

RESSALVA

Atendendo solicitação do(a) autor(a), o texto completo desta dissertação será disponibilizado somente a partir de 02/12/2026.



**UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"**

Faculdade de Ciências e Tecnologia – Campus de Presidente Prudente

GABRIELA ZANCHETTA

**PREDIÇÃO DE RENDIMENTO DA CULTURA DA BATATA-DOCE
A PARTIR DE IMAGENS DE ALTA RESOLUÇÃO ESPACIAL E
MODELAGEM POR APRENDIZADO DE MÁQUINA**

Presidente Prudente – SP

2024

GABRIELA ZANCHETTA

**PREDIÇÃO DE RENDIMENTO DA CULTURA DA BATATA-DOCE
A PARTIR DE IMAGENS DE ALTA RESOLUÇÃO ESPACIAL E
MODELAGEM POR APRENDIZADO DE MÁQUINA**

Dissertação de Mestrado apresentada à Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), Faculdade de Ciências e Tecnologia, campus de Presidente Prudente, para obtenção do título de Mestra em Ciências Cartográficas.

Área de Concentração: Aquisição, Análise e Representação de Informações Espaciais.

Linha de Pesquisa: Cartografia e Sensoriamento Remoto.

Prof^ª. Dr^ª. Fernanda Sayuri Yoshino Watanabe
Orientadora

Prof. Dr. Nilton Nobuhiro Imai
Coorientador

Presidente Prudente – SP

2024

Z27p

Zanchetta, Gabriela

Predição de rendimento da cultura da batata-doce a partir de imagens de alta resolução espacial e modelagem por aprendizado de máquina / Gabriela Zanchetta. -- Presidente Prudente, 2024

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

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Tecnologia, Presidente Prudente

Orientadora: Fernanda Sayuri Yoshino Watanabe

Coorientador: Nilton Nobuhiro Imai

1. Predição. 2. Sensoriamento remoto. 3. Sensor multiespectral. 4. Agricultura digital. 5. Colheita inteligente. I. Título.

Impacto potencial desta pesquisa

A pesquisa propõe um modelo de predição de rendimento da batata-doce, com uso de Aeronave Remotamente Pilotada (ARP), câmera de alta resolução e aprendizado de máquina. Esse avanço pode beneficiar pequenos produtores a aumentar a eficiência agrícola, contribuindo para um dos Objetivos de Desenvolvimento Sustentável (ODS): “fome zero e agricultura sustentável”.

Potencial impact of this research

The research proposes a prediction model for sweet potato yield, using a Remotely Piloted Aircraft (RPA), high-resolution camera and machine learning. This advance can benefit small producers by increasing agricultural efficiency, contributing to one of the Sustainable Development Goals (SDGs): “zero hunger and sustainable agriculture”.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Estimativa de rendimento da cultura da batata-doce a partir de imagens de alta resolução espacial e modelagem por aprendizado de máquina

AUTORA: GABRIELA ZANCHETTA

ORIENTADORA: FERNANDA SAYURI YOSHINO WATANABE

COORIENTADOR: NILTON NOBUHIRO IMAI

Aprovada como parte das exigências para obtenção do Título de Mestre em Ciências Cartográficas, área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:

Documento assinado digitalmente



FERNANDA SAYURI YOSHINO WATANABE
Data: 02/12/2024 20:15:32-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. FERNANDA SAYURI YOSHINO WATANABE (Participação Presencial)
Departamento de Cartografia / Universidade Estadual Paulista “Júlio de Mesquita Filho” - Faculdade de Ciências e Tecnologia

Documento assinado digitalmente



MARIA DE LOURDES BUENO TRINDADE GALO
Data: 02/12/2024 20:53:45-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. MARIA DE LOURDES BUENO TRINDADE GALO (Participação Presencial)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente - FCT/Unesp

Documento assinado digitalmente



SAMIRA LUNS HATUM DE ALMEIDA
Data: 05/12/2024 16:03:33-0300
Verifique em <https://validar.iti.gov.br>

Profª. Dra. SAMIRA LUNS HATUM DE ALMEIDA (Participação Virtual)
Departamento de Engenharia e Ciências Exatas / FCAV - UNESP Jaboticabal

Presidente Prudente, 02 de dezembro de 2024

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pelo apoio financeiro, concedido pelo Processo N. 2021/06029-7 - Projeto Temático da FAPESP “Sensoriamento remoto de alta resolução para agricultura digital”.

Agradecimentos à Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP), campus de Presidente Prudente e ao Programa de Pós-graduação em Ciências Cartográficas (PPGCC) por toda estrutura ao longo do desenvolvimento desta pesquisa.

Agradeço a Deus, por me conceder forças e sabedoria ao longo desta jornada.

A minha família, por todo o amor, suporte e incentivo incondicional que me deram durante os anos de estudo. Agradeço especialmente aos meus pais (Cionéa e Edivaldo) e irmãos (Fran e Vitinho), por serem meus pilares e me apoiarem em cada escolha que fiz. Sem vocês, nada disso seria possível.

Aos meus amigos, que estiveram presentes em cada etapa, compartilhando risos, momentos de descontração e palavras de encorajamento. Vocês tornaram essa caminhada mais leve e especial. Um reconhecimento singular à Juliane, que esteve presente em todo o processo me dando forças (presencialmente e à distância).

Ao meu namorado (Gabriel), por ser minha fonte de apoio constante, por acreditar em mim nos momentos em que duvidei e por estar ao meu lado em todos os desafios. Sua paciência e compreensão foram fundamentais para que eu chegasse até aqui. Também agradeço à sua família (C. Ligia, Maria Dolores, Rafaela, Alex e Heleninha), que me acolheu com tanto carinho e sempre me incentivou ao longo desse percurso.

Reconhecimentos ao Rafael C. F., por todo o suporte e colaboração ao longo do trabalho. Gratidão também à Luana e Mikaelly, pelo apoio nas campanhas de campo.

À minha orientadora, Dra. Fernanda, e ao meu coorientador, Dr. Nilton, pelas orientações, paciência e valiosas contribuições ao longo desta trajetória. A dedicação e o conhecimento de ambos foram essenciais para a conclusão deste trabalho. Sou grata pela oportunidade de aprender com vocês.

Ao Pedro L. M. N., por ceder gentilmente a área de estudo para o desenvolvimento deste trabalho. Obrigada pela oportunidade e confiança!

Por fim, agradeço a todos aqueles que, de alguma forma, contribuíram para a realização desta dissertação, direta ou indiretamente.

A todos, meu mais sincero muito obrigada!

RESUMO

A agricultura desempenha um papel central na economia brasileira, mas o setor enfrenta desafios como altos custos de produção e impactos socioambientais nas áreas de cultivo. Estimar o rendimento agrícola com assertividade é fundamental para permitir a precificação antecipada, otimizando a gestão da produção. Apesar de muitos estudos sobre previsões de rendimento em diversas culturas por meio do sensoriamento remoto, há uma lacuna significativa na pesquisa sobre a batata-doce. Nesse contexto, o uso de Aeronaves Remotamente Pilotadas (ARP) surge como uma abordagem promissora, proporcionando previsões não destrutivas na cultura. Neste sentido, esta pesquisa teve como objetivo desenvolver um modelo para prever o rendimento da batata-doce a partir de imagens de alta resolução espacial, utilizando algoritmos de aprendizado de máquina. Foram treinados para calibração de modelos os algoritmos *Random Forest* (RF), *K-Nearest Neighbors* (KNN), *Extreme Gradient Boosting* (XGBoost) e Regressão Linear. Para redução dos dados de entrada dos modelos, diversas técnicas de seleção de atributos foram aplicadas. O estudo foi realizado em uma área comercial de cultivo de batata-doce no município de Regente Feijó, região Oeste do Estado de São Paulo, Brasil. As imagens foram capturadas com uma câmera multiespectral Alpha 7Rxxx Sextuple, da Agrowing, com 14 bandas espectrais. A câmera foi embarcada em uma ARP Matrice 300RTK, da DJI. Além das bandas espectrais, foram testados os índices espectrais de vegetação *Normalized Difference Vegetation Index* (NDVI), *Green Normalized Difference Vegetation Index* (GNDVI) e *Normalized Difference Red Edge Index* (NDRE) como atributos do modelo. O peso das raízes tuberosas foi usado como variável *target*. Os resultados mostram que o modelo RF apresentou o melhor desempenho, com valores de MAE = 1,39 t/ha, RMSE = 2,15 t/ha, *bias* = 7,40% e $R^2 = 0,88$, destacando-se como uma abordagem eficiente para a previsão de rendimento da batata-doce.

Palavras-chave: Predição; sensoriamento remoto; sensor multiespectral; agricultura digital, colheita inteligente.

ABSTRACT

Agriculture plays a central role in the Brazilian economy, but the sector faces challenges such as high production costs and socio-environmental impacts on cultivated areas. Accurately estimating agricultural yield is essential to enable early pricing, optimizing production management. Despite many studies on yield predictions in various crops through remote sensing, there is a significant gap in research on sweet potatoes. In this context, the use of Remotely Piloted Aircraft (RPA) emerges as a promising approach, providing non-destructive predictions in the crop. In this sense, this research aimed to develop a model to predict sweet potato yield from high spatial resolution images, using machine learning algorithms. The Random Forest (RF), K-Nearest Neighbors (KNN), Extreme Gradient Boosting (XGBoost) and Linear Regression algorithms were trained for model calibration. To reduce the input data of the models, several attribute selection techniques were applied. The study was carried out in a commercial sweet potato cultivation area in the municipality of Regente Feijó, western region of the state of São Paulo, Brazil. The images were captured with an Alpha 7Rxxx Sextuple multispectral camera, from Agrowing, with 14 spectral bands. The camera was embedded in a DJI ARP Matrice 300RTK. In addition to the spectral bands, the spectral vegetation indices Normalized Difference Vegetation Index (NDVI), Green Normalized Difference Vegetation Index (GNDVI) and Normalized Difference Red Edge Index (NDRE) were tested as model attributes. The weight of tuberous roots was used as the target variable. The results show that the RF model presented the best performance, with values of MAE = 1.39 t/ha, RMSE = 2.15 t/ha, bias = 7.40% and $R^2 = 0.88$, standing out as an efficient approach for sweet potato yield prediction.

Keywords: Prediction; remote sensing; multispectral sensor; digital agriculture; smart harvesting.

LISTA DE FIGURAS

Figura 1. Curva do fator de reflectância de uma folha verde sadia.....	28
Figura 2. Espectro de reflectância médio de genótipos de trigo durante o processo de senescência (10 denota copas completamente verdes, 0 denota senescência completa, com base em pontuações visuais).	29
Figura 3. Desenvolvimento da equação partir de dois alvos de referência utilizando o método da linha empírica.	32
Figura 4. Ajuste de uma reta por pontos experimentais pelo Método dos Mínimos Quadrados (MMQ).	34
Figura 5. Representação do <i>Random Forest</i> como regressor.	36
Figura 6. Arquitetura geral do algoritmo XGBoost.....	37
Figura 7. KNN para regressão definindo um novo ponto (vermelho) através dos vizinhos (k) pela métrica da distância, sendo esse novo valor definido como a média de todos os valores do k vizinhos combinados.....	38
Figura 8. Localização da área de estudo – Regente Feijó, SP, Brasil e distribuição espacial dos elementos amostrais da cultura de batata-doce para análise radiométrica e coleta de dados das raízes tuberosas.	43
Figura 9. Levantamento estático rápido com uso de a) base e b) <i>rover</i> para obtenção de dados GNSS.....	45
Figura 10. Câmera multiespectral, modelo <i>Alpha 7Rxxx Sextuple</i> , fabricante <i>Agrowing</i> ..	46
Figura 11. Quadrantes referentes à câmera <i>Agrowing</i> de 14 bandas e seus respectivos comprimentos de onda.....	47
Figura 12. ARP, modelo <i>Matrice 300 RTK</i> , fabricante <i>DJI</i>	48
Figura 13. Fluxograma da metodologia geral.....	50
Figura 14. Fluxograma do processo aplicado para realizar o processamento fotogramétrico das imagens aéreas e geração dos ortomosaicos.	51
Figura 15. Recorte de uma das imagens tomadas pelo sensor possibilitando a visualização do alvo em EVA.	52

Figura 16. Resposta espectral dos alvos de EVA (branco, cinza claro, cinza escuro e preto) para cada banda do sensor multiespectral da <i>Agrowing</i> de acordo com seus valores de ND e refletância. Cada <i>plot</i> exibe os valores de R ² e a equação (y) para cada banda.....	54
Figura 17. Ortomosaico e histograma referente à campanha de 04 de abril de 2023.....	61
Figura 18. Gráfico de dispersão (<i>scatter plot</i>) de cada um dos algoritmos a) Random Forest, b) KNN, c) XGBoost, d) Regressão Linear com valores de peso observado x predito (em g/m ²), totalizando em 12 pontos teste.....	66
Figura 19. Gráfico dos valores de rendimento (g/m ²) em relação ao observado (real) – representado em linha contínua preta – e predito para cada algoritmo: RF (tracejado vermelho), KNN (tracejado azul), XGBoost (tracejado verde) e Regressão Linear (tracejado laranja). No eixo x aparecem as amostras que foram usadas nos dados de teste e no eixo y, os rendimentos (g/m ²).....	66
Figura 20. Gráfico de barras representado os valores que foram preditos em cada algoritmo para as diferentes datas de campanhas. Em tracejado vermelho aparece a linha com o valor de referência (relativo ao valor de colheita). As linhas tracejadas em verde retratam os valores que chegaram em até 10% (+ e -) do valor de referência.	69
Figura 21. Média dos pesos (g) das raízes tuberosas para cada data de campanha de campo.	71
Figura 22. Gráfico de precipitação para cada data de campanha. Os valores de precipitação são referentes a precipitação acumulada no período entre uma data de campanha (anterior) e outra (atual). Para 04/04/2023 o período foi de 27/03/2023 a 04/04/2023; 13/04/2023: 05/04/2023 a 13/04/2023; 20/04/2023: 14/04/2023 a 20/04/2023; 29/04/2023: 21/04/2023 a 29/04/2023; 08/05/2023: 30/04/2023 a 08/05/2023; 18/05/2023: 09/05/2023 a 18/05/2023.	72
Figura 23. Mapa de rendimento do modelo que apresentou as melhores métricas: RF para a data de 20/04/2023.	73
Figura 24. Mapas de rendimento da cultura da batata-doce derivados do melhor modelo encontrado, aplicados para cada algoritmo (RF, KNN, XGBoost e Regressão Linear) e data de campanha de campo (04/04/2023, 13/04/2023, 20/04/2023, 29/04/2023, 08/05/2023, 18/05/2023) apresentados em tons de vermelho (valores mais baixos de peso em g/m ²) e verde (valores mais altos).....	76

LISTA DE TABELAS

Tabela 1. Fases de desenvolvimento da batata-doce em condições tropicais.....	24
Tabela 2. Principais índices de vegetação utilizados na agricultura.....	29
Tabela 3. Relação entre os dias de campanha, dias após plantio (DAP), semanas referentes ao plantio da cultura, dias anteriores a colheita e nº de elementos amostrais coletados por campanha.	44
Tabela 4. Comprimento de onda central e <i>Full Width at Half Maximum</i> (FWHM) referentes às 14 bandas (canais) espectrais da câmera da <i>Agrowing</i>	46
Tabela 5. Principais características da câmera multiespectral <i>Alpha 7Rxxx Sextuple</i>	47
Tabela 6. Dados referentes aos voos realizados em campo.....	48
Tabela 7. Síntese dos conjuntos de dados testados e seleção de atributos realizada para cada um deles.....	57
Tabela 8. Informações referente ao processamento realizado no Agisoft Metashape para as imagens referentes a todas as campanhas de campo (dados referentes ao processamento realizado pelo <i>software</i> da <i>Agrowing</i>).....	60
Tabela 9. Métricas dos melhores modelos encontrados para cada conjunto de elementos amostrais. Para cada conjunto de dados testados ($n = 57$, $n = 75$ e $n = 93$) foram selecionados modelos que apresentaram as melhores métricas (MAE, RMSE, R^2 e <i>Bias</i>). Também estão apresentados os métodos de seleção que foram aplicados a esses modelos e a validação cruzada escolhida ($k = 5$ ou <i>LOO</i>).	63
Tabela 10. Atributos derivados dos melhores modelos aplicados para cada conjunto de elementos amostrais ($n = 57$, $n = 75$ e $n = 93$).	64

LISTA DE ABREVIATURAS E SÍMBOLOS

°C	Graus Celsius
μm	Micrômetro
cm	Centímetros
ha	Hectares
kg	Quilogramas
km	Quilômetros
m	Metros
m/s	Metros por segundo
mm	Milímetros
nm	Nanômetros
n°	Número
t	Toneladas
<i>T_B</i>	Temperatura basal superior
<i>T_b</i>	Temperatura basal inferior

LISTA DE SIGLAS

ANAC	Agência Nacional de Aviação Civil
ANOVA	Analysis of variance
ARP	Aeronave Remotamente Pilotada
CART	Classification and Regression Tree
Cepea	Centro de Estudos Avançados em Economia Aplicada
CNA	Confederação da Agricultura e Pecuária do Brasil
COVID-19	Corona Virus Disease
DAP	Dias após plantio
DAS	Dias após semeadura
DVI	Difference Vegetation Index
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ENVI	Environment for Visualizing Images
ESALQ	Escola Superior de Agricultura "Luiz De Queiroz"
EVA	Etileno Acetato de Vinila
FAO	Food and Agriculture Organization
FWHM	Full Width at Half Maximum
GCPs	Ground Control Points
GDD	Graus-dia de desenvolvimento
GNDVI	Green Normalized Difference Vegetation Index
GNSS	Global Navigation Satellite System
GPS	Global Positioning System
GSD	Ground Sample Distance
IBGE	Instituto Brasileiro de Geografia e Estatística
IBM	International Business Machines Corporation
Ifov	Istantaneous Field of View

INMET	Instituto Nacional de Meteorologia
IVs	Índices de Vegetação
KNN	K-Nearest Neighbors
LOO	Leave One Out
MAE	Mean Absolute Error (erro médio absoluto)
MDS	Modelo Digital de Superfície
MMQ	Método dos Mínimos Quadrados
MP	Megapixel
MTR	Multi-target Regression
ND	Número digital
NDRE	Normalized Difference Red Edge Index
NDVI	Normalized Difference Vegetation Index
NIR	Near Infrared
ODS	Objetivos do Desenvolvimento Sustentável
ONU	Organização das Nações Unidas
PIB	Produto Interno Bruto
PLS	Partial Least Square
PPK	Post Processed Kinematic
R ²	Coefficiente de determinação
RBMC	Rede Brasileira de Monitoramento Contínuo
REM	Radiação Eletromagnética
RF	Random Forest
RFR	Random Forest Regressor
RGB	Red, green, blue
RMSE	Raiz Do Erro Quadrático Médio
RMSE	Root mean squared error (erro quadrático médio)

ROI	Region of Interest
SAVI	Soil-Adjusted Vegetation Index
SHAP	Shapley Additive Explanations
SIG	Sistemas de Informações Geográficas
SR	Simple Ratio
SVM	Support Vector Machine
SWIR	Short Wave Infrared
TAL	Taxa Assimilatória Líquida
UAV	Unmanned Aerial Vehicle
UNESP	Universidade Estadual Paulista
UPH	Unidade de Planejamento de Recursos Hídricos
USP	Universidade de São Paulo
VANT	Veículos Aéreos Não Tripulados
VIP	Variable Importance in Projection
VIS	Visível
XGBoost	Extreme Gradient Boosting

SUMÁRIO

1 INTRODUÇÃO	19
2 HIPÓTESE.....	21
3 OBJETIVOS	21
3.1 Objetivo geral	21
3.2 Objetivos específicos	21
4 JUSTIFICATIVA	22
5 FUNDAMENTAÇÃO TEÓRICA.....	23
5.1 A cultura da batata doce.....	23
5.2 Produção de batata-doce no Brasil.....	25
5.3 Sensoriamento remoto por ARP	26
5.4 Comportamento espectral da vegetação	27
5.5 Índices espectrais de vegetação (IV)	29
5.6 Calibração radiométrica.....	30
5.7 Algoritmos de aprendizado de máquina para modelagem preditiva.....	32
5.7.1 Regressão Linear por Mínimos Quadrados Ordinários.....	33
5.7.2 <i>Random Forest</i> (RF)	34
5.7.3 <i>Extreme Gradient Boosting</i> (XGBoost)	36
5.7.4 <i>K-Nearest Neighbors</i> (KNN)	37
5.8 Técnicas de seleção de atributos	38
5.8.1 Método baseado em filtro	39
5.8.2 Método <i>wrapper</i>	40
5.8.3 Método <i>embedded</i>	40
5.9 Análise do desempenho dos modelos de regressão	41
6 MATERIAL E MÉTODOS	42
6.1 Área de estudo	42

6.2 Delineamento amostral e campanhas de campo	43
6.3 Posicionamento dos pontos amostrais por GNSS	44
6.4 Imageamento com ARP e câmara multiespectral	46
6.5 Dados de precipitação	48
6.6 Métodos	49
6.6.1 Processamento das imagens tomadas por ARP e geração dos ortomosaicos	50
6.6.1.1 Processamento fotogramétrico	50
6.6.1.2 Calibração radiométrica das imagens multiespectrais por linha empírica	51
6.6.2 Cálculo dos índices espectrais de vegetação	54
6.6.3 Modelo de predição de rendimento	55
6.6.3.1 Extração das estatísticas zonais das plantas amostradas	55
6.6.3.2 Preparo dos dados de entrada	56
6.6.3.3 Seleção de atributos	56
6.6.3.4 Ajuste e avaliação do modelo	58
6.6.3.5 Implementação do modelo nas imagens	59
7 RESULTADOS E DISCUSSÕES	59
7.1 Ortomosaicos	59
7.2 Predição de rendimento	61
7.3 Aplicação do modelo nas imagens	68
8 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES PARA TRABALHOS FUTUROS	77
REFERÊNCIAS BIBLIOGRÁFICAS	79
APÊNDICE A – HIPERPARÂMETROS TESTADOS PARA CADA ALGORITMO DE APRENDIZADO DE MÁQUINA (RF, KNN, XGBOOST E REGRESSÃO LINEAR). DIFERENTES VALORES DOS HIPERPARÂMETROS FORAM EXPERIMENTADOS, E O GRIDSEARCHCV FEZ A SELEÇÃO DO MELHOR VALOR PARA CADA UM DELES. OS VALORES EM NEGRITO SÃO CONSIDERADOS COMO DEFAULT PELOS ALGORITMOS	94

**APÊNDICE B – ORTOMOSAICOS DE CADA CAMPANHA DE CAMPO
RADIOMETRICAMENTE CALIBRADOS E SEUS RESPECTIVOS
HISTOGRAMAS. OS ORTOMOSAICOS ESTÃO COM APLICAÇÃO DE
CONTRASTE E AS BANDAS DAS IMAGENS ESTÃO REPRESENTADAS
NOS HISTOGRAMAS COM DIFERENTES CORES PARA MELHOR
VISUALIZAÇÃO95**

1 INTRODUÇÃO

A segurança alimentar é um dos maiores desafios para a agricultura sustentável. Com o crescimento populacional e a necessidade crescente de recursos, a produção agrícola tem enfrentado o desafio de ser mais eficiente e sustentável, ao mesmo tempo que responde às demandas do mercado global. Dentre os Objetivos de Desenvolvimento Sustentável (ODS) da Organização das Nações Unidas (ONU), o “fome zero e agricultura sustentável” (ODS2) visa acabar com a fome, alcançar a segurança alimentar e melhoria da nutrição e promover a agricultura sustentável até o ano de 2030. Dentro do ODS2, ela requer o aumento de 100% da produtividade e na renda dos pequenos agricultores (ONU, 2024). Assim, os sistemas agrícolas devem se tornar mais produtivos e menos desperdiçadores, enquanto práticas agrícolas sustentáveis e sistemas alimentares devem ser promovidos por meio de uma abordagem holística e integrada (ONU, 2024).

Em busca de atender aos ODS, as inovações tecnológicas têm desempenhado um papel crucial na modernização do setor agrícola. Entre essas inovações, o uso de sensoriamento remoto baseado em Aeronaves Remotamente Pilotadas (ARP) tem-se mostrado muito promissor em aplicações agrícolas, inclusive em previsões de rendimento de culturas, como soja (Shammi *et al.*, 2024; Zhang *et al.*, 2019), trigo (Yang, *et al.*, 2024; Fei *et al.*, 2023; Prestes, 2020), milho (Killeen *et al.*, 2024; Kumar *et al.*, 2023, Furukawa *et al.*, 2020), cana-de-açúcar (Som-Ard *et al.*, 2018; Martello, 2017), batata (Li *et al.*, 2020), entre outras. O uso de ARP tem crescido rapidamente no setor agrícola devido à sua capacidade de realizar tarefas de forma mais eficiente, substituindo métodos manuais que tradicionalmente são demorados e exaustivos. Além disso, é uma alternativa que fornece dados de alta resolução espacial e temporal, e alta flexibilidade no planejamento da coleta das imagens (Zhang e Kovacs, 2012).

Os dados obtidos por sensoriamento remoto podem ser integrados a algoritmos de aprendizado de máquina (*machine learning*), permitindo a extração eficiente de informações. Esses algoritmos são capazes de analisar dados de alta dimensionalidade e podem otimizar a previsão do desenvolvimento da cultura a partir de matrizes estruturalmente complexas (Ashpure *et al.*, 2020). Algoritmos baseados em lógica, como árvores de decisão, e classificadores baseados em regras são os algoritmos mais comuns usados com sucesso para os problemas de classificação e predição (Canizo *et al.*, 2019). As técnicas de aprendizado de máquina podem utilizar uma variedade de dados para extração de informações úteis, possibilitando tomadas de decisão mais assertivas (Borém *et al.*, 2022).

Com o uso dos algoritmos de aprendizado de máquina, é possível obter previsões mais precisas e menos morosas, permitindo o monitoramento de culturas agrícolas. Existem diversos estudos que abordam a previsão de rendimento através do sensoriamento remoto e aprendizado de máquina para diferentes culturas, como cana-de-açúcar (Leda e Lima, 2019; Albuquerque, 2014; Amaro, 2023), soja (Barros, 2021; Batistella, 2023), milho (Bertolin *et al.*, 2017; Souza e Raitz, 2020), batata (Sun *et al.*, 2020; Gómez *et al.*, 2019; Purnamasari *et al.*, 2019), entre outros. No entanto, essa abordagem ainda é pouco explorada em culturas, como a batata-doce.

Nesta pesquisa, foi realizado um levantamento buscando por estudos relacionados ao rendimento da batata-doce baseados em sensoriamento remoto. Foram encontrados poucos trabalhos envolvendo a previsão do rendimento da batata-doce por sensoriamento remoto de alta resolução, sendo assim, uma cultura ainda não muito estudada. Além disso, os poucos trabalhos que abordam esse tema utilizam dados orbitais e terrestres (espectrorradiômetro). Dados obtidos por meio de ARP ainda são uma lacuna, o que torna esta pesquisa uma das pioneiras nesta temática.

Tedesco *et al.* (2021b) utilizaram imagens de satélite (Sentinel-2) para estimar o rendimento da batata-doce por meio de índices de vegetação (IV) (*Soil Adjusted Vegetation Index* – SAVI, *Normalized Difference Vegetation Index* – NDVI e *Green Normalized Difference Vegetation Index* – GNDVI), em diferentes estágios fenológicos da cultura para duas safras (verão e inverno). Como ferramenta, utilizaram o *Auto Machine Learning* (AutoML).

Em outro estudo, Tedesco *et al.* (2021a) utilizaram a mesma área de estudo e imagens do Sentinel-2 para prever o rendimento da batata-doce, considerando a classificação dos tubérculos para comercialização (Extra: < 0,15 kg; Extra AA: 0,15 – 0,45 kg; Extra A: > 0,45 kg). Os autores utilizaram uma abordagem preditiva baseada em aprendizado de máquina, adotando *Multi-target Regression* (MTR) com *Random Forest* (RF) e *K-Nearest Neighbors* (KNN). Como atributos de entrada, foram usados o estágio fenológico (inicial, médio e tardio), GDD e os mesmos IVs (SAVI, NDVI e GNDVI).

Karakaş *et al.* (2018) realizaram um estudo de previsão de rendimento para batata-doce utilizando índices espectrais obtidos de medidas coletadas por um espectrorradiômetro *Analytical Spectral Devices (ASD) Hand-Held* para duas variedades (Koganasengan e Beniazuma) em diferentes regimes de irrigação.

Poucos estudos foram realizados até o momento, e nenhum deles utilizou dados multitemporais para a cultura da batata-doce (*Ipomoea batatas* (L.) Lam). Sun *et al.* (2020) combinaram os dados espectrais (sensor hiperespectral acoplado em ARP) adquiridos em duas datas para desenvolver um modelo de previsão de rendimento para a batata (*Solanum*

tuberosum L.) e a precisão da previsão mostrou-se superior quando comparada ao uso de dados de apenas um único dia. Nesta dissertação, essa abordagem também foi adotada.

De igual modo, há poucos estudos publicados que utilizam a câmera *Alpha 7Rxxx Sextuple* (Agrowing, Rishon LeZion, Israel) lançada recentemente pela empresa Agrowing. A câmera possui um sensor multiespectral de 14 bandas espectrais, com destaque para 3 bandas na região do vermelho, 2 na região da borda do vermelho e 1 na região do infravermelho próximo (*Near Infrared* - NIR), sendo promissor para pesquisas em culturas agrícolas.

Em suma, prever o rendimento das culturas agrícolas permite prever resultados mais próximos do real valor de produção, sendo essencial para tomada de decisões mais eficientes. Visto que a comercialização do produto é o principal problema citado por 19% produtores, de acordo com o estudo de Albernaz *et al.* (2023), é possível precificar a cultura com antecedência, minimizar perdas de lucro e garantir alimento de qualidade a um preço adequado de mercado, buscando reduzir os impactos da fome.

2 HIPÓTESE

A hipótese deste trabalho é que os valores de reflectância da parte aérea (ramas) da batata-doce sejam capazes de prever o rendimento das raízes tuberosas (massa) através de dados multitemporais e algoritmos de aprendizado de máquina aplicados a imagens multiespectrais de alta resolução espacial obtidas por sensor embarcado em ARP.

3 OBJETIVOS

3.1 Objetivo geral

O objetivo principal desta dissertação de Mestrado foi desenvolver modelos biofísicos baseadas em algoritmos de aprendizado de máquina para a predição do rendimento da cultura da batata-doce, utilizando imagens de alta resolução espacial tomadas por sensor multiespectral da empresa Agrowing embarcado em ARP.

3.2 Objetivos específicos

Os objetivos específicos deste estudo foram:

8 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Este trabalho teve como objetivo principal desenvolver um modelo de predição de rendimento da cultura da batata-doce por meio de algoritmos de aprendizado de máquina aplicados a imagens multiespectrais e multitemporais de alta resolução espacial. Ao longo da pesquisa, foram discutidos e analisados os algoritmos que apresentaram as melhores métricas para predição; como foi realizada a coleta dos dados por ARP, elementos amostrais e processamento destes dados. Isso permitiu encontrar resultados muito satisfatórios, de grande relevância para a batata-doce, uma cultura com pouquíssimos trabalhos na temática de sensoriamento remoto, especificamente para imageamento com ARP. Assim, pode-se considerar esta pesquisa como a pioneira no uso de imagens coletadas de ARP para predição de rendimento da cultura da batata-doce. Até o momento, também é a primeira pesquisa a utilizar imagens da câmera *Alpha 7Rxxx Sextuple* (Agrowing, Rishon LeZion, Israel) para predição de rendimento em culturas agrícolas. Enfatiza-se aqui, a originalidade do trabalho, desde a extração dos dados por ARP, em que foi feita a coleta das imagens em campo até a construção dos modelos, testando diferentes algoritmos, atributos de uma câmera multiespectral ainda não testados e diversos hiperparâmetros. Além disso, não havia estudos sobre os dados multitemporais experimentados para a batata-doce (*Ipomoea batatas* (L.) Lam), apenas para a batata (*Solanum tuberosum* L.), em que foram combinadas duas datas de campanha (Sun *et al.*, 2020), indicando mais uma descoberta para o setor agrícola, principalmente para a cultura da batata-doce, que para este caso, foram estabelecidas seis datas.

Com base nos dados e métodos utilizados, foi possível abordar todos os objetivos específicos. A partir das imagens multiespectrais foi possível extrair três conjuntos de dados, em que foi feita seleção de atributos e avaliação das métricas para cada um deles. Para a seleção dos atributos, foram aplicados os métodos *Boruta*, *Spearman*, ANOVA, informação mútua, SHAP, VIP e índice de Gini. A seleção pelo método SHAP aplicado ao algoritmo XGBoost resultou no melhor modelo obtido, reduzindo drasticamente o número de atributos – de 51 para 4. Uma solução interessante foi atribuir o valor de 0 g/m² às amostras de solo na área, melhorando significativamente as métricas avaliadas em comparação aos outros conjuntos de dados testados. Dentre os algoritmos testados, o RF obteve a melhor predição, seguido pelo KNN, XGBoost e, por fim, Regressão Linear. O melhor período para realizar a predição foi de 36 dias antes da colheita, com 125 DAP.

O trabalho também visa contribuir como base para pesquisas que desejam utilizar a câmera da empresa *Agrowing* como ferramenta, visto que é uma câmera nova no mercado e que promete resultados promissores na área de agricultura por ter 3 bandas na região do vermelho, 2 bandas na região da borda do vermelho e 1 na região do NIR. Além de possuir uma alta resolução espacial, tendo sido usado neste trabalho um GSD de 2,07 cm (*shutter* 1/800). As bandas que mais contribuíram foram a de 650 nm, 630 nm, 550 nm e 710 nm (regiões do vermelho, verde e borda do vermelho). Os IVs testados (NDVI, GNDVI e NDRE), apesar de muito utilizados em diversos modelos de rendimento, para esta pesquisa não apresentaram contribuição ao desempenho dos modelos.

Além disso, o estudo colabora com o ODS2 da ONU: “fome zero e agricultura sustentável”, mais especificamente sobre o “aumento de 100% da produtividade e na renda dos pequenos agricultores”. A metodologia permite que os produtores possam estar previamente cientes sobre a quantidade de batata-doce que sua área produzirá e se adequar, antecipadamente, aos preços de mercado e ao manejo necessário, apoiando as práticas de cultivo na agricultura.

Um dos principais desafios desta pesquisa foi a coleta de elementos amostrais, pois foi adotada a abordagem multitemporal, em que os dados de rendimento foram coletados a cada campanha, as quais são laboriosas e havia pouca quantidade de mão-de-obra em campo. Para estudos futuros, recomenda-se uma quantidade maior de elementos amostrais para novos testes em algoritmos de *machine learning*. Aconselha-se a comparação de duas safras da mesma área, como verão e inverno, além de aplicar a validação do modelo em outras áreas de plantio da cultura. Recomenda-se também o uso de atributos texturais derivados das imagens multiespectrais para serem inseridos como entrada do modelo.

REFERÊNCIAS BIBLIOGRÁFICAS

- Agência Nacional de Aviação Civil (ANAC, Brasil).** Drones. Disponível em: <<https://www.gov.br/anac/pt-br/assuntos/drones>>. Acesso em: 16 set. 2024.
- ALBERNAZ, D. V.; MELO, R. A. de C.; VENDRAME, L. P. de C.; AMARO, G. B. Estudo prospectivo sobre produção de batata-doce no Brasil, desafios e demandas. **Research Gate**. 2023. Disponível em: <https://www.researchgate.net/publication/375892039_Estudo_prospectivo_sobre_producao_de_batata-doce_no_Brasil_desafios_e_demandas>. Acesso em: 01 out. 2024.
- ALBUQUERQUE, E. M. **Modelagem da produtividade da cana-de-açúcar na região de Barretos e Morro Agudo, São Paulo.** Dissertação (Mestrado em Meteorologia) – Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais. Campina Grande, 2014, 70p. Disponível em: <<http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/3836>>. Acesso em: 27 ago. 2023.
- AMARO, Rafaella Pironato. **Estimativa de produtividade da cana-de-açúcar a partir de imagens do satélite Sentinel-2^a e o algoritmo de aprendizagem de máquina *Random Forest*.** Dissertação (Mestrado em Ciências) – Escola Superior de Agricultura Luiz de Queiroz (ESALQ), Piracicaba, 2023. <https://doi.org/10.11606/D.11.2023.tde-02102023-163947>
- ANDEREGG, J.; YU, K.; AASEN, H.; WALTER, A.; LIEBISCH, F.; HUND, A. Spectral Vegetation Indices to Track Senescence Dynamics in Diverse Wheat Germplasm. **Front. Plant Sci.**, 10:1749, 2020. doi: 10.3389/fpls.2019.01749.
- ARIZA, A.; IRIZAR, M.R.; BAYER, S. Empirical line model for the atmospheric correction of sentinel-2A MSI images in the Caribbean Islands. **European Journal of Remote Sensing**, 51 (1): 765-776, 2018.
- ASHAPURE, A.; JUNG, J.; CHANG, A.; OH, S.; YEOM, J.; MAEDA, M.; MAEDA, A.; DUBE, N.; LANDIVAR, J.; HAGUE, S.; 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, p. 180-194, 2020. <https://doi.org/10.1016/j.isprsjprs.2020.09.015>
- BAESSO, R. D. S.; SOUZA, A. A. D. O coeficiente de determinação é uma medida confiável do poder explicativo de modelos de estimação do valor intrínseco das ações negociadas na Bovespa. In: **Congresso USP Controladoria e Contabilidade**, p. 1-17, 2010.

- BARBEDO, J. G. A. A Review on the Use of Unmanned Aerial Vehicles and Imaging Sensors for Monitoring and Assessing Plant Stresses. **Drones**, 3, 40, 2019. <https://doi.org/10.3390/drones3020040>
- BARNES, E. M. *et al.* Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. In: **International Conference on Precision Agriculture**, Bloomington. Madison: ASA: CSSA: SSSA, 2000.
- BARROS, A. C. de. **Estimativa da produção agrícola por meio de técnicas de sensoriamento remoto**. Tese (doutorado) – Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrônômicas, Botucatu, 2021, 179p. Disponível em: <<https://repositorio.unesp.br/handle/11449/214361>>. Acesso em: 27 ago. 2023.
- BASER, U.; BOZOGLU, M. The impacts of farm size on production cost and economic performance in beef cattle farming: a case of Samsun Province, Turkey. **Custos e @gronegocio online**, 17(1), 410-424, 2021.
- BATISTELLA, D. **Estimativa de produtividade de soja por meio de imagens orbitais e machine learning**. Tese (Doutorado em Agronomia) – Universidade Tecnológica Federal do Paraná, Pato Branco, 2023.
- BERTOLIN, N. de O.; FILGUEIRAS, R.; VENANCIO, L. P.; MANTOVANI, E. C. Predição da produtividade de milho irrigado com auxílio de imagens de satélite. **Revista Brasileira de Agricultura Irrigada**, v.11, n.º.4, p. 1627 – 1638, 2017. doi: 10.7127/rbai.v11n400567
- BERVEGLIERI, A.; IMAI, N. N.; WATANABE, F. S. Y.; TOMMASELLI, A. M. G.; EDERLI, G. M. P.; DE ARAÚJO, F. F.; LUPATINI, G. C.; HONKAVAARA, E. Remote Prediction of Soybean Yield Using UAV-Based Hyperspectral Imaging and Machine Learning Models. **AgriEngineering**, 6, 3242-3260, 2024. <https://doi.org/10.3390/agriengineering6030185>
- BHARADIYA, J. P.; TZENIOS, N. T.; REDDY, M. Forecasting of crop yield using remote sensing data, agrarian factors and machine learning approaches. **Journal of Engineering Research and Reports**, 24(12), 29-44, 2023. <https://doi.org/10.9734/jerr/2023/v24i12858>
- BIKIA, V.; ROVAS, G.; PAGOULATOU, S.; STERGIOPULOS, N. Determination of Aortic Characteristic Impedance and Total Arterial Compliance from Regional Pulse Wave Velocities Using Machine Learning: An in-silico Study. **Frontiers in Bioengineering and Biotechnology**. 9. 10.3389/fbioe.2021.649866, 2021.
- BORÉM, A.; QUEIROZ, D. M.; VALENTE, D. S. M.; PINTO, F. A. C. **Agricultura Digital**. São Paulo: Oficina de Textos. 2022.

- BRAIDO, L. M. H.; TOMMASELLI, J. T. G. Caracterização climática e dos anos extremos (chuvoso e seco): seus efeitos na produção de cana-de-açúcar, milho e soja para a região do Pontal do Paranapanema – SP. **Revista Formação (Online)**. ISSN: 1517-543X. E-ISSN: 2178-7298, 2010. <https://doi.org/10.33081/81epositó.v1i17.313>
- BREIMAN, L. Random Forests. 2001. Statistics Department University of California Berkeley, CA. **Machine Learning**, 45, 5–32, 2001.
- BREIMAN, Leo. **Classification and regression trees**. Routledge, 2017.
- BRIGGS, G. E.; KIDD, F. A.; WEST, C. A quantitative analysis of plant growth. **Annals of Applied Biology**, v. 7, p. 202-223, 1920.
- CAMPOS FILHO, F. F. **Algoritmos Numéricos: uma abordagem moderna de cálculo numérico**. 3ª edição. Ed. Minas Gerais: LTC, 2018. 520 p.
- CANIZO, B. V. *et al.* Data mining approach based on chemical composition of grape skin for quality evaluation and traceability prediction of grapes. **Computers and Electronics in Agriculture**, v. 162, n. March, p. 514–522, 2019.
- CASTEJON, E. F.; FONSECA, L. M. G.; FORSTER, C. H. Q. Melhoria do processo de correção geométrica de imagens CBERS-CCD pelo uso de amostras georreferenciadas classificadas. **Boletim De Ciências Geodésicas**, 21(4), 658–673, 2015. <https://doi.org/10.1590/S1982-21702015000400038>
- Centro de Estudos Avançados em Economia Aplicada (Cepea/Esalq-USP) e Confederação da Agricultura e Pecuária do Brasil (CNA)**. PIB do Agronegócio Brasileiro. Disponível em: <<https://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx>>. Acesso em: 02 mar. 2022.
- CHAVES, M. E. D.; ALVES, M. de C. Recent applications of the MODIS sensor for soybean crop monitoring and deforestation detection in Mato Grosso, Brazil. **CAB Reviews Perspectives in Agriculture Veterinary Science Nutrition and Natural Resources**. 14. 10.1079/PAVSNNR201914007, 2019.
- CHEN, G.; CHEN, J. A novel wrapper method for feature selection and its applications. **Neurocomputing**, v. 159, p. 219-226, ISSN 0925-2312, 2015. <https://doi.org/10.1016/j.neucom.2015.01.070>.
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: **Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining**. 2016. p. 785-794.
- CHUKWU, G. O. Crop irrigation water needs of sweet potato (*Ipomoea batatas*). **African Journal of root and Tuber Crops**, v. 1, p.35-38, 1995.

- Confederação da Agricultura e Pecuária do Brasil (CNA).** Guerra Rússia-Ucrânia: o panorama do abastecimento de fertilizantes. Disponível em: <<https://cnabrasil.org.br/noticias/guerra-russia-ucrania-o-panorama-do-abastecimento-de-fertilizantes>>. Acesso em: 05 out 2023.
- CORRALES, D. C.; SCHOVING, C.; RAYNAL, H.; DEBAEKE, P.; JOURNET, E-P.; CONSTANTIN, J. A surrogate model based on feature selection techniques and regression learners to improve soybean yield prediction in southern France. **Computers and Electronics in Agriculture**, v. 192, 106578, ISSN 0168-1699, 2022. <https://doi.org/10.1016/j.compag.2021.106578>.
- COVER, T. M.; HART, P. E. Nearest neighbor pattern classification. **IEEE Transactions on Information Theory**, vol. 13, no. 1, pp. 21-27, 1967, doi: 10.1109/TIT.1967.1053964.
- COVER, T. M.; THOMAS, J. A. **Elements of information theory**. John Wiley & Sons, 1991.
- CUNHA, G. R. da.; PIRES, J. L. F.; DALMAGO, G. A.; SANTI, A.; PASINATO, A. A evolução do conceito de rendimento em agricultura e as estratégias de segurança alimentar. **Revista Plantio Direto**, p. 9, 2011.
- CUNHA, R. L. D. F.; SILVA, B. Estimating Crop Yields with Remote Sensing and Deep Learning. **2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS)**, Santiago, Chile, pp. 273-278, 2020. doi: 10.1109/LAGIRS48042.2020.9165608.
- DEBALKE, D. B.; ABEBE, J. T. Maize yield forecast using GIS and remote sensing in Kaffa Zone, Southwest Ethiopia. **Environmental Systems Research**, 11, 1, 2022. <https://doi.org/10.1186/s40068-022-00249-5>
- DONG, W.; HUANG, Y.; LEHANE, B.; MA, G. XGBoost algorithm-based prediction of concrete electrical resistivity for structural health monitoring. **Automation in Construction**, v. 114, 103155, 2020. <https://doi.org/10.1016/j.autcon.2020.103155>.
- EFFROSYNIDIS, D.; ARAMPATZIS, A. An evaluation of feature selection methods for environmental data. **Ecological Informatics**, v. 61, 101224, ISSN 1574-9541, 2021. <https://doi.org/10.1016/j.ecoinf.2021.101224>.
- Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) – Hortaliças.** Sistema de produção da batata-doce. Versão Eletrônica, 2021. Disponível em: <<https://www.embrapa.br/documents/1355126/8971369/Sistema+de+Produ%C3%A7%C3%A3o+de+Batata-Doce.pdf/4632fe60-0c35-71af-79cc-7c15a01680c9>>. Acesso em 31 mar. 2022.

- Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). **A cultura da batata-doce**. Brasília, DF: Embrapa Hortaliças, 1995. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/162018/1/A-cultura-da-batata-doce.pdf>>. Acesso em: 22 out. 2024.
- FALL, C. M. N.; LAVAYSSE, C.; KERDILES, H.; DRAMÉ, M. S.; ROUDIER, P.; GAYE, A. T. Performance of dry and wet spells combined with remote sensing indicators for crop yield prediction in Senegal. **Climate Risk Management**, 33, 100331, 2021. <https://doi.org/10.1016/j.crm.2021.100331>
- FEI, S.; HASSAN, M. A.; XIAO, Y. *et al.* UAV-based multi-sensor data fusion and machine learning algorithm for yield prediction in wheat. **Precision Agriculture**, 24, 187–212, 2023. <https://doi.org/10.1007/s11119-022-09938-8>
- FENG, C.; ZHANG, W.; DENG, H.; DONG, L.; ZHANG, H.; TANG, L.; ZHENG, Y.; ZHAO, Z. A Combination of OBIA and Random Forest Based on Visible UAV Remote Sensing for Accurately Extracted Information about Weeds in Areas with Different Weed Densities in Farmland. **Remote Sensing**, 15, 4696, 2023. <https://doi.org/10.3390/rs15194696>
- FERNANDES, P. **Estimativa da produtividade de milho (*Zea Mays L.*) através de imagens multiespectrais obtidas por veículo aéreo não tripulado**. Dissertação (Mestrado em Agricultura de Precisão) – Universidade Federal de Santa Maria (UFSM), Santa Maria, 2016.
- FISHER, R. A. The use of multiple measurements in taxonomic problems. **Annals of eugenics**, v. 7, n. 2, p. 179-188, 1936.
- Food and Agriculture Organization of the United Nations (FAO) FAOSTAT: Countries by commodity**. 2022. Disponível em: <https://www.fao.org/faostat/en/#rankings/countries_by_commodity>. Acesso em: 25 set. 2024.
- FURUKAWA, F.; MARUYAMA, K.; SAITO, Y. K.; KANEKO, M. Corn Height Estimation Using UAV for Yield Prediction and Crop Monitoring. In: Avtar, R., Watanabe, T. (eds) **Unmanned Aerial Vehicle: Applications in Agriculture and Environment**. Springer, Cham, 2020. https://doi.org/10.1007/978-3-030-27157-2_5
- GASQUES, J. G.; BACCHI, M. R. P.; RODRIGUES, L.; BASTOS, E. T.; VALDES, C. (2016). **Produtividade da agricultura brasileira: a hipótese da desaceleração**. Brasília: Ipea, 2016. p. 144-163. Disponível em: <<https://repositorio.ipea.gov.br/bitstream/11058/9241/1/Produtividade%20da%20agricultura.pdf>>. Acesso em: 08 set. 2023.

- GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, [s.l.], v.58, n.3, p.289-298, 1996. DOI. 10.1016/S0034-4257(96)00072-7.
- GITELSON, A. A.; MERZLYAK, M. N. Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. **Journal of Plant Physiology**, 148, 494–500, 1996.
- GOMES, Amanda Pereira Assis. **Calibração radiométrica de imagens obtidas por câmeras utilizadas em veículos aéreos não tripulados**. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa, MG, 2020. 53 f.
- GÓMEZ, D.; SALVADOR, P.; SANZ, J.; CASANOVA, J. L. Potato Yield Prediction Using Machine Learning Techniques and Sentinel 2 Data. **Remote Sensing**, 11, 1745, 2019. <https://doi.org/10.3390/rs11151745>
- HELENE, O. **Métodos dos mínimos quadrados**. Editora Livraria da Física, 2006.
- HODSON, T. O. "Root-mean-square error (RMSE) or mean absolute error (MAE): When to use them or not." **Geoscientific Model Development**, v. 15, n. 14, p. 5481-5487, 2022.
- HOEFSLOOT, P.; INES, A. V.; DAM, J. C. V.; DUVEILLER, G.; KAYITAKIRE, F.; HANSEN, J. Combining crop models and remote sensing for yield prediction: Concepts, applications and challenges for heterogeneous smallholder environments. **In Proceedings of the Report of CCFAS-JRC Workshop at Joint Research Centre, Ispra, Italy**, 13–14, Joint Research Center Technical Report. Publications Office of the European Union: Luxembourg, 2012. Disponível em: < <https://hdl.handle.net/10568/25135> >. Acesso em: 01 out. 2024.
- HUETT, D. O. Evaluation of yield, variability and quality of sweetpotato cultivars in subtropical Australia. **Experimental Agriculture**, v.12, p. 9-16, 1976. doi:10.1017/S0014479700007006
- IMANNI, H. S. EL.; HARTI, A. EL.; IYSAOUY, L. EL. Wheat Yield Estimation Using Remote Sensing Indices Derived from Sentinel-2 Time Series and Google Earth Engine in a Highly Fragmented and Heterogeneous Agricultural Region. **Agronomy**, 12(11):2853, 2022. <https://doi.org/10.3390/agronomy12112853>
- Instituto Brasileiro de Geografia e Estatística (IBGE)**. Produção Agrícola Municipal (PAM): Tabelas. 2023. Disponível em: < <https://sidra.ibge.gov.br/pesquisa/pam/tabelas> >. Acesso em: 25 set. 2024.

Instituto Brasileiro de Geografia e Estatística (IBGE). RBMC – Rede Brasileira de Monitoramento Contínuo dos Sistemas. [s. d]. Disponível em: <<https://www.ibge.gov.br/85epositório/85epositório-sobre-posicionamento-geodesico/rede-geodesica/16258-rede-brasileira-de-monitoramento-contínuo-dos-sistemas-gnss-rbmc.html?=&t=o-que-e>>. Acesso em: 18. Mar. 2023.

Instituto Brasileiro de Geografia e Estatística (IBGE). Recomendações para levantamentos relativos estáticos – GPS. 2008. Disponível em: <https://geoftp.ibge.gov.br/85eposit_e_outros_documentos_de_referencia/normas/recom_gps_internet.pdf>. Acesso em: 18 mar. 2023.

Instituto Nacional de Meteorologia (INMET). Banco de dados Meteorológicos. Disponível em: <<https://bdmep.inmet.gov.br/>>. Acesso em: 16 set. 2024.

International Business Machines Corporation (IBM). What is the k-nearest neighbors (KNN) algorithm? 2024. Disponível em: <[https://www.ibm.com/topics/knn#:~:text=The%20k%2Dnearest%20neighbors%20\(KNN,used%20in%20machine%20learning%20today.](https://www.ibm.com/topics/knn#:~:text=The%20k%2Dnearest%20neighbors%20(KNN,used%20in%20machine%20learning%20today.)>. Acesso em: 01 out. 2024.

İRİK, H. A.; ROPELEWSKA, E.; ÇETIN, N. Using spectral vegetation indices and machine learning models for predicting the yield of sugar beet (*Beta vulgaris* L.) under different irrigation treatments. **Computers and Electronics in Agriculture**, 221, 109019, 2024.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos naturais.** São José dos Campos: Parênteses, 2009.

JENSEN, R. R.; GATRELL, J. D.; D. D. MCLEAN (Eds.). **Geo-Spatial Technologies in Urban Environments**, N.Y.: Springer, 176 p. 2005.

JEONG, Y.; YU, J.; WANG, L.; SHIN, H.; KOH, S. M.; PARK, G. Cost-effective reflectance calibration method for small UAV images. **International Journal of Remote Sensing**, 39(21), 7225-7250, 2018.

JORGE, L. A. de C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão. **Ferramentas para agricultura de precisão**, v. 8, p. 109, 2013. Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1003485/uso-de-veiculos-aereos-nao-tripulados-vant-em-agricultura-de-precisao>>. Acesso em: 8 ago. 2023.

JOSHI, A.; PRADHAN, B.; CHAKRABORTY, S.; BEHERA, M. D. Winter wheat yield prediction in the conterminous United States using solar-induced chlorophyll fluorescence data and XGBoost and random forest algorithm. **Ecological Informatics**, 77, 102194, 2023. <https://doi.org/10.1016/j.ecoinf.2023.102194>

- KARAKAŞ, M. C. *et al.* Estimation of Yield in Sweet Potato Varieties with Using Spectral Indices. **Scientific Committee-Bilim Kurulu**, p. 93, 2018.
- KENNEDY, P. **A Guide to Econometrics**. Massachusetts: Blackwell Publishing, 2008.
- KHANAL, S.; FULTON, J.; KLOPFENSTEIN, A.; DOURIDAS, N.; SHEARER, S. Integration of high resolution remotely sensed data and machine learning techniques for spatial prediction of soil properties and corn yield. **Computers and electronics in agriculture**, 153, 213-225, 2018. <https://doi.org/10.1016/j.compag.2018.07.016>
- KILLEEN, P.; KIRINGA, I.; YEAP, T.; BRANCO, P. Corn Grain Yield Prediction Using UAV-Based High Spatiotemporal Resolution Imagery, Machine Learning, and Spatial Cross-Validation. **Remote Sensing**. 16(4):683, 2024. <https://doi.org/10.3390/rs16040683>
- KOHAVI, R.; JOHN, G. H. Wrappers for feature subset selection. **Artificial intelligence**, v. 97, n. 1-2, p. 273-324, 1997.
- KUMAR, C.; MUBVUMBA, P.; HUANG, Y.; DHILLON, J.; REDDY, K. Multi-Stage Corn Yield Prediction Using High-Resolution UAV Multispectral Data and Machine Learning Models. **Agronomy**. 13(5):1277, 2023. <https://doi.org/10.3390/agronomy13051277>
- KURIHARA, J.; NAGATA, T.; TOMIYAMA, H. Rice Yield Prediction in Different Growth Environments Using Unmanned Aerial Vehicle-Based Hyperspectral Imaging. **Remote Sensing**, 15(8), 2004, 2023. <https://doi.org/10.3390/rs15082004>
- KURSA, M. B.; RUDNICKI, W. R. Feature Selection with the Boruta Package. **Journal of Statistical Software**, 36(11), 1–13, 2010. <https://doi.org/10.18637/jss.v036.i11>
- KVÅLSETH, T. O. Cautionary note about R 2. **The American Statistician**, 39(4), 279-285, 1985. <https://doi.org/10.2307/2683704>
- LATORRE, M. *et al.* Correção Atmosférica: conceitos e fundamentos. **Espaço & Geografia**, v.5, n1, p.153-178, 2002.
- LEDA, V. C.; GONÇALVES, A. K.; LIMA, N. da S. Sensoriamento remoto aplicado a modelagem de produtividade da cultura da cana-de-açúcar. **Energia na agricultura**, 34(2), 263–270, 2019. <https://doi.org/10.17224/EnergAgric.2019v34n2p263-270>
- LEGENDRE, P.; DALE, M. R. T.; FORTIN, M.-J.; GUREVITCH, J.; HOHN, M.; MYERS, D. The Consequences of Spatial Structure for the Design and Analysis of Ecological Field Surveys. **Ecography**, 25, 601–615, 2002.
- LI, B.; XU, X.; ZHANG, L.; HAN, J.; BIAN, C.; LI, G.; LIU, J.; JIN, L. Above-ground biomass estimation and yield prediction in potato by using UAV-based RGB and hyperspectral imaging. **ISPRS Journal Photogrammetry and Remote Sensing**, 162, 161–172, 2020. <https://doi.org/10.1016/j.isprsjprs.2020.02.013>.

- LIU, H.; YU, L. Toward integrating feature selection algorithms for classification and clustering. **IEEE Transactions on knowledge and data engineering**, v. 17, n. 4, p. 491-502, 2005.
- LIU, L.-W.; LU, C.-T.; WANG, Y.-M.; LIN, K.-H.; MA, X.; LIN, W.-S. Rice (*Oryza sativa* L.) Growth Modeling Based on Growth Degree Day (GDD) and Artificial Intelligence Algorithms. **Agriculture**, 12, 59, 2022. <https://doi.org/10.3390/agriculture12010059>
- LIZOT, M.; ANDRADE JÚNIOR, P. P.; TROJAN, F.; MAGACHO, C. S.; THESARI, S. S.; GOFFI, A. S. Analysis of evaluation methods of sustainable supply chain management in production engineering journals with high impact. **Sustainability (Switzerland)**, 12(1), 270, 2020. <http://dx.doi.org/10.3390/su12010270>
- LOUPPE, G.; WEHENKEL, L.; SUTERA, A.; GEURTS, P. Understanding variable importances in forests of randomized trees. **Advances in neural information processing systems**, 26, 2013.
- LUNDBERG, S. M.; LEE, SU-IN. A unified approach to interpreting model predictions. **Advances in neural information processing systems**, v. 30, p. 4765-4774, 2017.
- MARTELLO, Maurício. **Estimativa da altura e produtividade da cana-de-açúcar utilizando imagens obtidas por aeronave remotamente pilotada**. Dissertação (Mestrado em Ciências) – Escola Superior de Agricultura Luiz de Queiroz (ESALQ), Piracicaba, 2017.
- MARTELLO, Maurício. **Estimativa da altura e produtividade da cana-de-açúcar utilizando imagens obtidas por aeronave remotamente pilotada**. Dissertação (Mestrado em Ciências) – Escola Superior de Agricultura Luiz de Queiroz (ESALQ), Piracicaba, 2017.
- MAZA, E. E. A. **Atividade da redutase do nitrato e acúmulo de prolina livre em *Phaseolus vulgaris* L. em função de níveis de água e doses de nitrogênio**. Tese (Mestrado) – Universidade Federal de Viçosa, Viçosa, 69p., 1991.
- MEDEIROS, J. G. Análise de crescimento em duas cultivares de batata-doce (*Ipomoea batatas* (L.) Lam). **Revista Brasileira de Fisiologia Vegetal**, v. 2, p.23-29, 1990.
- MELO, C. **XGBoost: aprenda este algoritmo de Machine Learning em Python**. 2019. Disponível em: < <https://sigmoidal.ai/xgboost-aprenda-algoritmo-de-machine-learning-em-python/>>. Acesso em: 02 out. 2024.
- MOLIN, J. P. **Agricultura de precisão: números do mercado brasileiro – boletim técnico número 03**. USP ESALQ, 2017.
- MONTES, S. M. N. M. **Cultura da batata-doce: do plantio a comercialização**. Campinas: Instituto Agrônômico, 2013. 80p.

- MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. Editora UFV – Viçosa-MG, 2003, 2ª ed. 307p.
- MURDOCH, W.; JAMES, SINGH, C.; KUMBIER, K.; ABBASI-ASL, R.; YU, B. Interpretable machine learning: definitions, methods, and applications. **arXiv preprint**, 1901.04592, 2019. <https://doi.org/10.1073/pnas.1900654116>
- NOH, S. A.; PARK, S. H.; HUH, G. H.; PAEK, K. H.; SHIN, J. S.; BAE, J. M. Growth retardation and differential regulation of expansin genes in chilling stresses sweetpotato. **Plant Biotechnol Reports**, v.3, p. 75-85, 2009. <http://dx.doi.org/10.1007/s11816-008-0077-0>
- NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. 4ª Edição. São Paulo: Blucher, 2010. Cap. 4.
- OLIVEIRA, S. P.; VIANA, A. E. S. V.; MATSUMOTO, S. N.; JÚNIO, N. S. C.; SÃO JOSÉ, T. S. A. R. Efeito da poda e de épocas de colheita sobre características agrônômicas da mandioca. **Acta Scientiarum Agronomy**, v.32, p.99-108, 2010.
- OMETTO, J. C. **Bioclimatologia vegetal**. São Paulo: Agronômica Ceres 1981. 440p.
- ONWUEME, I. C.; CHARLES, W. B. **TROPICAL Root and Tuber Crops: Production, perspectives and future prospects**. Rome: FAO, 1994. 115p.
- Organização das Nações Unidas (ONU)**. Food Security and Nutrition and Sustainable Agriculture. Disponível em: <<https://sdgs.un.org/topics/food-security-and-nutrition-and-sustainable-agriculture>>. Acesso em: 30 set. 2024.
- PADRÓ, J.-C.; MUÑOZ, F.-J.; ÁVILA, L.Á.; PESQUER, L.; PONS, X. Radiometric Correction of Landsat-8 and Sentinel-2A Scenes Using Drone Imagery in Synergy with Field Spectroradiometry. **Remote Sensing**, 10, 1687, 2018. <https://doi.org/10.3390/rs10111687>
- PANDAY, U. S.; PRATIHAST, A. K.; ARYAL, J.; KAYASTHA, R. B. A Review on Drone-Based Data Solutions for Cereal Crops. **Drones**, 4, 41, 2020. <https://doi.org/10.3390/drones4030041>
- PEARSON, Karl. Notes on the history of correlation. **Biometrika**, v. 13, n. 1, p. 25-45, 1920.
- PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. Oficina de textos, 2012.
- PORTO, L. R.; BERVEGLIERI, A.; IMAI, N. N. Calibração radiométrica em imagens multiespectrais aéreas utilizando linha empírica e placa colorimétrica. In: **Anais do XX Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis. Anais eletrônicos. São José dos Campos, INPE, 2023. Disponível em: <<https://proceedings.science/sbsr->

2023/trabalhos/calibracao-radiometrica-em-imagens-multiespectrais-aereas-utilizando-linha-empir?lang=pt-br> Acesso em: 10 jul. 2023.

- POSSEBON, W. P. **Comportamento espectral da soja e predição de produtividade com uso de NVDI**. Trabalho de Conclusão de Curso (Graduação) – Universidade Estadual do Rio Grande do Sul, Curso de Bacharelado em Agronomia, Unidade em Santana do Livramento, 2023. Santana do Livramento, 2023. 21 f.
- PRESTES, Christopher Djonny Pereira. **Predição de produtividade de trigo por meio de dados espectrais e altura estimada da planta obtidos por meio de aeronave remotamente pilotada**. Dissertação (Mestrado em Computação Aplicada) - Universidade Estadual de Ponta Grossa, Ponta Grossa, 2020.
- PRESTES, Christopher Djonny Pereira. **Predição de produtividade de trigo por meio de dados espectrais e altura estimada da planta obtidos por meio de aeronave remotamente pilotada**. Dissertação (Mestrado em Computação Aplicada) - Universidade Estadual de Ponta Grossa, Ponta Grossa, 2020.
- PRODHAN, F. A.; ZHANG, J.; YAO, F.; SHI, L.; PANGALI SHARMA, T. P.; ZHANG, D.; CAO, D.; ZHENG, M.; AHMED, N.; MOHANA, H. P. Deep Learning for Monitoring Agricultural Drought in South Asia Using Remote Sensing Data. **Remote Sensing**, 13, 1715, 2021. <https://doi.org/10.3390/rs13091715>
- PURNAMASARI, R. A.; NOGUCHI, R.; AHAMED, T. Land suitability assessments for yield prediction of cassava using geospatial fuzzy expert systems and remote sensing. **Computers and Electronics in Agriculture**, 166, 2019. <https://doi.org/10.1016/j.compag.2019.105018>.
- QUEIROGA, R. C. F.; SANTOS, M. A.; MENEZES, M. A.; VIEIRA, C. P. G.; SILVA, M. C. Fisiologia e produção de cultivares de batata-doce em função da época de colheita. **Horticultura Brasileira**, 25: 371-374, 2007.
- RAJA, S. P.; Sawicka, B.; Stamenkovic, Z.; Mariammal, G. Crop Prediction Based on Characteristics of the Agricultural Environment Using Various Feature Selection Techniques and Classifiers. **IEEE Access**, v. 10, pp. 23625-23641, 2022, doi: 10.1109/ACCESS.2022.3154350.
- REN, Y.; ZHANG, L.; SUGANTHAN, P. N. Ensemble Classification and Regression-Recent Developments, Applications and Future Directions [Review Article]. **IEEE Computational Intelligence Magazine**, vol. 11, no. 1, pp. 41-53, 2016. doi: 10.1109/MCI.2015.2471235.
- RESENDE, G. M. Características produtivas de cultivares de batata-doce em duas épocas de colheita, em Porteirinha – MG. **Horticultura Brasileira**, v.8, p.68-71, 2000. <https://doi.org/10.1590/S0102-05362000000100016>

- RONQUIM, C. C. **Dinâmica espaço temporal do carbono aprisionado na fitomassa dos agroecossistemas do Nordeste do Estado de São Paulo**. 2007. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/CNPM/2108/1/doc63_carbono_nesp.pdf>. Acesso em: 01 outb 2024.
- ROSLIM, M. H. M.; JURAIMI, A. S.; CHE'YA, N. N.; SULAIMAN, N.; MANAF, M. N. H. A.; RAMLI, Z.; MOTMAINNA, M. Using Remote Sensing and an Unmanned Aerial System for Weed Management in Agricultural Crops: A Review. **Agronomy**, 11, 1809, 2021. <https://doi.org/10.3390/agronomy11091809>
- ROSLINA, A. H.; NORAZIAH, A. Prediction of hepatitis prognosis using Support Vector Machines and Wrapper Method. **Seventh International Conference on Fuzzy Systems and Knowledge Discovery, Yantai, China**, pp. 2209-2211, 2010. doi: 10.1109/FSKD.2010.5569542.
- ROSSI, M. 2017. **Mapa pedológico do Estado de São Paulo: revisado e ampliado**. São Paulo: Instituto Florestal, v.1. 118p, 2017.
- ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. p. 309–317. In Freden, S.C. (ed.) **Third earth resources technology satellite-1 symposium**. Vol. 1: Technical presentations. NASA SP-351. Natl. Aeronautics and Space Admin., Washington, DC. 1974.
- SCHNEIDER, A.; HOMMEL, G.; BLETTNER, M. Linear regression analysis: part 14 of a series on evaluation of scientific publications. **Deutsches Arzteblatt International**, Nov;107(44):776-82, 2010. doi: 10.3238/arztebl.2010.0776.
- SHAHZAMAN, M.; ZHU, W.; BILAL, M.; HABTEMICHEAL, B. A.; MUSTAFA, F.; ARSHAD, M.; ULLAH, I.; ISHFAQ, S.; IQBAL, R. Remote Sensing Indices for Spatial Monitoring of Agricultural Drought in South Asian Countries. **Remote Sensing**, 13, 2059, 2021. <https://doi.org/10.3390/rs13112059>
- SHAMMI, S. A.; HUANG, Y.; FENG, G.; TEWOLDE, H.; ZHANG, X.; JENKINS, J.; SHANKLE, M. Application of UAV Multispectral Imaging to Monitor Soybean Growth with Yield Prediction through Machine Learning. **Agronomy**. 14(4):672, 2024 <https://doi.org/10.3390/agronomy14040672>
- SHI, X.; SONG, J.; WANG, H.; LV, X.; ZHU, Y.; ZHANG, W.; BU, W.; ZENG, L. Improving soil organic matter estimation accuracy by combining optimal spectral preprocessing and feature selection methods based on pXRF and vis-NIR data fusion. **Geoderma**, v. 430, 116301, ISSN 0016-7061, 2023. <https://doi.org/10.1016/j.geoderma.2022.116301>.

- SHMUELI, G. To Explain or to Predict?. **Statistical Science**, 25, 3, 289-310, 2010. <https://doi.org/10.1214/10-STS330>
- SILVA FILHO, F. R. da; VENANCIO, M. V. de L.; DE SOUSA, I. A. A. Aprendizado por Agrupamento. **Revista Sistemas e Mídias Digitais (RSMD)**, v. 6, n1, 2021.
- SILVA, G. B. S.; LOEBMANN, D. G. D. S. W.; FOLHARINI, S. D. O.; NOGUEIRA, S. F.; VICENTE, L. E.; ANDRADE, R. G.; FURTADO, A. L. D. S. **Procedimentos para correção geométrica de imagens de satélite**. Campinas, SP: Embrapa Monitoramento por Satélite, 2012. 18 p. Disponível em: <<https://www.infoteca.cnptia.embrapa.br/bitstream/doc/958866/1/02812.pdf>>. Acesso em: 24 out. 2024.
- SMITH, G. M.; MILTON, E. J. The use of the empirical line method to calibrate remotely sensed data to reflectance. **International Journal of Remote Sensing**, v. 20, n. 13, p. 2653-2662, 1999.
- SOM-ARD, J.; HOSSAIN, M. D.; NINSAWAT, S.; VEERACHITT, V. Pre-harvest Sugarcane Yield Estimation Using UAV-Based RGB Images and Ground Observation. **Sugar Tech**, 20, 645–657, 2018. <https://doi.org/10.1007/s12355-018-0601-7>
- SOUZA, J. M. F.; RAITZ, F. H. N. **Estimativa da produtividade do milho utilizando sensoriamento remoto**. Trabalho de Conclusão de Curso – Curso de Agronomia – Centro Universitário de Anápolis – UniEvangélica, 2020, 29p. Disponível em: <<http://repositorio.aee.edu.br/jspui/handle/aee/17104>>. Acesso em: 27 ago. 2023.
- SPEARMAN, C. The proof and measurement of association between two things. **The American Journal of Psychology**, 15(1), 72–101, 1904. <https://doi.org/10.2307/1412159>
- STABEN, G.W.; PFITZNER, K.; BARTOLO, R.; LUCIEER, A. Empirical line calibration of WorldView-2 satellite imagery to reflectance data: using quadratic prediction equations. **Remote Sensing Letters**, 3:6, 521-530, 2012.
- STEPANOV, A.; DUBROVIN, K.; SOROKIN, A.; ASEEEVA, T. Predicting Soybean Yield at the Regional Scale Using Remote Sensing and Climatic Data. **Remote Sensing**, 12, 1936, 2020. <https://doi.org/10.3390/rs12121936>
- STEPANOV, A.; DUBROVIN, K.; SOROKIN, A.; ASEEEVA, T. Predicting Soybean Yield at the Regional Scale Using Remote Sensing and Climatic Data. **Remote Sensing**, 12, 1936, 2020. <https://doi.org/10.3390/rs12121936>
- SULAIMAN, N.; CHE'YA, N. N.; MOHD ROSLIM, M. H.; JURAIMI, A. S.; MOHD NOOR, N.; FAZLIL ILAHI, W. F. The Application of Hyperspectral Remote Sensing Imagery

- (HRSI) for Weed Detection Analysis in Rice Fields: A Review. **Applied Sciences**, 12, 2570, 2022. <https://doi.org/10.3390/app12052570>
- SUN, C.; FENG, L.; ZHANG, Z.; MA, Y.; CROSBY, T.; NABER, M.; WANG, Y. Prediction of End-Of-Season Tuber Yield and Tuber Set in Potatoes Using In-Season UAV-Based Hyperspectral Imagery and Machine Learning. **Sensors**, 20, 5293, 2020. <https://doi.org/10.3390/s20185293>
- SUN, K.; ROY, A.; TOBIN, J. M. Artificial intelligence and machine learning: Definition of terms and current concepts in critical care research. **Journal of Critical Care**, 82, 154792, 2024. <https://doi.org/10.1016/j.jcrc.2024.154792>
- TEDESCO, D.; DE ALMEIDA MOREIRA, B. R.; JÚNIOR, M. R. B.; PAPA, J. P.; DA SILVA, R. P. Predicting on multi-target regression for the yield of sweet potato by the market class of its roots upon vegetation indices. **Computers and Electronics in Agriculture**, 191, 106544, 2021a. <https://doi.org/10.1016/j.compag.2021.106544>
- TEDESCO, D.; DE OLIVEIRA, M. F.; DOS SANTOS, A. F.; SILVA, E. H. C.; ROLIM, G. de S.; DA SILVA, R. P. Use of remote sensing to characterize the phenological development and to predict sweet potato yield in two growing seasons, **European Journal of Agronomy**, v. 129, 126337, 2021b. <https://doi.org/10.1016/j.eja.2021.126337>
- THAO, N. T. T.; KHOI, D. N.; DENIS, A.; VIET, L. V.; WELLENS, J.; TYCHON, B. Early Prediction of Coffee Yield in the Central Highlands of Vietnam Using a Statistical Approach and Satellite Remote Sensing Vegetation Biophysical Variables. **Remote Sensing**, 14, 2975, 2022. <https://doi.org/10.3390/rs14132975>
- WANG, Y.; PAN, Z.; ZHENG, J.; QIAN, L.; MINGTAO, L. A hybrid ensemble method for pulsar candidate classification. **Astrophysics and Space Science**. 364. 10.1007/s10509-019-3602-4, 2019. doi: 10.1007/s10509-019-3602-4
- WIJEWARDANA, C. REDDY, K. R.; SHANKLE, M. W.; MEYERS, S.; GAO, W. Low and high-temperature effects on sweetpotato storage root initiation and early transplant establishment. **Scientia Horticulturae**, v. 240, p. 38-48, 2018.
- WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. **Climate research**, v. 30, n. 1, p. 79-82, 2005.
- WOLD, S.; JOHANSSON, E.; COCCHI, M. PLS: partial least squares projections to latent structures. In: **3D QSAR in Drug Design: Theory, Methods and Applications**. Kluwer ESCOM Science Publisher, p. 523-550, 1993.

- YANG, S.; LI, L.; FEI, S.; YANG, M.; TAO, Z.; MENG, Y.; XIAO, Y. Wheat Yield Prediction Using Machine Learning Method Based on UAV Remote Sensing Data. **Drones**. 8(7):284, 2024. <https://doi.org/10.3390/drones8070284>
- ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision Agriculture**, 13, 693–712, 2012. <https://doi.org/10.1007/s11119-012-9274-5>
- ZHANG, H.; WANG, L.; TIAN, T.; YIN, J. A Review of Unmanned Aerial Vehicle Low-Altitude Remote Sensing (UAV-LARS) Use in Agricultural Monitoring in China. **Remote Sensing**, 13, 1221, 2021. <https://doi.org/10.3390/rs13061221>
- ZHANG, X.; ZHAO, J.; YANG, G.; LIU, J.; CAO, J.; LI, C.; ZHAO, X.; GAI, J. Establishment of Plot-Yield Prediction Models in Soybean Breeding Programs Using UAV-Based Hyperspectral Remote Sensing. **Remote Sensing**. 11(23):2752, 2019 <https://doi.org/10.3390/rs11232752>
- ZHU, X.; GUO, R.; LIU, T.; XU, K. Crop Yield Prediction Based on Agrometeorological Indexes and Remote Sensing Data. **Remote Sensing**, 13, 2016, 2021. <https://doi.org/10.3390/rs13102016>