoritmos similares como RNA, M5P, REPT, (RF) e (SVM), junto com configurações de entrada no conjunto de dados (considerando manejo da irrigação, temperatura foliar e variáveis espectrais) verificou uma acurácia de 0,5 menor ao alcançado nesse trabalho exceto o RF que obteve resultados similar. Isso porque quanto maior a acurácia mais preciso será a previsão.

DT e RF tiveram menor acurácia quando utilizando somente SB como entrada, mas apresentaram acurácia similar a M5P e SVM quando utilizado somente IVs. O bom desempenho de RF utilizando IVs como variáveis de entrada em modelos de predição de produtividade de milho já foi reportado na literatura por Marques Ramos et al., (2020) que observaram bons resultados para o algoritmo RF na previsão da produtividade do milho utilizando IVs como variáveis de entrada dos modelos.

Avaliando os inputs usando esse mesmo algoritmo, o SB e SB+IV obtiveram os melhores desempenhos sem diferença significativa de precisão. Como ambas as entradas apresentaram resultados semelhantes, de ponto de vista prática, de otimização do processo e econômico, usar apenas SB é mais vantajoso. Isso porque o uso de IV requer um processamento mais intenso de dados, recursos, além de maior tempo e da necessidade de cálculos para obter cada índice de vegetação. A utilização de bandas espectrais como entrada em algoritmos de aprendizado de máquina também produziu resultados precisos em diversos estudos como o do Gava et al., (2022) na identificação de variedades de soja utilizando por sua vez imagens de satélite e Landsat-8 com o sensor OLI (USGS Landsat 8 Collection 1 Tier 1 e dados em tempo real (TOA

Reflectance). Isso se comprova com esse estudo, mostrando que apenas SB pode ser aplicado em quatro dos seis algoritmos.

O algoritmo Máquina de Vetores de Suporte (SVM) por exemplo que foi um dos destaques desse estudo, é um dos modelos de aprendizado de máquina (ML) que tem ganhado destaque entre os pesquisadores da área. Estudos como o de Mountrakis et al., (2010) e Khatami et al., (2016) examinaram seu desempenho na classificação de dados de sensoriamento e obtiveram resultados positivos. Esse algoritmo permite alcançar precisão e capacidade de generalização, mesmo com amostras pequenas ou quando a dimensionalidade das características é maior do que o número de amostras (SHAO et al., 2012; ABDEL-RAHMAN et al., 2013). O mesmo atingiu bons resultados na classificação de genótipos de soja em termos de macronutrientes primários (SANTANA et al., 2023a, SANTANA et al., 2023b). Guo et al., (2021) comprovaram que o algoritmo SVM apresenta boas precisões na previsão do rendimento do arroz, com base em variáveis fenológicas que contribuíram no desempenho do algoritmo. Entretanto, o presente estudo não utilizou variáveis fenológicas. Da silva et al., (2024) aplicaram os algoritmos SVM, RNA, RF, ZeroR e PSVM para prever nitrogênio e pigmentos em milho e obtiveram resultados promissores com RF e SVM.

O algoritmo M5P tem grande eficácia no processamento de grandes volumes de dados em alta dimensão e é reconhecido por sua resistência ao trabalhar com dados faltantes (BEHNOOD et al., 2017). Ele foi aplicado em estudo de análise como de Kok, et al., (2021) que afirmaram que a máquina de vetor de suporte (SVM) mostra um desempenho satisfatório na previsão do rendimento de grãos, mas há alguns desafios na sua aplicação pois conforme o tamanho dos dados aplicados vai aumentando, o tempo necessário para fazer os cálculos fica maior e a interpretação se torna mais difícil. Sendo assim, mesmo com capacidade de lidar com grandes volumes de dados o SVM apresenta o desafio por exemplo de mais tempo para processar.

Dessa maneira, sabendo a importância econômica do milho, vários países poderiam se beneficiar desse tipo de abordagem que inclusive está demonstrando resultados promissores. Junto com a capacidade vasta das tecnologias de ML essa estimativa tem um real potencial de melhorar os resultados nas empresas de melhoramento genético, ajudar na seleção de linhagens endogâmicas com maior produtividade, servir de apoio nas pesquisas de aumento de produtividades das linhagens do milho e ainda proporciona um bom custo-benefício das variedades comerciais para todos os níveis de produtores e consumidores a longo prazo. Ao que

tudo indica, tecnologias inovadoras têm o potencial de impulsionar a exploração dos índices de produtividade, e a integração de aprendizado de máquina com dados de sensoriamento remoto, que têm um papel crucial nesse cenário.

Nesse sentido, futuras pesquisas abordando a predição de produtividade de linhagem endogâmica de milho devem ser realizadas em outros locais, avaliando outras variáveis e/ou utilizando diferentes abordagens de sensoriamento remoto, como sensores hiperespectrais acoplados em RPA visando alcançar maior acurácia de predição da produtividade.

Conclusão

Todos os algoritmos testados, com exceção do modelo ZeroR, tiveram acurácias de predição similares. Contudo, os algoritmos M5P e SVM proporcionaram maior acurácia de predição independente dos inputs testados. Portanto, estes algoritmos se mostram promissores para uma abordagem mais prática da predição de produtividade em milho por meio de sensoriamento multiespectral, uma vez que utilizar apenas SBs como variáveis de entrada é mais vantajoso já que utilizar apenas IVs requer maior processamento de dados, mais tempo e recursos humanos e computacionais.

Referências

ABDEL-RAHMAN, EM.; AHMED, FB.; ISMAIL, R. Random Forest regression and spectral band selection for estimating sugarcane leaf nitrogen concentration using EO-1 Hyperion hyperspectral data. *International Journal of Remote Sensing*, v. 34(2), 712-728, **2013**. Disponível em: <https://doi.org/10.1080/01431161.2012.713142>

ASHAPURE, A.; JUNG, J.; CHANG, A.; OH, S.; YEOM, J.; MAEDA, M.; SMITH, W. Developing a machine learning based cotton yield estimation framework using multi-temporal UAS data. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 169, 180-194, **2020**. Disponível em: <https://doi.org/10.3390/agronomy13051277>

BALA, A. Machine Learning Approaches for Crop Yield Prediction-Review. *International Journal of Computer Engineering and Technology*, v.11(1), 23-27, **2020**. Disponível em: <https://ssrn.com/abstract=3638847>

BASCON, MV.; NAKATA, T.; SHIBATA, S.; TAKATA, I.; KOBAYASHI, N.; KATO, Y.; NISHIUCHI, S. Estimating yield-related traits using UAV-derived multispectral images to improve rice grain yield prediction. *Agriculture*, v.12(8), 1141, **2022**. Disponível em: <https://doi.org/10.3390/agriculture12081141>

BARZIN, R., LOTFI, H., VARCO, JJ.; BORA, GC. Aprendizado de máquina na avaliação do sensor de dossel ativo multiespectral para predição da concentração de nitrogênio e rendimento da folha de milho. *Sensoriamento remoto*, 14 (1), 120, **2022**. <https://doi.org/10.3390/rs14010120>

BARZIN, R.; PATHAK, R.; LOTFI, H.; VARCO, J.; BORA, GC. Use of UAS multispectral imagery at different physiological stages for yield prediction and input resource optimization in corn. *Remote Sensing*, v. 12(15), 2392, **2020**. Disponível em: <https://doi.org/10.3390/rs12152392>

BEHNOOD, A.; BEHNOOD, V.; GHAREHVERAN, MM.; ALYAMAC, KE. Prediction of the compressive strength of normal and high-performance concretes using

M5P model tree algorithm. *Construction and Building Materials*, v. 142, 199-207, **2017**. Disponível em: <https://doi.org/10.1016/j.conbuildmat.2017.03.061>

BIAN, C.; SHI, H.; WU, S.; ZHANG, K.; WEI, M., ZHAO; Y.; CHEN, S. Prediction of field-scale wheat yield using machine learning method and multi-spectral UAV data. *Remote Sensing*, v. 14(6), 1474, **2022**. Disponível em: <https://doi.org/10.3390/rs14061474>

CONAB, CN de A. Acompanhamento da safra brasileira, Grãos; Brasília, DF, 2024; ISBN 2318-6852. Disponível em <https://www.conab.gov.br/info-agro/safra/gaos/boletim-da-safra-de-graos>

CONTINI, E.; MOTA, MM.; MARRA. R.; BORGHI, E.; DE MIRANDA, RA.; DA SILVA, AF.; DA SILVA, DD.; MACHADO, JR.A.; COTA, LV.; DA COSTA, RV.; MENDES, SM. Caracterização e desafios tecnológicos do milho. *Brasília: Embrapa. (Desafios do Agronegócio Brasileiro, 2)*, 2019.

DA SILVA, EE.; BAIO, FHR.; TEODORO, LPR.; DA SILVA JUNIOR, CA.; BORGES, RS.; TEODORO, PE. UAV-multispectral and vegetation indices in soybean grain yield prediction based on in situ observation, *Remote Sensing Applications: Society and Environment*, v. 18, 100318, **2020**. Disponível em: <https://doi.org/10.1016/j.rsase.2020.100318>

DA SILVA, BC.; DE MELLO PRADO, R.; BAIO, FHR.; CAMPOS, CNS.; TEODORO, LPR.; TEODORO, PE.; SANTANA, DC.; FERNANDES, TFS.; DA SILVA JUNIOR, CA.; DE SOUZA LOUREIRO, E. New approach for predicting nitrogen and pigments in maize from hyperspectral data and machine learning models. *Remote Sensing Applications: Society and Environment*, v. 33, 101110, **2024**. Disponível em: <https://doi.org/10.1016/j.rsase.2023.101110>

DHAKA, VS.; VIKAS, L. Wheat yield prediction using artificial neural network and crop prediction techniques (a survey). *IJRASET*, v. 2, 330-341, 2014.

EUGENIO, FC.; GROHS, M.; VENANCIO, LP.; SCHUH, M.; BOTTEGA, EL.; RUOSO, R.; SCHONS, C.; MALLMANN, CL.; BADIN, TL.; FERNANDES, P. Estimation of soybean yield from machine learning techniques and multispectral RPAS imagery. *Remote Sensing Applications: Society and Environment*, v. 20, 100397, **2020**. Disponível em: <https://doi.org/10.1016/j.rsase.2020.100397>

FOLBERTH, C.; BAKLANOV, A.; BALKOVIČ, J.; SKALSKÝ, R.; KHABAROV, N.; OBERSTEINER, M. Spatio-temporal downscaling of gridded crop model yield estimates based on machine learning. *Agricultural and forest meteorology*, v. 264, 1-15, **2019**. Disponível em: <https://doi.org/10.1016/j.agrformet.2018.09.021>

GAVA, R.; SANTANA, DC.; COTRIM, MF.; ROSSI, FS.; TEODORO, LPR.; DA SILVA JUNIOR, CA.; TEODORO, PE. Soybean cultivars identification using remotely sensed image and machine learning models. *Sustainability*, v. 14(12), 7125, **2022**. Disponível em: <https://doi.org/10.3390/su14127125>

GUO, Y.; FU, Y.; HAO, F.; ZHANG, X.; WU, W.; JIN, X.; BRYANT, CR.; SENTHILNATH, J. Integrated phenology and climate in rice yields prediction using machine learning methods. *Ecological Indicators*, v. 120, 106935, **2021**. Disponível em: <https://doi.org/10.1016/j.ecolind.2020.106935>

HAN, J.; ZHANG, Z.; CAO, J.; LUO, Y.; ZHANG, L.; LI, Z.; ZHANG, J. Prediction of winter wheat yield based on multi-source data and machine learning in China. *Remote Sensing*, v. 12(2), 236, **2020**. Disponível em: <https://doi.org/10.3390/rs12020236>

HATFIELD, JL.; PRUEGER, JH. Value of Using Different Vegetative Indices to Quantify Agricultural Crop Characteristics at Different Growth Stages under Varying Management Practices. *Remote Sensing*. 2010; 2(2):562-578. <https://doi.org/10.3390/rs2020562>

JEONG, JH.; RESOP, JP.; MUELLER, ND.; FLEISHER, D. H.; YUN, K.; BUTLER, EE.; TIMLIN, DJ.; SHIM, KM.; GERBER, JS.; REDDY, VR.; KIM, SH. Random forests for global and regional crop yield predictions. *PLoS one*, v. 11(6), e0156571, **2016**. Disponível em: <https://doi.org/10.1371/journal.pone.0156571>

KAMATH, P.; PATIL, P.; SHRILATHA, S.; SOWMYA, S. Crop yield forecasting using data mining. *Global Transitions Proceedings*, v. 2, 402-407, **2021**. Disponível em: <https://doi.org/10.1016/j.gltip.2021.08.008>

KAMIR, E.; WALDNER, F.; HOCHMAN, Z. Estimating wheat yields in Australia using climate records, satellite image time series and machine learning methods. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 160, 124-135, **2020**. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2019.11.008>

KHATAMI, R.; MOUNTRAKIS, G.; STEHMAN, SV. A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote sensing of environment*, 177, 89-100, **2016**. Disponível em: <https://doi.org/10.1016/j.rse.2016.02.028>

KOK, ZH.; SHARIFF, ARM.; ALFATNI, MSM.; KHAIRUNNIZA-BEJO, S. Support vector machine in precision agriculture: a review. *Computers and Electronics in Agriculture*, v. 191, 106546, **2021**. Disponível em: <https://doi.org/10.1016/j.compag.2021.106546>

KUMAR, C.; WALTON, G.; SANTI, P.; LUZA, C. An ensemble approach of feature selection and machine learning models for regional landslide susceptibility mapping in the arid mountainous terrain of Southern Peru. *Remote Sensing*, v. 15(5), 1376, **2023**. Disponível em: <https://doi.org/10.3390/rs15051376>

MEDINA, H.; TIAN, D.; ABEBE, A. On optimizing a MODIS-based framework for in-season corn yield forecast. *International journal of applied earth observation and geoinformation*, v. 95, 102258, **2021**. Disponível em: <https://doi.org/10.1016/j.jag.2020.102258>

MENDES, UC.; SOUSA, SB.; SCHINDLER, RF.; PINTO, JFN.; DOS REIS, EF. Depressão por endogamia em uma população de milho denominada mpa. *XII seminário nacional milho safrinha, EMBRAPA*, **2013**.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. *ISPRS journal of photogrammetry and remote sensing*, v. 66(3), 247-259, **2011**. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2010.11.001>

RAMOS, APM.; OSCO, LP.; FURUYA, DEG.; GONÇALVES, WN.; SANTANA, DC.; TEODORO, LPR.; DA SILVA JUNIOR, CA.; CAPRISTO-SILVA GF.; LI, J.; BAIIO FHR.; JUNIOR JM.; TEODORO, PE.; PISTORI, H. A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices. *Computers and Electronics in Agriculture*, 178, 105791, **2020**. Disponível em: <https://doi.org/10.1016/j.compag.2020.105791>

R CORE TEAM. R: A Language and Environment for Statistical Computing. *R foundation for Statistical Computing*, Vienna, Austria, **2024**. Disponível em: <https://www.R-project.org/>.

SANTANA, DC.; THEODORO, GDF.; GAVA, R.; DE OLIVEIRA, JLG.; TEODORO, LPR.; DE OLIVEIRA, I.C.; BAIIO, FHR.; DA SILVA JUNIOR, CA.; DE OLIVEIRA, JT.; TEODORO, PE. A New Approach to Identifying Sorghum Hybrids Using UAV Imagery Using Multispectral Signature and Machine Learning. *Algorithms*, v. 17, 23, **2024**. Disponível em: <https://doi.org/10.3390/a17010023>

SANTANA, DC.; TEIXEIRA FILHO, MCM.; DA SILVA, MR.; CHAGAS, PHMD.; DE OLIVEIRA, JLG.; BAIIO, FHR.; CAMPOS, CNS.; TEODORO, LPR.; DA SILVA JUNIOR, CA.; TEODORO, PE.; SHIRATSUCHI, LS. Machine Learning in the Classification of Soybean Genotypes for Primary Macronutrients' Content Using UAV–Multispectral Sensor. *Remote Sensing*, v. 15(5), 1457, **2023a**. Disponível em: <https://doi.org/10.3390/rs15051457>

SANTANA, DC.; TEODORO, LPR.; BAIIO, FHR.; DOS SANTOS, RG.; CORADI, PC.; BIDUSKI, B.; DA SILVA JUNIOR, CA.; TEODORO PE.; SHIRATSUCHI, LS. Classification of soybean genotypes for industrial traits using UAV multispectral imagery and machine learning. *Remote Sensing Applications: Society and*

Environment, v. 29, 100919, **2023b**. Disponível em: <https://doi.org/10.1016/j.rsase.2023.100919>

SCOTT, A.J.; KNOTT, M. A cluster analysis method for grouping means in the analysis of variance. *Biometrics*, v. 30, 507-512, **1974**. Disponível em: <https://doi.org/10.2307/2529204>

SENTHILNATH, J.; DOKANIA, A.; KANDUKURI, M.; RAMESH K.N.; ANAND, G.; OMKAR, SN. Detection of tomatoes using spectral-spatial methods in remotely sensed RGB images captured by UAV. *Biosystems Engineering*, v.146, 16-32, **2016**. Disponível em: <https://doi.org/10.1016/j.biosystemseng.2015.12.003>

SHAHHOSSEINI, M.; HU, G.; ARCHONTOULIS, S. V. Forecasting corn yield with machine learning ensembles. *Frontiers in Plant Science*, v. 11, 1120, **2020**. Disponível em: <https://doi.org/10.3389/fpls.2020.01120>

SHAO, Y.; ZHAO, C.; BAO, Y.; HE, Y. Quantification of nitrogen status in rice by least squares support vector machines and reflectance spectroscopy. *Food and Bioprocess Technology*, v. 5, 100-107, **2012**. Disponível em: <https://doi.org/10.1007/s11947-009-0267-y>

SHAFIEE, S.; LIED, LM.; BURUD, I.; DIESETH, JA.; ALSHEIKH, M.; LILLEMO, M. Sequential forward selection and support vector regression in comparison to LASSO regression for spring wheat yield prediction based on UAV imagery. *Computers and Electronics in Agriculture*, v. 183, 106036, **2021**. <https://doi.org/10.1016/j.compag.2021.106036>

SUN, J.; LAI, Z.; DI, L.; SUN, Z.; TAO, J.; SHEN, Y. Multilevel deep learning network for county-level corn yield estimation in the us corn belt. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 13, 5048-5060, **2020**. Disponível em: [10.1109/JSTARS.2020.3019046](https://doi.org/10.1109/JSTARS.2020.3019046)

SIEGFRIED, J.; ADAMS, CB.; RAJAN, N.; HAGUE, S.; SCHNELL, R.; HARDIN, R. Combining a cotton ‘Boll Area Index’ with in-season unmanned aerial multispectral and

thermal imagery for yield estimation. *Field Crops Research*, v. 291, 108765, **2023**. Disponível em: <https://doi.org/10.1016/j.fcr.2022.108765>

SISHODIA, RP.; RAY, RL.; SINGH, SK. Applications of remote sensing in precision agriculture: A review. *Remote sensing*, v. 12(19), 3136, **2020**. Disponível em: <https://doi.org/10.3390/rs12193136>

SURYA, P.; AROQUIARAJ, IL. Crop yield prediction in agriculture using data mining predictive analytic techniques. *International Journal of Research and Analytical Reviews*, v. 5(4), 783-787, **2018**.

TANABE, R.; MATSUI, T.; TANAKA, TS. Winter wheat yield prediction using convolutional neural networks and UAV-based multispectral imagery. *Field Crops Research*, 291, 108786, **2023**. Disponível em: <https://doi.org/10.1016/j.fcr.2022.108786>

TEAM, RC. R: A language and environment for statistical computing. *R Foundation for Statistical Computing, Vienna, Austria*, **2017**. Disponível em: <https://www.R-project.org>.

TIAN, L.; WANG, C.; LI, H.; SUN, H. Yield prediction model of rice and wheat crops based on ecological distance algorithm. *Environmental Technology & Innovation*, v. 20, 101132, **2020**. Disponível em : <https://doi.org/10.1016/j.eti.2020.101132>

VANI, S.; SUKUMARAN, RK.; SAVITHRI, S. Prediction of sugar yields during hydrolysis of lignocellulosic biomass using artificial neural network modeling. *Bioresource Technology*, v. 188, 128-135, **2015**. Disponível em: <https://doi.org/10.1016/j.biortech.2015.01.083>

VENANCIO, LP.; MANTOVANI, EC.; DO AMARAL, CH.; NEALE, CMU.; GONÇALVES, IZ.; FILGUEIRAS, R.; CAMPOS, I. Forecasting corn yield at the farm level in Brazil based on the FAO-66 approach and soil-adjusted vegetation index (SAVI). *Agricultural Water Management*, v. 225, 105779, **2019**. Disponível em: <https://doi.org/10.1016/j.agwat.2019.105779>

WAN, L.; CEN, H.; ZHU, J.; ZHANG, J.; ZHU, Y.; SUN, D.; DU, X.; ZHAI, L.; WENG, H.; LI, Y.; LI, X.; BAO, Y.; SHOU, J.; HE, Y. Grain yield prediction of rice using multi-temporal UAV-based RGB and multispectral images and model transfer—a case study of small farmlands in the South of China. *Agricultural and Forest Meteorology*, v.291, 108096, 2020. Disponível em: <https://doi.org/10.1016/j.agrformet.2020.108096>

ZHOU, X.; KONO, Y.; WIN, A., MATSUI, T.; TANAKA, TST. Predicting within-field variability in grain yield and protein content of winter wheat using UAV-based multispectral imagery and machine learning approaches. *Plant Production Science*, v. 24(2), 137-151, 2021. Disponível em: <https://doi.org/10.1080/1343943X.2020.1819165>

ZHOU, X.; ZHENG, H. B.; XU, X. Q.; HE, J. Y.; GE, X. K.; YAO, X.; CHENG, T.; ZHU, Y.; CAO, W.; TIAN, Y. C. Predicting grain yield in rice using multi-temporal vegetation indices from UAV-based multispectral and digital imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 246-255, 2017. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2017.05.003>

Material suplementar

Tabela S1. Relação dos índices de vegetação

Sigla	Índice de Vegetação
NDVI	Índice de vegetação pela diferença normalizada

InRE	Logaritmo neperiano do Red-edge
NDRE	Índice de vegetação da diferença normalizada pelo Red-Edge
SAVI	Índice de vegetação ajustado pela presença de solo
EVI	Índice de vegetação aumentada
PNDVI	Índice de vegetação por diferença normalizada pan
CCCI	Índice de conteúdo de clorofila da copa (Canopy Chlorophyll Content Index)
GNDVI	Índice de vegetação pela diferença normalizada ao verde
IAF	Índice de Área Foliar
NIR/G	Refletância vermelho e infravermelho próximo
NIR/R	Refletância no infravermelho próximo e vermelho
RE/NIR	Bandas espectrais do infravermelho próximo (NIR) e a banda de borda vermelha

MSAVI	Índice de vegetação modificado ajustado pela presença de solo
MTVI	Modified Triangular Vegetation Index
CIgreen	Índice De Clorofila Verde
CVI	Índice de vegetação global
MCARI	Índice de refletância de absorção de clorofila modificado
CTVI	Capsid-targeted viral inactivation
MSR	Índice de vegetação de dados raster
OSAVI	Índice de Vegetação Ajustado ao Solo Otimizado
RDVI	Retrieval–Detection method for Verbal Irony
WDRVI	Wide Dynamic Range Vegetation Index
VARI	Índice Resistente à Atmosfera na Região Visível
GLI	Índice foliar verde

ATSAVI	Ajusted Transformed soil-adjusted VI
ARVI2	Atmospherically Resistant Vegetation Index 2
GTVI	Green Triangle Vegetation Index
GDVI	Difference NIR/Green Difference Vegetation Index
EVEI2	Enhanced Vegetation Index 2
GEMI	Global Environment Monitoring Index
GSAVI	Índice de Vegetação Ajustado pelo Solo Verde
IPVI	Infrared Percentage Vegetation Index
LogR	Log Ratio
MSTNir Red	Modified Simple Ratio NIR/RED
Norm_R_1	Normalized G
NGRDI	Índice de vegetação da diferença normalizada do verde e do vermelho

DVI	Difference Vegetation Index
SQRT_IR_R	Raiz quadrada do vermelho e infravermelho próximo
TNDVI	NDVI transformado
TVI	Transformed Vegetation Index
WDRVI	Índice de Vegetação de Larga Escala Dinâmica
SCCCI	Índice simplificado de conteúdo de clorofila do dossel

R_{NIR} : reflectância na faixa do infravermelho próximo; R_{GREEN} : reflectância na faixa do verde; R_{RED} : reflectância na faixa do vermelho; R_{EDGE} : reflectância na faixa de transição do vermelho (Red-edge); L: fator de correção do efeito do solo.