

UNIVERSIDADE ESTADUAL PAULISTA - UNESP

CÂMPUS DE JABOTICABAL

**PREDIÇÃO DE PARÂMETROS AGRONÔMICOS PARA COLHEITA
INTELIGENTE DE AMENDOIM: UMA ESTRATÉGIA DIGITAL USANDO
SENSORIAMENTO REMOTO E IA**

Jarlyson Brunno Costa Souza

Engenheiro Agrícola

2025

UNIVERSIDADE ESTADUAL PAULISTA - UNESP

CÂMPUS DE JABOTICABAL

**PREDIÇÃO DE PARÂMETROS AGRONÔMICOS PARA COLHEITA
INTELIGENTE DE AMENDOIM: UMA ESTRATÉGIA DIGITAL USANDO
SENSORIAMENTO REMOTO E IA.**

Jarlyson Brunno Costa Souza

Orientador: Prof. Dr. Rouverson Pereira da Silva

Coorientador: Prof. Dr. Adão Felipe dos Santos

Tese apresentada à Faculdade de Ciências
Agrárias e Veterinárias – Unesp, Câmpus
de Jaboticabal, como parte das exigências
para a obtenção do título de Doutor em
Agronomia (Produção Vegetal).

2025

S729p

Souza, Jarlyson Brunno Costa

Predição de parâmetros agrônômicos para colheita inteligente do amendoim: Uma estratégia digital usando sensoriamento remoto e IA / Jarlyson Brunno Costa Souza. -- Jaboticabal, 2025

161 p. : tabs., mapas

Tese (doutorado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal

Orientador: Rouverson Pereira da Silva

1. Agricultura Digital. 2. Agricultura de precisão. 3. Colheita inteligente. 4. Sensoriamento remoto. 5. Inteligência artificial. I. Título.

PONTENCIAIS IMPACTOS DESTA PESQUISA


A presente tese apresenta contribuições significativas nos âmbitos social, ambiental e econômico, ao propor uma estratégia digital voltada à predição de parâmetros agronômicos na cultura do amendoim. No aspecto **ECONÔMICO**, destaca-se a otimização das operações de colheita por meio da previsão antecipada da produtividade e da maturação fisiológica, permitindo melhor planejamento logístico e redução das perdas associadas à colheita em estágios inadequados. A diminuição dos custos operacionais, aliada ao uso de ferramentas de sensoriamento remoto e inteligência artificial, favorece a elevação da rentabilidade e agrega valor à cadeia produtiva, sobretudo pelo fortalecimento da rastreabilidade e da tomada de decisão baseada em dados. No contexto **AMBIENTAL**, temos a diminuição do uso de métodos invasivos: Técnicas digitais substituem práticas tradicionais (como o método Hull-Scrape), evitando o manuseio constante do solo e da planta, contribuindo para a preservação da estrutura do solo e da microbiota local. A abordagem adotada neste estudo permite o monitoramento contínuo e não destrutivo das lavouras, minimizando intervenções físicas e promovendo maior sustentabilidade na condução da cultura. No aspecto **SOCIAL**, destaca-se a democratização do acesso a tecnologias digitais, por meio da utilização de imagens gratuitas e modelos baseados em dados reais, o que favorece especialmente pequenos e médios produtores. Ademais, a formação de profissionais capacitados para atuarem com agricultura digital e a adoção de ferramentas tecnológicas no campo contribuem para o desenvolvimento rural e para a segurança alimentar, ao elevar a eficiência produtiva e a qualidade do produto.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: PREDIÇÃO DE PARÂMETROS AGRONÔMICOS PARA COLHEITA INTELIGENTE DE AMENDOIM: UMA ESTRATÉGIA DIGITAL USANDO SENSORIAMENTO REMOTO E IA

AUTOR: JARLYSON BRUNNO COSTA SOUZA
ORIENTADOR: ROVERSON PEREIRA DA SILVA
COORIENTADOR: ADÃO FELIPE DOS SANTOS


Aprovado como parte das exigências para obtenção do Título de Doutor em Agronomia (Produção Vegetal), pela Comissão Examinadora:



Prof. Dr. ROVERSON PEREIRA DA SILVA (Participação Presencial)
Departamento de Engenharia / FCAV UNESP Jaboticabal



Prof. Dr. LUCAS RIOS DO AMARAL (Participação Presencial)
Departamento de Engenharia Agrícola / Universidade Estadual de Campinas (UNICAMP) - Campinas/SP



Prof. Dr. TIAGO RODRIGO FRANCETTO (Participação Presencial)
Departamento de Engenharia Agrícola / Universidade Federal de Santa Maria (UFSM) - Cachoeira do Sul/RS



Prof. Dr. ALAN RODRIGO PANOSSO (Participação Presencial)
Departamento de Ciências Exatas / FCAV UNESP Jaboticabal

Prof. Dr. GLAUCO DE SOUZA ROLIM (Participação Presencial)
Departamento de Ciências Exatas / FCAV UNESP Jaboticabal



Jaboticabal, 25 de abril de 2025

DADOS CURRICULARES DO AUTOR

Jarlyson Brunno Costa Souza, nascido em São Luís, Maranhão, Brasil, em 03 de outubro de 1990, é filho de Waldirene Márcia Alves Costa e José Maria Souza. Coursou do Ensino Fundamental ao Ensino Médio na escola Centro Educacional São Francisco de Assis – CEFTRAN, no município de Paço do Lumiar - MA, Brasil, concluindo o ensino básico e médio em 2008. Ingressou no ensino superior em 2014, no curso de Engenharia Agrícola pela Universidade Federal do Maranhão (UFMA), Campus Chapadinha, obtendo o título de Engenheiro Agrícola em julho de 2019. Durante a graduação, foi bolsista de Iniciação Científica PIBIC na UFMA por um ano, atuando nas áreas de máquinas e mecanização, sob a orientação do professor Dr. Washington da Silva Sousa. Participou de projetos adicionais de pesquisa na área de Pós-Colheita e colaborou na execução e apresentação de trabalhos publicados em congressos e revistas científicas. Fundou, juntamente com o Prof. Dr. Washington da Silva Sousa, o grupo de pesquisa GETAD (Grupo de Estudos em Tecnologia e Agricultura Digital). Concluiu o curso e recebeu o título de Bacharel em Engenharia Agrícola em 2019. Em agosto de 2019, iniciou o curso de Mestrado Acadêmico em Agronomia (Produção Vegetal), com concentração nas áreas de Máquinas Agrícolas e Agricultura Digital, pela Universidade Estadual Paulista (UNESP), na Faculdade de Ciências Agrárias e Veterinárias, em Jaboticabal, São Paulo. Atuou no Laboratório de Máquinas e Mecanização Agrícola, na UNESP, sob a orientação do Prof. Dr. Rouverson Pereira da Silva. Durante o mestrado, realizou pesquisas com ênfase em Agricultura Digital, especialmente sensoriamento remoto aéreo e orbital na cultura do amendoim, em parceria com órgãos públicos e privados. Também participou de pesquisas para avaliar sistemas mecanizados de colheita em soja, amendoim e café. Em julho de 2021, submeteu-se à banca examinadora para obtenção do título de Mestre em Agronomia (Produção Vegetal), sendo aprovado e recebendo o título de Mestre em Agronomia. Em agosto de 2021, iniciou o doutorado, sob orientação do mesmo professor do mestrado. Durante o doutorado, teve a oportunidade de trabalhar com ferramentas de Agricultura Digital em diversos projetos, abrangendo culturas como amendoim, soja, tomate, batata, sorgo, algodão, milho, cana-de-açúcar e forrageiras. Além disso, realizou parte do doutorado na Universidade de Auburn, no estado do Alabama, Estados Unidos, sob a supervisão da Prof. Dra. Brenda Ortiz. Por fim, submeteu esta tese de doutorado para obter, junto ao programa de Produção Vegetal da UNESP, o título de Doutor em Agronomia, com conclusão em 25 de abril de 2025.

**Não cruze os braços diante de uma dificuldade,
pois o maior homem do mundo
morreu de braços abertos.**
(Bob Marley)

Aos meus pais José Maria Souza e Waldirene Márcia Alves Costa, às minhas avós Irene Alves da Costa e Raimunda Pereira de Souza (em memória), à minha noiva Samira Luns Hatum de Almeida, à minha filha Ana Sofia Cutrim Souza e às minhas irmãs Jarlyanne Nargylla Costa Souza, Wanessa Helena Costa Barbosa.

A vocês, DEDICO!

A todos os meus familiares e amigos, OFEREÇO!

AGRADECIMENTOS

Em primeiro lugar agradeço a Deus por não desistir de mim e me transformar em uma pessoa melhor a cada dia. Agradeço a Ele pela minha família poder presenciar o meu crescimento como pessoa e como profissional, e por ele colocar pessoas maravilhosas na minha vida.

Aos meus pais Waldirene Márcia Alves Costa e José Maria Souza que nunca deixaram de acreditar no meu potencial e que fizeram o possível e o impossível para que eu chegasse até aqui. Eu peço a Deus que eu tenha sempre a coragem e essa mesma dedicação para criar meus filhos, obrigado pai e mãe, vocês são os principais responsáveis por essa vitória. À minha avó Irene Alves da Costa, que em momentos difíceis sempre me estendeu a mão e à nossa família, sendo o nosso pilar em vários sentidos. Agradeço à minha irmã Jarlyanne Nargylla Costa Souza por toda parceria e brigas, e no final de tudo a gente sempre se defende e se ajuda. À minha amada filha Ana Sofia Cutrim Souza, que é o grande amor da minha vida e que sem a vinda dela a este mundo eu nunca teria me tornado a pessoa que eu sou hoje; você mudou a minha vida filha, e eu espero um dia conseguir retribuir toda ausência e a distância desses longos anos estudando, em que você sempre foi meu alicerce. À minha futura esposa, Samira Luns Hatum de Almeida, que é a minha parceira de vida, minha maior inspiração como pessoa e principalmente como profissional. Agradeço a Deus todos os dias por colocar em minha vida uma mulher tão guerreira e parceira. Eu te amo, casa comigo?!

Aos meus amigos e mentores da graduação Prof. Dr. Edmilson Igor Bernardo de Almeida e o Prof. Dr. Washington da Silva Sousa que nem mesmo a distância foi capaz de separar. Agradeço por Deus por nossos caminhos se cruzarem, vocês são minhas inspirações e hoje, amigos de profissão, lutando juntos as mesmas lutas. A nossa irmandade permanecerá intacta para todo o sempre meus irmãos.

À Universidade Federal do Maranhão, “Centro de Ciências Agrárias e Ambientais” Campus de Chapadinha, que me formou como profissional, que me fez Engenheiro Agrícola e a todos os professores que de alguma forma contribuíram para que eu chegasse até aqui, em especial, Edmilson Igor Almeida, Washigton da Silva, Khalil de Menezes, Telmo Mendes, que além de professores, sempre se mostraram amigos e conselheiros. Agradeço aos amigos da graduação que embarcaram no projeto GETAP, Mádilo Lages, Carlos Augusto e Eduardo Arouche, que sem dúvidas nos despertou para pesquisa nos levando a pós-graduação, obrigado pelo empenho de todos que nos levou ao mestrado. Agradeço a todos os colegas da primeira turma de Engenharia Agrícola da

UFMA, pelas brigas, amizades e parceria; nós sabemos o quão difícil foi essa jornada, porém, obtivemos sucesso e ajudamos o nosso curso a ser o que é hoje. Por fim, mas não menos importante, agradeço ao professor Jocélio dos Santos por ter idealizado e trabalhado duro para abrir o curso de Engenharia Agrícola na UFMA, curso este, que mudou a minha vida e de muitos colegas.

À Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agrárias e Veterinárias, Campus de Jaboticabal, em especial ao Programa de Pós-Graduação em Agronomia (Produção Vegetal) e À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão de bolsa (Código 001) e oportunidade de realizar pesquisa na pós-graduação.

Ao Professor Dr. Rouverson, ao qual eu devo toda minha gratidão. Professor, eu quero aqui agradecer por tudo, pela sua orientação, por mudar a minha vida, por me ensinar a ser uma pessoa melhor, por me tornar o profissional que eu sou hoje. Muitas pessoas passaram pela minha formação, mas nenhuma teve o impacto que você teve. A sua preocupação em não apenas formar profissionais é algo assustador e ao mesmo tempo transformador. Eu tive muita sorte de conviver esses cinco anos ao seu lado, a gente sabe que com altos e baixos, isso é normal falando de Jarlyson, porém, hoje eu saio renovado, e preparado para tentar transmitir tudo que você me ensinou. E do fundo do coração, se eu conseguir impactar as pessoas, metade do que você conseguiu fazer comigo, eu tenho certeza de que já vai ser o suficiente para mudar muitas vidas. Obrigado pela parceria e pela amizade, chefe.

Aos meu coorientador Adão Felipe dos Santos, que eu tenho grande admiração, pela sua história ou simplesmente, pelo jeito Adão de ser. Você é uma pessoa incrível de um coração gigante e que me ensinou quase tudo que eu sei dentro da ciência. Na verdade, você sempre foi a minha principal inspiração e referência como pós-graduando. Agradeço por ainda hoje sermos tão próximos e espero levar sua amizade para sempre.

Aos Professores. Dr. Carlos Eduardo Angeli Furlani, Dr. Cristiano Zerbato, Dr. Afonso Lopes e aos técnicos David Trevizoli e Maranhão, obrigado por toda ajuda, conhecimento e experiências trocadas, e a todos os outros funcionários do Departamento de Engenharia. Gostaria de agradecer à Dra. Brenda Ortiz pela oportunidade de fazer o doutorado sanduiche nos Estados Unidos, e por todo conhecimento adquirido nos seis meses que lá estive. Além disso, gostaria de expressar minha gratidão a todas da equipe do Laboratório de Agricultura de Precisão da Auburn University, que me ajudaram na

adaptação e com os trabalhos em campo: Pablo Duarte, Marina de Val, Lucas Ramon, Megan Thurmond, Mailson Oliveira.

A toda família da República TOca Fogo, Edgard Silva, Mailson Oliveira, João Godinho, Luan Oliveira, Everton Carvalho, Armando Lopes, Eduardo Arouche, Francisco Amaral, Jardel Souza, Ancelmo Cazuzza e a Neuza Helena, por toda a parceria, pelas festas e brincadeiras sadias. Sem vocês os meus dias longe de casa e da minha família seriam mais difíceis.

Aos meus amigos e parceiros do Laboratório de Máquinas e Mecanização Agrícola, Alex Gonzaga, Luan Pereira, Joao Godinho, Aline Alcântara, Bruno Rocca, Danilo Tedesco, Francieli Ferreira, Francieli Morlin, Jean Lucas, Mailson Oliveira, Marcelo Junior, Romário Porto, Danilo Tedesco, Tulio Marra, Paulo Cardoso, Thiago Oliveira, Erika Sales, Airtton Andrade, Igor Cristian, Lucas Zonfrilli, Luis Alberto, Breno Santos, Priscila Martins, Rosemary Gay, Pedro, Vinicius Carreira, Olavo Betiol, Edcarla Nicolau, e, principalmente, Armando Lopes e Samira Almeida que estiveram comigo desde o mestrado em todos os desafios em contribuição mutua: obrigado pela parceria! Por fim, agradecer todos os estagiários que passaram nesses cinco anos de LAMMA, e dizer que sem vocês eu não estaria defendendo uma tese de doutorado. Obrigado pela dedicação e empenho de todos os estagiários do nosso laboratório que sem sombra de dúvidas, são os melhores.

Ao Mailson Oliveira por todo conhecimento repassado e pela irmandade tanto no Brasil quanto nos Estados Unidos, onde sem ele minha experiencia internacional teria sido bem mais difícil. Aos demais amigos da Fraternity, Lucas Ramon e Murilo Morata pelos churrascos, risadas e as noites incríveis no fat daddy's em Auburn, obrigado pela amizade meus irmãos. Aos meus amigos de infância, Francisco Inaldo, Anderson Soares, Rafael Ribeiro, Gustavo Mendes, Nando Trindade e Thiago Santos, que estão sempre felizes com os objetivos alcançados e sempre torcendo por mim de longe e mandando mensagens de incentivo.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Agradeço o apoio no trabalho também ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) número do processo 165677/2021-0.

Enfim, a todos que de alguma forma contribuíram para que eu chegasse até aqui, e que sempre estiveram ao meu lado em momentos tristes e felizes, o meu muito obrigado!

SUMÁRIO

LISTA DE ABREVIACÕES	12
LISTA DE TABELAS.....	16
LISTA DE FIGURAS.....	17
CAPÍTULO 1: CONSIDERAÇÕES INICIAIS.....	19
CAPÍTULO 2: SENSORIAMENTO REMOTO E INTELIGÊNCIA ARTIFICIAL: UMA REVISÃO ABRANGENTE PARA O MONITORAMENTO DA CULTURA DO AMENDOIM	22
2. Panorama das Tecnologias Digitais no Manejo do Amendoim: O Papel do SR e da IA	23
2.1 Métodos da revisão sistemática.	26
2.2 Estratégia de Pesquisa.....	26
2.3. Critério de Elegibilidade.....	27
2.4. Extração de dados.....	27
3. Análise das Descobertas de Pesquisa.....	29
3.1. Evolução, Impacto e Eficiência.....	29
3.2. Formas de Divulgação Científica.....	31
3.3. Tendências dos Alvos de Estudo.....	33
3.4. Síntese dos Principais Estudos de SR e IA na Cultura do Amendoim (2014-2024)	35
3.5. Agricultura digital em foco no amendoim: Avanços e Desafios.....	43
4. Sensoriamento Remoto.....	44
4.1. Tipos de Sensores e Plataformas Utilizadas.....	45
4.2. Índices de Vegetação Aplicados.....	48
4.3 Tecnologias Associadas ao SR.....	50
5. Inteligência Artificial.....	51
5.1. Aplicações de Machine Learning e Deep Learning na Agricultura do Amendoim.....	52
5.2. Algoritmos Utilizados na Cultura do Amendoim.....	53
5.3. Pré-processamento e Qualidade dos Dados para Modelos de IA.....	54

5.4. Desempenho dos Modelos.....	55
6. Limitações e Desafios	57
7. Perspectivas Futuras e Inovações.....	58
8. Considerações Finais e Recomendações Para o Avanço do Sensoriamento Remoto e IA no Manejo da Cultura do Amendoim.....	59
9. Referência.....	60
CAPÍTULO 3: GENERALIZAÇÃO DE MODELOS DE PREDIÇÃO DA PRODUTIVIDADE DO AMENDOIM USANDO REDES NEURAIS ARTIFICIAIS E ÍNDICES DE VEGETAÇÃO.....	68
1.Introdução.....	69
2. Material e Métodos.....	71
2.1. Area Experimental e Aquisição de Dados de Campo.....	71
2.2. Aquisição de Imagem de Satélite.....	74
2.3 Análise de Dados.....	75
3. Resultados.....	77
3.1. Análise Exploratória dos Dados de Produtividade.....	77
3.2. Validação dos Modelos de Predição	79
3.3. Variáveis de Importância da Validação dos Modelos.....	83
3.4. Generalização dos Modelos de Predição.....	84
3.5. Recalibração dos Modelos de Predição.....	87
3.6. Variáveis de Importância dos Modelos de Recalibração.....	90
4. Discussão.....	91
4.1. Influência do Solo e de Cultivares na Predição da Produtividade.....	91
4.2. Influência dos Índices de Vegetação nos Modelos de Predição.....	92
4.3. Efetividade dos Modelos de RNA na Predição da Produtividade Agrícola.....	93
4.4. Generalização, Aplicabilidade dos Modelos de Predição.....	94
4.5. Impacto da Recalibração dos Modelos com Dados Ampliados.....	94
5. Conclusão.....	95
6. Referências.....	96
7. Material Suplementar	99
CAPÍTULO 4: PREDIÇÃO MULTIALVO DA MATURAÇÃO E PRODUTIVIDADE DO AMENDOIM USANDO SENSORIAMENTO REMOTO INTEGRADO A IA PARA O AVANÇO DA COLHEITA INTELIGENTE.....	101
1.Introdução.....	102

2. Material e Métodos.....	104
2.1. Aquisição de Imagem de Satélite.....	108
2.3 Análise de Dados.....	109
3. Resultados.....	111
4. Discussão.....	116
5. Conclusão.....	119
6. Referências.....	119
7. Material Suplementar.....	123
CAPÍTULO 5: INTEGRANDO ZONAS DE MANEJO, REDES NEURAIAS ARTIFICIAIS E SENSORIAMENTO REMOTO PARA A COLHEITA INTELIGENTE DE AMENDOIM.....	124
1.Introdução.....	125
2. Material e Métodos.....	127
2.1 Área de estudo e Delimitação das Zonas de Manejo	127
2.2 Amostragem de Solo Direcionada	127
2.3 Análise da Maturação do Amendoim	128
2.4 Imagens de Satélite e Índices de Vegetação	129
2.5 Análise Estatística	131
2.6 Estimativa de PMI usando RNA	131
3. Resultados.....	132
4. Discussão.....	141
5. Conclusão.....	143
6. Referências.....	144
7. Material Suplementar.....	147
CAPÍTULO 6: CONSIDERAÇÕES FINAIS	151

LISTA DE ABREVIATURAS

PRISMA: Itens Preferenciais para Relatar Revisões Sistemáticas e Metanálises;

ARP: Aeronave Remotamente Pilotada;

IA: Inteligência Artificial;

SR: Sensoriamento Remoto;

IAF: Índice de Área Foliar;

RNAs: Redes Neurais Artificiais;

SAFER: Algoritmo Simples para Recuperação da Evapotranspiração;

PMI: Índice de Maturidade do Amendoim;

AD: Agricultura Digital;

PICO: População, Intervenção, Comparação e Resultado;

IVs: Índices de Vegetação;

NIR: Infravermelho Próximo;

NDVI: Índice de Vegetação por Diferença Normalizada;

OSAVI: Índice de Vegetação Ajustado ao Solo Otimizado;

RDVI: Índice de Vegetação por Diferença Renormalizada;

NPCI: Índice Normalizado de Pigmento e Clorofila;

NDRE: Índice de Diferença Normalizada na Borda Vermelha;

MSR: Razão Simples Modificada;

EVI: Índice de Vegetação Aprimorado;

CIRE: Índice de Clorofila na Borda Vermelha;

DVI: Índice de Vegetação por Diferença;

MSAVI: Índice de Vegetação Ajustado ao Solo Modificado;

TVI: Índice de Vegetação Transformado;

GRVI: Índice de Vegetação por Razão Verde;

SAVI: Índice de Vegetação Ajustado ao Solo;

MCARI: Índice de Absorção de Clorofila Modificado no Espectro de Reflectância;

GNDVI: Índice de Vegetação por Diferença Normalizada Verde;

NLI: Índice Não-Linear;

MNLI: Índice Não-Linear Modificado;

PRI: Índice de Reflectância Fotoquímica;

CI: Índice de Clorofila;

WI: Índice de Água;

MTVI: Índice Triangular de Vegetação Modificado;

VOG1: Índice de Borda Vermelha de Vogelmann;

SIPI: Índice de Pigmento Insensível à Estrutura;

PSRI: Índice de Reflectância para Senescência Vegetal;

SR: Razão Simples;

ARI: Índice de Reflectância para Antocianina;

TCARI: Índice de Absorção de Clorofila Transformado no Espectro de Reflectância;

ML: Aprendizado de Máquina;

DL: Aprendizado Profundo;

CNN: Redes Neurais Convolucionais;

AP: Agricultura de Precisão;

MLP: Perceptron Multicamadas;

MTR: Regressão Multialvo;

RBF: Função de Base Radial;

LRM: Regressão Linear Múltipla;

LR: Regressão Linear;

SVM: Máquina de Vetores de Suporte;

KNN: K- Vizinhos Mais Próximos;

PCA: Análise de Componentes Principais;

AR: Aritmética ReliefF;

MF: Filtragem Mediana; Kappa: Coeficiente Kappa de Cohen;

RMSE: Erro Quadrático Médio;

MAE: Erro Médio Absoluto;

MAPE: Erro Percentual Absoluto Médio;

IoT: Internet das Coisas.

GNSS: Sistema Global de Navegação de Satélite;

GPS: Global positioning System;

GLONASS: Global'naya Navigatsionnaya Sputnikovaya Sistema;

BeiDou: Beidou Navigation Satellite System;

DPC: Dias para Colheita;

PS: PlanetScope;

TOA: Refletância no topo da atmosfera;

BOA: Refletância de Fundo da Atmosfera;

IPS: Intelligent Problem Solver;

REM: Run Existing Model;

IQRs Interquartis;

LISTA DE TABELAS

Tabela 2.1. Componentes específicos para este estudo em função do PICO.....	26
Tabela 2.2. Principais aspectos das pesquisas em sensoriamento remoto para aplicações na cultura do amendoim.....	39
Tabela 2.3. Principais aspectos das pesquisas em inteligência artificial para aplicações na cultura do amendoim.....	40
Tabela 3.1. Informações sobre as áreas de estudo para as duas Safras.....	71
Tabela 3.2. Índices de vegetação utilizados como entrada nos modelos preditivos.....	75
Tabela 3.3. Análise de sensibilidade para determinação de variáveis importantes.....	84
Tabela 3.4. Análise de sensibilidade para determinação de variáveis importantes.....	91
Tabela 4.1. Informações sobre as áreas de estudo para as duas Safras.....	105
Tabela 4.2. Índices de vegetação utilizados como entrada nos modelos preditivos.....	108
Tabela 5.1. Índices de Vegetação utilizados como entrada nos modelos de estimativa	130
Tabela 5.2. Análise de textura de solo para 20 cm profundidade.....	148
Tabela 5.3. Análise de textura de solo para 40 cm profundidade.....	149
Tabela 5.4. Métricas de Avaliação dos Modelos.....	149
Tabela 5.5. Configuração dos algoritmos RBF e MLP.....	150
Tabela 5.6. Análise de Sensibilidade das Variáveis de Entrada.....	150

LISTA DE FIGURAS

Figura 2.1. Evolução da produção e da área colhida do amendoim entre 1994 e 2022 (A) e distribuição geográfica da produção global (B) Fonte FAO.....	23
Figura 2.2. Fluxograma do processo de identificação, triagem, elegibilidade e inclusão de estudos de revisão sistemática. Fonte Autores (2025)	27
Figura 2.3. Fluxo de aplicação do sensoriamento remoto e inteligência artificial no cultivo do amendoim, utilizando diferentes plataformas, sensores e algoritmos para análise e classificação de variáveis agrônômica. Fonte Autores (2025).	28
Figura 2.4. Distribuição global (A) e evolução temporal (B) das publicações sobre sensoriamento remoto e inteligência artificial no cultivo do amendoim. Fonte Autores (2025)	30
Figura 2.5. Redes de coautoria em pesquisas sobre a interação de sensoriamento remoto e inteligência artificial no cultivo do amendoim (A) principais autores e colaborações ao longo do tempo (B) estrutura das conexões entre pesquisadores, destacando autores centrais na disseminação do conhecimento na área. Fonte Autores (2025).	31
Figura 2.6. Distribuição dos artigos utilizados na revisão sistemática de acordo com a frequência de publicações e o fato de impacto dos periódicos. Fonte Autores (2025)	33
Figura 2.7. Evolução dos temas de pesquisa sobre sensoriamento remoto e inteligência artificial aplicados ao cultivo do amendoim entre 2020 e 2024. Fonte Autores (2025)	35
Figura 2.8. Gráfico de Sankey representando a conexão entre plataformas, sensores. Aplicações e algoritmos no monitoramento da cultura do amendoim. Fonte Autores (2025)	43
Figura 2.9. Comparação entre sensores RGB, multiespectral e hiperespectral em relação à reflectância e ao comprimento de onda capturado. Fonte Shiratsuhi (2023)	46
Figura 3.1. Localização das áreas experimentais para a safra 2020/2021 e 2021/2022 ...	73
Figura 3.2. Esquema representativo da metodologia	74
Figura 3.3 Análise exploratória da produtividade de amendoim nas safras 20/21 (A) e 21/22 (B)	79

Figura 3.4. Calibração dos modelos preditivos da produtividade do amendoim com dados da safra 2020/21	81
Figura 3.5. Validação dos modelos desenvolvidos na safra 2020/2021. Em “azul” são os erros dos modelos desenvolvidos na calibração e em “vermelho” os erros da validação em áreas da safra 2021/2022	86
Figura 3.6. Recalibração e ampliação de dados para o modelo de predição da produtividade do amendoim utilizando dados das duas safras (2020/2021 e 2021/2022).	88
Figura 4.1. Localização das áreas experimentais para a safra 2020/2021 e 2021/2022	106
Figure 4.2. Esquema representativo da metodologia aplicada	107
Figura 4.3. Diagrama de Sankey para a combinação de algoritmos e recursos KNN e RF para predição da produtividade e maturação do amendoim	110
Figure 4.4. Boxplot da produtividade e do PMI observado e predito na fase de teste dos modelos para o RF e KNN	112
Figura 4.5. Análise de resíduos para os algoritmos RF e KNN para análise de subestimação e superestimação do PMI e produtividade do amendoim	113
Figura 4.6. Gráfico de radar para análise de desempenho dos modelos em função do Erro Médio Absoluto (MAE) para as variáveis dependentes (Produtividade e PMI)	116
Figura 4.7. Gráfico de boxplot para análise do comportamento dos dados adquiridos em campo para Produtividade e PMI	123
Figure 5.1. Mapa de localização dos pontos e da área de estudo	128
Figura 5.2. Esquema representativo da metodologia apresentada	132
Figure 5.3. Comportamento dos dados de maturação por boxplot (a) e desenvolvimento da maturação ao longo do tempo em área total (b)	133
Figure 5.4. Comportamento dos dados de maturação por boxplo (a) e desenvolvimento da maturação ao longo do tempo dentro de cada zona de manejo (b)	135
Figure 5.5. Correlação (a) e Análise de Componentes Principais (b) para validação das zonas de manejos geradas	137
Figure 5.6. Evolução da média da maturação ao longo do tempo (97 a 139 DAS) (a) e mapas do momento ótimo de colheita para 7 e 1 dias antes da colheita (b)	138
Figure 5.7. Gráficos de desempenho dos modelos de estimativa da maturação com RBF (a) e MLP (b)	139
Figure 5.8. Mapas de colheita e resíduos interpolados por IDW do PMI para dados observados, MLP e RBF para 7 (a) e 1 (b) dias antes da colheita (DBH)	141

Figura 5.9. Mapas interpolados por krigagem de condutividade elétrica do solo e solo exposto	147
--	------------

CAPÍTULO 1: CONSIDERAÇÕES GERAIS

Esta Tese explora o uso integrado de sensoriamento remoto (SR) e inteligência artificial (IA) para a determinação de parâmetros de colheita na cultura do amendoim. Em um cenário no qual a otimização das decisões de manejo é essencial para a realização de uma colheita inteligente, esta pesquisa procura eliminar um obstáculo significativo ao oferecer informações valiosas para operações de colheita de amendoim, viabilizadas por ferramentas digitais. A cultura do amendoim, de grande importância socioeconômica e nutricional, exige tecnologias avançadas que potencializem sua produtividade e qualidade do produto.

Ao adotar uma abordagem científica para o monitoramento de parâmetros agronômicos, como maturação e produtividade, este estudo demonstra como o uso de tecnologias digitais pode transformar o cultivo do amendoim. SR e IA não apenas oferecem precisão, mas também permitem uma análise detalhada e escalável, contribuindo para uma tomada de decisão fundamentada e adaptada às condições específicas de cada lavoura. Este estudo, portanto, se posiciona na fronteira do conhecimento para maximizar os benefícios da ciência e tecnologia no campo para a cultura do amendoim, promovendo um cultivo mais eficiente, sustentável e alinhado às exigências do mercado global. Esta tese se inicia com este capítulo, no qual apresentamos a seguir, a estrutura do seu desenvolvimento.

No **Capítulo 2** apresentamos uma revisão sistemática abrangente sobre o uso de tecnologias da Agricultura Digital para o monitoramento de parâmetros agronômicos na cultura do amendoim. Este estudo sistemático abrange 40 artigos publicados entre 2020 e 2024 que integram o uso de Sensoriamento Remoto com Machine Learning e/ou Deep Learning. O principal objetivo deste capítulo é avaliar o impacto da aplicação conjunta dessas ferramentas na pesquisa, voltada para otimizar o manejo agrícola e solucionar problemas críticos da cultura. A partir de uma análise detalhada da metodologia e dos resultados apresentados nos estudos selecionados, buscamos oferecer novos insights que contribuam para elevar a produtividade e fomentar o desenvolvimento do amendoim. Este levantamento sistemático fornece uma base sólida de evidências e práticas que destacam o papel central das tecnologias digitais no aprimoramento do manejo agrônomo, oferecendo uma visão inovadora e atualizada para a expansão e sustentabilidade do cultivo de amendoim. Este capítulo foi submetido como artigo para avaliação na revista *Agronomy Journal* (IF: 2.0; CiteScore: 4.7).

No **Capítulo 3** descrevemos um estudo direcionado à predição da produtividade do amendoim, com até 30 dias de antecedência à colheita, em 11 áreas comerciais, utilizando dados de satélite e índices de vegetação como variáveis independentes. Neste trabalho, foram desenvolvidos modelos de predição em cinco momentos distintos anteriores à colheita, permitindo uma análise detalhada da evolução da acurácia preditiva ao longo do ciclo da cultura. Em seguida, o modelo foi testado em áreas não incluídas inicialmente, para avaliar sua capacidade de generalização e a precisão em prever produtividade em regiões desconhecidas, um aspecto essencial para aplicação prática e escalabilidade dos modelos em novas áreas de cultivo. Além disso, o modelo foi recalibrado com dados adicionais, abrangendo novas cultivares e manejos distintos, para investigar se a precisão aumentava e o erro diminuía com a inclusão de novos dados. Esse processo de recalibração permitiu uma avaliação sobre a robustez e a adaptabilidade do modelo em condições variáveis. Este capítulo foi aceito como artigo para publicação na revista *Smart Agricultural Technology* (IF: 6,3; CiteScore: 4.2).

No **Capítulo 4** exploramos o uso de regressão multialvo empregando os algoritmos K-Nearest Neighbors e Random Forest para prever, com até 30 dias, a maturação e a produtividade da cultura do amendoim, simultaneamente. Utilizando dados de satélite e índices de vegetação como variáveis preditoras, este estudo demonstrou potencial para otimizar a previsão dos parâmetros de colheita, oferecendo uma ferramenta de apoio à tomada de decisão para produtores, promovendo uma colheita inteligente. Para a geração do banco de dados, foram utilizadas 11 áreas comerciais, permitindo uma modelagem mais robusta e representativa das condições reais de cultivo. No trabalho também investigamos o desempenho dos algoritmos KNN e RF em capturar e identificar a variabilidade do campo, essencial para um monitoramento preciso e ajustado às particularidades de cada área. Este capítulo foi submetido como artigo para avaliação na revista *Computers and Electronics in Agriculture* (IF: 7.7; CiteScore: 15.3).

Já no **Capítulo 5**, abordamos a colheita inteligente do amendoim em área com alta variabilidade espacial. O estudo, conduzido nos Estados Unidos, analisou a variabilidade do solo a partir de dados de condutividade elétrica e imagens de solo exposto, adquiridas por satélites de alta resolução. Com base nesses dados, foi realizada uma análise temporal da dinâmica e do comportamento da maturação, revelando padrões distintos dentro de cada zona de manejo previamente definida. A partir dessa segmentação, avaliou-se a capacidade dos algoritmos de aprendizado de máquina (MLP e RBF) para estimar essa variabilidade, analisando sua precisão e acurácia na estimativa da maturação do

amendoim. Por fim, foram gerados mapas interpolados para indicar, dentro do talhão, as áreas prontas para colheita com antecedência de 7 e 1 dias, permitindo a tomada de decisão mais precisa para o momento ótimo de colheita. Os resultados destacam a alta eficiência da integração entre técnicas de agricultura de precisão e agricultura digital no monitoramento da variabilidade espacial do amendoim, demonstrando o potencial dessas abordagens para otimizar o processo de colheita.

No **Capítulo 6**, apresentamos uma discussão sobre as direções futuras para pesquisas, destacando áreas nas quais aprimoramentos e explorações adicionais poderão beneficiar o desenvolvimento contínuo do conhecimento sobre o uso de tecnologias digitais no manejo do amendoim. Com base nas abordagens e nos resultados alcançados nos capítulos anteriores — que incluem predições estimativa de produtividade e maturação, respectivamente, utilizando dados de sensoriamento remoto, machine learning e regressão multialvo — examinamos neste capítulo como os achados podem servir de base para futuras investigações, ampliando as possibilidades de aplicação de tecnologias digitais na cultura do amendoim.

CAPÍTULO 2 – SENSORIAMENTO REMOTO E INTELIGÊNCIA ARTIFICIAL: UMA REVISÃO ABRANGENTE SOBRE O MONITORAMENTO DA CULTURA DO AMENDOIM¹

Resumo: O cultivo do amendoim tem se expandido globalmente, impulsionado por avanços tecnológicos que buscam aumentar a produtividade e melhorar a sustentabilidade. Sensoriamento remoto (SR) e inteligência artificial (IA) têm sido amplamente empregados para o monitoramento da cultura, permitindo análises precisas e tomadas de decisão baseadas em dados. No entanto, a falta de padronização nos métodos e a necessidade de bases de dados mais robustas representam desafios para a aplicação eficiente dessas tecnologias. Esta revisão sintetiza o estado da arte do uso de SR e IA no monitoramento do amendoim, identificando principais abordagens, algoritmos, sensores e lacunas na pesquisa. Foi realizada uma revisão sistemática (2020-2024) baseada no protocolo PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses). A busca incluiu artigos científicos indexados em Scopus e Web of Science, considerando critérios de elegibilidade e exclusão, resultando na análise de 40 estudos sobre SR e IA aplicados ao amendoim. Os estudos demonstram a predominância de sensores multiespectrais e hiperespectrais, com plataformas proximais sendo as mais utilizadas. Algoritmos de aprendizado de máquina, como Random Forest e SVM, são comuns, mas redes neurais profundas apresentam maior precisão na detecção de doenças. Apenas 37,5% dos artigos reportaram hiperparâmetros detalhados, e a maioria utilizou bases de dados pequenas, limitando a generalização dos modelos. Conclui-se que, para ampliar a eficiência dessas tecnologias, são necessárias maior padronização, bases de dados robustas e validação externa dos modelos.

Palavras-chaves Agricultura Digital, Machine Learning, Deep Learning, Sensoriamento, Sensores.

¹ Capítulo foi submetido como artigo para avaliação na revista Agronomy Journal (IF: 2.0; CiteScore: 4.7).

1. Panorama das Tecnologias Digitais no Manejo do Amendoim: O Papel do SR e da IA.

Nos últimos anos, o amendoim tem se destacado como uma das culturas agrícolas com potencial para produção em larga escala, sendo cultivado em diversas regiões e países ao redor do mundo. A produção de amendoim e a área destinada ao seu cultivo apresentaram um crescimento expressivo ao longo dos últimos 28 anos, de 1994 a 2022, como mostrado na Figura 2.1A. A Ásia dominou essa expansão com 63,2% da produção, seguida pela África, com uma participação de 28%, enquanto as Américas representaram 8,7%, conforme mostrado na Figura 2.1B. O desenvolvimento tecnológico é fundamental para manter os níveis de produção frente às condições ambientais adversas, bem como ao crescimento da população global. Atualmente, técnicas integradas de Sensoriamento Remoto (SR) e Inteligência Artificial (IA) tornaram-se ferramentas poderosas para a avaliação de produtividade agrícola, área de cultivo e medidas de sustentabilidade. As descobertas mais recentes sobre o amendoim têm contribuído para avanços na gestão e no monitoramento agrícola, utilizando SR e IA.




Figura 2.1. Evolução da produção e da área colhida de amendoim entre 1994 e 2022 (A) e distribuição geográfica da produção global (B).

Fonte: Autores (2025).

Estudos demonstram que o uso de dados espectrais e texturais baseados em Aeronaves Remotamente Pilotadas (ARPs) proporciona um método não invasivo para estimar o Índice de Área Foliar (IAF), permitindo o monitoramento eficiente do crescimento e do vigor da cultura do amendoim em diferentes estádios (Qiao et al., 2024; Sarkar et al., 2021; e Qi et al., 2020). Modelos de regressão multialvo aumentam ainda

mais a acurácia na agricultura, ao prever tanto a biomassa da parte aérea como a biomassa radicular (Oliveira et al., 2024). Algoritmos de aprendizado de máquina, como Random Forest e XGBoost, têm sido aplicados para prever a produtividade do amendoim (Pugh et al., 2024). Além disso, inovações como sistemas baseados em visão computacional e o uso de sensor radar otimizaram o cultivo de amendoim por meio de processos automatizados, como a contagem de plântulas e o monitoramento de produtividade (Puhl, 2023). O principal desafio é a determinação do momento ideal de colheita, que tradicionalmente depende de métodos subjetivos, como o teste Hull-Scrape, no qual a camada externa das cascas do amendoim é removida manualmente para avaliar visualmente a maturidade.

O teste Hull-Scrape, embora amplamente utilizado, muitas vezes depende da análise individual, o que leva a variações e potenciais imprecisões na estimativa da maturação das vagens de amendoim. Pesquisas recentes buscam melhorar a acurácia e a objetividade das avaliações da maturação do amendoim usando tecnologias. Redes Neurais Artificiais (RNAs) integradas às geotecnologias do SR, como imagens orbitais ou aéreas, têm demonstrado potencial para prever a maturação das vagens e aprimorar as estimativas de colheita (Souza et al., 2022; Santos et al., 2021). O modelo SAFER (Simple Algorithm for Evapotranspiration Retrieving) integra dados climáticos e espectrais, fornecendo previsões precisas do Índice de Maturidade do Amendoim (PMI), com forte correlação com avaliações tradicionais de campo e uma redução significativa na subjetividade, oferecendo uma alternativa confiável (Almeida et al., 2023). Outro problema no cultivo de amendoim que merece atenção é a contaminação por aflatoxinas nas vagens, que representa um risco significativo para a segurança alimentar e a qualidade do produto.

As aflatoxinas, produzidas por certos fungos como o *Aspergillus flavus*, são altamente tóxicas e podem causar sérios problemas de saúde se consumidas. Detectar a contaminação por aflatoxinas é um desafio devido à sua distribuição não uniforme no campo e às limitações dos métodos tradicionais de teste, que podem ser invasivos, demorados e inconsistentes. Com o objetivo de resolver esse problema, alguns estudos estão desenvolvendo métodos avançados de detecção que podem melhorar a precisão e a eficiência. Modelos em nível de pixel utilizando redes convolucionais alcançaram 94% de precisão na detecção de aflatoxinas (Wang et al., 2024). O uso de sensores com resoluções hiperespectrais e multiespectrais, respectivamente, tem se mostrado eficaz na detecção precisa de contaminações fúngicas, obtendo acurácias diagnósticas de até 100%

(Guo et al., 2024; Sudki et al., 2023). Lavrinenko et al. (2022) utilizaram espectroscopia luminosa para a rápida detecção de fungos, enquanto Manhando et al. (2021) exploraram a tomografia de coerência óptica para a identificação precoce de mofo. Garantir sementes de amendoim de alta qualidade também é crucial para melhorar a produtividade agrícola e a segurança alimentar, como demonstram estudos recentes. O uso de imagens proximais em terahertz com aprendizado de máquina e a espectroscopia visível-infravermelho próximo, combinada com algoritmos de otimização, foi desenvolvido para avaliar de forma não destrutiva a qualidade das sementes, incluindo o teor de proteína (Jiang et al., 2024; Rajabi-Sarkhani et al., 2023; Zhou et al., 2022).

Por fim, as doenças nas plantas de amendoim também afetam o vigor e o potencial produtivo do cultivo agrícola, exigindo monitoramento preciso e detecção precoce. Estudos recentes destacam a eficácia do uso de SR e aprendizado de máquina para enfrentar esses desafios. O SR aéreo por meio das ARPs e dados hiperespectrais permitem o mapeamento preciso e a avaliação da gravidade de doenças como a murcha meridional (*Fusarium oxysporum* f. sp. *Vasinfestum*), alcançando mais de 90% de precisão (Guo et al., 2024; Guo et al., 2023). Modelos de aprendizado de máquina, e dados hiperespectrais, também têm sido fundamentais para a identificação e o monitoramento precoce de doenças (Lin et al., 2024; Wei et al., 2021; Guan et al., 2022).

Neste artigo, conduzimos uma revisão sistemática sobre o uso integrado de SR e IA no manejo da cultura do amendoim, analisando como essas tecnologias vêm revolucionando o campo. Ao reunir estudos que empregam ferramentas poderosas dessas técnicas de Agricultura Digital (AD), focamos nas aplicações práticas para superar desafios centrais, como por exemplo a identificação precoce de doenças, a estimativa precisa da maturação das vagens, avaliação da qualidade das vagens e das sementes, entre outros objetivos de estudo. Buscamos esclarecer o impacto de soluções tecnológicas para o amendoim, enfatizando tanto os benefícios quanto as limitações, e demonstrando como essas inovações se traduzem em avanços sustentáveis e seguros na produção. Este levantamento serve como um ponto de partida para futuras investigações e desenvolvimentos, incentivando a implementação mais ampla de práticas aprimoradas que garantam o sucesso da cultura do amendoim em face das crescentes demandas e desafios agrícolas globais.

A integração de tecnologias está ajudando a aumentar a produtividade, juntamente com processos mais sustentáveis e controlados em termos de qualidade. A evolução contínua dessas inovações pode adaptar ainda mais as ferramentas de produção do

amendoim para aumentar os rendimentos e minimizar os riscos na produção, permitindo um manejo mais específico da saúde da cultura. Pesquisas adicionais nessa área devem levar a soluções melhores e mais rápidas para os problemas enfrentados pelos produtores de amendoim em todo o mundo.

2. Métodos da revisão sistemática

2.1. Critérios para Seleção da Literatura na Revisão

Foi realizada uma revisão sistemática da literatura existente com o objetivo de investigar as aplicações do SR integrado a ferramentas de IA no monitoramento da cultura do amendoim, visando responder à questão de pesquisa formulada segundo o protocolo PICO (População, Intervenção, Comparação e Outcome – resultado) (Tabela 2.1) (Murad, 2016). Qual o impacto do uso de técnicas de SR e IA no monitoramento da cultura do amendoim? Para a seleção dos estudos, foram seguidas as diretrizes de revisão sistemática do Itens Preferenciais para Relatar Revisões Sistemáticas e Metanálises (PRISMA) (Figura 1) (Page et al., 2021).

Tabela 2.1. Protocolo PICO - Componentes específicos para este estudo.

Elemento	Descrição
Problema	Falta de métodos eficientes para o monitoramento da cultura do amendoim
Intervenção	Aplicação de ferramentas de AD para o monitoramento agrônômico do amendoim
Comparação	Abordagens convencionais ou monitoramento digital
Resultado	Impacto na precisão e detecção de parâmetros da cultura com o uso eficiente das tecnologias digitais.

Fonte: Autores (2025).

2.2. Estratégia de Busca

Nosso estudo buscou sintetizar e classificar a literatura sobre a aplicação de ferramentas de Agricultura Digital na cultura do amendoim. Para tanto, foram selecionados 40 estudos acadêmicos relevantes através de uma busca realizada nas principais bases de dados, especificamente Scopus (<https://www.scopus.com>) e Web of Science (www.webofscience.com). A fim de assegurar a inclusão de trabalhos pertinentes ao tema, utilizamos operadores booleanos na seguinte formulação: ("peanut") AND

("remote sensing" OR "machine learning"). Essa estratégia foi adotada para garantir uma compilação abrangente de artigos que abordam a integração entre SR e AI na cultura do amendoim, conforme fluxograma abaixo (Figura 2.2).




Figura 2.2. Fluxograma do processo de identificação, triagem, elegibilidade e inclusão de estudos na revisão sistemática.

Fonte: Autores (2025).

2.3. Critérios de Elegibilidade

A pesquisa na literatura abrangeu os últimos 10 anos (2014-2024), porém foi encontrado artigos com essa temática apenas nos últimos 5 anos e foi conduzida com base nos critérios definidos pelos autores, visando garantir a consistência, robustez e elegibilidade dos artigos selecionados. O escopo da revisão foi rigorosamente seguido, priorizando estudos que incorporassem tanto SR quanto IA. O processo incluiu a exclusão de duplicatas e artigos não pertinentes. Além disso, apenas artigos científicos foram considerados, excluindo-se revisões, e a busca foi realizada exclusivamente em bases de dados reconhecidas. Uma análise minuciosa de todos os artigos foi realizada, abrangendo títulos, destaques, resumos, palavras-chave e metodologias.

2.4. Extração dos Dados

Os critérios de inclusão estabelecidos exigiram que os estudos avaliassem a aplicação de técnicas combinadas de SR e IA no monitoramento de aspectos inerentes à cultura do amendoim. Dentro do escopo de SR, foram considerados todos os níveis de coleta e tipos de sensores. Para os métodos de IA, a seleção foi restrita a estudos que utilizassem RNAs (redes neurais artificiais), aprendizado de máquina (ML - machine learning) e aprendizado profundo (DL - deep learning). O foco da revisão concentrou-se em estudos que abordaram os seguintes parâmetros: doenças, pragas, qualidade das sementes, produtividade, melhoramento genético, maturação das vagens, biomassa e pós-colheita (Figura 2.3).

Durante a fase de triagem para a composição do banco de dados, que incluiu a análise de títulos, resumos e métodos, os artigos foram excluídos com base nos seguintes critérios: a) estudos não relacionados ao tema; b) estudos que envolviam mais de uma cultura; c) estudos que não havia SR e/ou IA; d) trabalhos não revisados por pares, como capítulos de livros, trabalhos apresentados em conferências e relatórios técnicos; e e) publicações em idiomas diferentes do inglês. Essa abordagem pode ser visualmente compreendida na Figura 2.3, que apresenta o fluxo de aplicação do Sensoriamento Remoto e da Inteligência Artificial na cultura do amendoim. A figura demonstra como diferentes plataformas de aquisição e sensores são combinados com algoritmos de aprendizado de máquina e aprendizado profundo para extrair e classificar variáveis agronômicas essenciais




Figure 2.3. Fluxo de aplicação do Sensoriamento Remoto e Inteligência Artificial no cultivo de amendoim, utilizando diferentes plataformas, sensores e algoritmos para análise e classificação de variáveis agrônômicas.

3. Análise das Descobertas da Pesquisa

A realização de uma investigação minuciosa do uso de técnicas de SR e IA na cultura do amendoim é fundamental para consolidar o conhecimento disponível e identificar lacunas para novas pesquisas. O amendoim, uma cultura em crescimento global, destaca-se não apenas pelo seu valor econômico, mas também por seu potencial nutricional e pela versatilidade de aplicação na indústria alimentícia.

3.1. Evolução, Impacto e Representatividade

A investigação identificou um conjunto inicial de 301 artigos potenciais para a revisão sistemática. Após uma seleção criteriosa, baseada na relevância e aderência dos estudos que relacionam SR e IA ao monitoramento de parâmetros agrônômicos da cultura do amendoim, foram selecionados 40 artigos científicos publicados no período de 2020 a 2024. Esses trabalhos permitiram mapear a evolução, o impacto e a eficiência das técnicas aplicadas à cultura, destacando avanços significativos na área de estudo.

Globalmente, o mapeamento das publicações mostrou que a China lidera com mais de 50% da produção científica, resultado de um forte investimento em pesquisa e inovação no setor agrícola (Figura 2.4A). Os Estados Unidos e o Brasil ocupam, respectivamente, a segunda e terceira posições, com 23% e 13% das publicações. Em

contraste, países como Austrália e Irã apresentaram uma presença limitada na área, cada um com apenas uma publicação durante o período avaliado, e sem registros de apoio financeiro específico para tais estudos. Esses achados ressaltam a distribuição desigual de recursos para pesquisa agrícola e demonstram o impacto do investimento em ciência e tecnologia no avanço do conhecimento sobre a cultura do amendoim.

A análise revelou um aumento expressivo na produção científica voltada para o amendoim nos últimos cinco anos, com destaque para o período a partir de 2020, quando o número de publicações relacionadas ao escopo desta revisão mais que dobrou, alcançando um ápice em 2021 e 2024 (Figura 2.4B). Esses dados refletem a crescente valorização da cultura do amendoim na agricultura global e indicam o direcionamento de esforços em pesquisas de alto impacto para explorar novas fronteiras para a cultura.




Figure 2.4. Distribuição global (A) e evolução temporal (B) das publicações sobre Sensoriamento Remoto e Inteligência Artificial no cultivo de amendoim.

Fonte: Autores (2025).

Os gráficos de rede revelam os principais autores envolvidos em pesquisas sobre a integração de SR e IA aplicados à cultura do amendoim nos últimos anos, destacando tanto a coautoria quanto a evolução temporal dessas publicações (Figura 2.5A). É notável a relevância de autores como Wei Guo, Tingting Chen, Yin Bao, Adão Santos e Rouverson Silva, que aparecem como os principais colaboradores em publicações, indicando sua liderança na área e forte integração com outros pesquisadores.

O segundo gráfico aprofunda essa análise, mostrando a principal ligação na rede, que é entre os autores Yan Bao, Adão Santos e Rouverson Silva (Figura 2.5B),

demonstrada pela amplitude de conexões com diferentes redes de pesquisadores, o que sugeri um papel de difusão de conhecimento. A predominância dessa colaboração de longa data, ilustra a consolidação de parcerias sólidas e contínuas, enquanto o gradiente temporal (2020-2024) indica um crescimento recente na contribuição de novos autores, com aumento na intensidade das publicações a partir de 2021. Esses resultados enfatizam o impacto global na integração de ferramentas digitais para otimizar o manejo do amendoim e apontam para uma colaboração interdisciplinar ativa, refletindo um movimento colaborativo considerável entre os principais pesquisadores e sugerindo um futuro promissor para inovações tecnológicas para a cultura em questão.




Figura 2.5. Redes de coautoria em pesquisas sobre a integração de Sensoriamento Remoto e Inteligência Artificial no cultivo de amendoim. (A) Principais autores e colaborações ao longo do tempo. (B) Estrutura das conexões entre pesquisadores, destacando autores centrais na disseminação do conhecimento na área. Fonte: Autores (2025).

3.2. Formas de Divulgação Científica

Os resultados apresentados no gráfico (Figura 2.6) indicam a distribuição dos artigos utilizados na revisão sistemática com base na frequência de publicações e no fator de impacto dos periódicos. A análise revela que as publicações estão concentradas em periódicos de alta relevância nas áreas de agricultura digital, sensoriamento remoto e

ciência dos alimentos, refletindo a multidisciplinaridade e o foco crescente na aplicação de tecnologias avançadas à agricultura.

A figura 6 evidencia que o periódico *Food Chemistry* se destaca com o maior fator de impacto (8,5) contando com quatro artigos, o que sugere um interesse significativo da comunidade científica nos aspectos químicos relacionados à produção e qualidade do amendoim. Em contrapartida, o maior número de publicações foi encontrado em *Computers and Electronics in Agriculture*, com seis artigos, ressaltando a importância das ferramentas tecnológicas aplicadas à agricultura digital, como inteligência artificial e sensoriamento remoto, no monitoramento de parâmetros agronômicos.

Outros periódicos com alta relevância para a revisão incluem *Precision Agriculture* (fator de impacto 5,4) e *Remote Sensing* (4,2), os quais estão fortemente alinhados às tecnologias empregadas no monitoramento remoto e gestão eficiente de lavouras. Além disso, *Postharvest Biology and Technology* e *Agriculture* também tiveram uma presença significativa, sugerindo que o escopo das pesquisas não se limita ao cultivo, mas abrange também aspectos relacionados ao pós-colheita e à sustentabilidade da cadeia produtiva do amendoim.

De maneira geral, a Figura 2.6 reforça que a interseção entre SR, ciência dos alimentos e AD é essencial para a inovação na cultura do amendoim. O impacto crescente das publicações em periódicos especializados reflete não apenas o avanço técnico-científico da área, mas também o aumento do reconhecimento da relevância socioeconômica dessa cultura. Esses achados indicam que a pesquisa sobre amendoim está em expansão, especialmente em periódicos voltados para inovações tecnológicas na agricultura e ciência aplicada, consolidando sua relevância no cenário agrícola mundial.



Figura 2.6. Distribuição dos artigos utilizados na revisão sistemática de acordo com a frequência de publicações e o fator de impacto dos periódicos Fonte: Autores (2025).

3.3 Tendência dos Alvos de Estudo

A evolução do foco das pesquisas sobre a cultura do amendoim entre 2020 e 2024, evidencia tendências emergentes e áreas prioritárias de investigação ao longo do tempo. Em 2020, o destaque está nas pesquisas sobre doenças, com seis publicações focadas nessa temática, o que reflete uma preocupação inicial com a saúde da cultura e os desafios fitossanitários enfrentados pelos produtores. Além disso, tópicos como pragas e IAF começaram a ganhar atenção nesse período, apontando para a relevância do monitoramento de estresses bióticos e fisiológicos no início do período analisado.

Nos anos seguintes, os estudos passaram a abranger uma gama mais ampla de temas. Em 2021, teve uma diversificação nos temas de pesquisa, com a incorporação de estudos sobre morfologia e pós-colheita, além de uma continuidade nos trabalhos

relacionados à maturação e às doenças. O ano de 2022 manteve um foco semelhante, mas destacou também investigações sobre nutrição, refletindo um interesse crescente na otimização de práticas agronômicas para melhorar a produtividade.

Em 2023 e 2024, o escopo das pesquisas se torna mais amplo e alinhado às necessidades de inovação em agricultura digital. Melhoramento de cultivares e biomassa surgem como tópicos importantes, indicando uma mudança de foco para o desenvolvimento de variedades mais adaptadas e eficientes. Em particular, 2024 apresenta uma concentração acentuada em doenças, com sete publicações, sugerindo uma intensificação dos esforços para mitigar problemas fitossanitários, possivelmente em resposta a novos desafios climáticos ou epidemiológicos, além de apresentar o maior número de alvos de estudo, o que indica que o uso dessas ferramentas de SR estão expansão para diversos seguimentos de pesquisa na cultura.

Esse panorama, ilustrado na figura 2.7, demonstra a transição das pesquisas ao longo do tempo, passando de um foco inicial nos problemas fitossanitários e estresse fisiológico para uma abordagem mais integrada, envolvendo maturação, rendimento, e melhoramento genético. Essa diversificação reflete o amadurecimento das pesquisas na cultura do amendoim, acompanhando as demandas por produtividade sustentável e inovação tecnológica na agricultura global.




Figure 2.7. Evolução dos temas de pesquisa sobre Sensoriamento Remoto e Inteligência Artificial aplicados ao cultivo do amendoim entre 2020 e 2024. Fonte: Autores (2025).

3.4. Síntese dos Principais Estudos de SR e IA na Cultura do Amendoim (2014-2024).

A análise dos resultados para o SR (Tabela 2) destaca as configurações de sensores, abrangendo variações em comprimento de onda, resolução espacial, bandas espectrais e requisitos de calibração, para diferentes aplicações na cultura do amendoim. Os comprimentos de onda variam amplamente, cobrindo espectros do visível ao infravermelho próximo e médio, indicando uma abordagem abrangente para capturar tanto características fisiológicas quanto estresses da cultura.

A predominância de sensores multiespectrais e hiperespectrais (Tabela 2) indica a importância dessas tecnologias na geração de índices de vegetação e na identificação de condições específicas da planta, como presença de doenças, variações na biomassa e estágios de maturação. A resolução espacial das imagens também apresenta variações significativas, indo desde valores sub-métricos, como 0,3 m/pixel, que permitem análises detalhadas de folhas individuais e sintomas precoces de estresses, até resoluções mais elevadas, como 3 m/pixel, mais indicadas para monitoramento de grandes áreas de cultivo. Resoluções mais altas, como as observadas em sensores RGB e hiperespectrais em plataformas proximais (Tabela 2.2), são essenciais para análises detalhadas da morfologia da planta e para a detecção precisa de sintomas iniciais de doenças. Já resoluções mais baixas, predominantes em sensores multiespectrais acoplados a plataformas orbitais, são mais adequadas para monitoramento em escala de campo.

No que se refere às bandas espectrais, observa-se uma predominância de sensores multibanda e hiperespectrais, que possibilitam a coleta de dados em várias faixas do espectro eletromagnético, essenciais para a criação de índices de vegetação e detecção de condições específicas da cultura. Contudo, a maioria das configurações analisadas carece de informações sobre índices específicos e métodos de calibração, o que pode impactar a comparabilidade e a confiabilidade dos dados coletados.

Além disso, apenas uma fração dos sensores apresentou configurações de sensor customizáveis, o que sugere uma limitação na adaptabilidade dos sistemas para responder a variabilidades ambientais e de cultivo. Essa diversidade de configurações evidencia uma abordagem não padronizada, indicando a necessidade de protocolos mais claros e calibrações específicas para fortalecer a precisão e a aplicabilidade dos dados de sensoriamento remoto no manejo do amendoim.

Dessa forma, os achados sintetizados na Tabela 2.2 demonstram que a área de sensoriamento remoto aplicada à cultura do amendoim ainda enfrenta desafios significativos em termos de padronização, calibração e escalabilidade das análises. A expansão do uso de plataformas aéreas e orbitais, aliada ao aprimoramento das metodologias de calibração e ao uso de índices espectrais bem definidos, poderá contribuir para melhorar a precisão das análises e aumentar a aplicabilidade dessas tecnologias no manejo da cultura em diferentes regiões e condições agrícolas.

A análise sistemática dos artigos selecionados revela uma abordagem variada na configuração e uso de parâmetros, bases de dados, e algoritmos para aplicações de inteligência artificial (IA) na cultura do amendoim (Tabela 2.3). Entre os artigos

revisados, 37,5% apresentaram detalhes de hiperparâmetros utilizados, indicando uma lacuna significativa de especificidade em muitos estudos, pois 15 artigos omitiram essa informação. Isso sugere a necessidade de uma maior padronização e transparência na definição de hiperparâmetros, uma prática que facilita a replicação e validação dos resultados.

No que se refere aos conjuntos de dados, observa-se que a maioria dos estudos analisados trabalha com bases relativamente pequenas, e nove artigos não apresentaram informações detalhadas sobre os bancos de dados utilizados. O número de amostras varia significativamente, desde menos de 150 até mais de 1.000 registros, sendo que a maioria dos estudos se baseia em amostras inferiores a 300. Como mostrado na Tabela 3, essa limitação pode impactar a robustez e a generalização dos modelos, especialmente em algoritmos complexos, como redes neurais profundas, que demandam maior variabilidade para reduzir o risco de overfitting.

Quanto à divisão entre treino e teste, as configurações mais comuns foram 80/20 e 70/30, utilizadas em 12 e 6 estudos, respectivamente. A padronização desses percentuais de divisão indica uma prática comum em estudos de IA, que visa garantir uma avaliação equilibrada de desempenho dos modelos. No entanto, apenas 3 artigos dos 40 revisados realizaram testes de generalização, destacando uma limitação importante nos estudos de IA aplicada ao amendoim, já que a capacidade de generalização é crucial para validar a aplicabilidade dos modelos em condições diferentes das amostras de treinamento.

Em termos de desempenho, a maioria dos estudos utilizou métricas tradicionais, como acurácia, precisão e F1-score (medida F1), enquanto outros incluíram métricas específicas, como Kappa (coeficiente kappa de Cohen), RMSE (erro quadrático médio), MAE (erro médio absoluto), R^2 (coeficiente de determinação) e MAPE (erro percentual absoluto médio), que permitem uma avaliação mais detalhada do ajuste dos modelos.

Contudo, um artigo específico não apresentou dados de performance, o que reduz a transparência sobre a eficácia do método proposto. Esses achados indicam uma necessidade de avanços na padronização de práticas metodológicas e na ampliação do uso de bases de dados mais robustas e testes de generalização para aumentar a confiabilidade e a aplicabilidade dos modelos em larga escala na cultura do amendoim.

Os achados apresentados na Tabela 2.3 reforçam a necessidade de avanços na padronização metodológica, na ampliação do uso de bases de dados mais robustas e na realização de testes de generalização. O aprimoramento dessas práticas contribuiria para aumentar a confiabilidade e a aplicabilidade dos modelos de IA na cultura do amendoim,

permitindo que essas soluções sejam mais eficazes e adaptáveis a diferentes cenários agrícolas.

1 **Table 2.2.** Main aspects of state-of-the-art research in remote sensing for peanut applications.

Author	Application	Platform	Sensor	Band	IV	Calibration	Spatial Resolution	Wavelength (nm)
(Wang et al., 2024)	Disease	Proximal	Hyperspectral	33	-	-	1392x1040 pixels	400-720
(Jiang et al., 2024)	Disease	Proximal	Thermal	-	-	-	32x32 pixels	-
(W. Guo et al., 2024)	Disease	Aerial	Multispectral	5	20	Yes	1cm/pixel	-
(Lin et al., 2024)	Disease	Proximal	RGB	3	-	-	4800x4344 pixels	-
(W. Guo et al., 2024)	Disease	Proximal	Hyperspectral	288	-	Yes	-	1000-2500
(Qiao et al., 2024)	LAI	Aerial	Multispectral	5	15	Yes	0.86 m/pixel	450-840
(Chapu et al., 2024)	Disease and Improvement	Proximal	Multispectral	4	12	-	-	-
(Sun et al., 2024)	Disease	Proximal	Hyperspectral	-	-	Yes	-	350-2500
(Oliveira et al., 2024)	Maturity and Biomass	Orbital	Multispectral	4	5	Yes	3 m/pixels	455-860
(Pugh et al., 2024)	Yield and Improvement	Aerial	RGB	3	-	-	1.37 cm/pixels	-
(Rajabi-Sarkhani et al., 2023)	Seeds	Proximal	Hyperspectral	-	-	-	-	250-1150
(Bidese-Puhl et al., 2023)	Yield	Proximal	Radar	-	-	Yes	-	-
(Bagherian et al., 2023)	Improvement	Aerial	Hyperspectral	200	80	Yes	0.1 m/pixels	400-1000
(W. Guo et al., 2023)	Disease	Proximal	Hyperspectral	-	12	-	-	350-2500
(Sudki et al., 2023)	Seeds	Proximal	Multispectral	-	-	Yes	2192x2192pixels	365-790
(Wu et al., 2022)	Seeds	Proximal	Hyperspectral	235	-	Yes	1344x1024pixels	400-1000
(Souza et al., 2022)	Maturiy	Orbital and Aerial	Multispectral	9	7	Yes	RPA = 7.96cm/px Sat=3m/px	RPA = 465-860 Sat = 455-860
(Lin et al., 2022)	Morphology	Aerial	RGB	-	-	-	1920x1080 pixels	-
(Fonseca de Oliveira et al., 2022)	Seeds	Proximal	Multispectral	19	-	Yes	2182x2192 pixels	365-970
(ZOU et al., 2022)	Seeds	Proximal	Hyperspectral	256	-	Yes	1344x1024 pixels	387-1034
(de Almeida et al., 2023)	Maturiy	Orbital	Multispectral	4	1	Yes	3 m/pixel	450-860
(Lavrinenko et al., 2022)	Disease	Proximal	Multispectral	4	-	-	-	350-1000
(Santos, Lacerda, et al., 2021)	Maturity	Aerial	Multispectral	4	11	Yes	95 mm/pixel	530-810
(Julrat & Trabelsi, 2022)	Post-Harvest	Proximal	Microwave	-	-	-	-	-

(dos Santos et al., 2021)	Maturity	Orbital	Multispectral	4	5	Yes	3-5 m/pixels	455-860	2
(Manhando et al., 2021)	Disease	Proximal	3D scanner	-	-	-	512x512 pixels	840	
(Wei et al., 2021)	Disease	Proximal	Hyperspectral	157	-	-	-	200-1100	3
(Sarkar et al., 2021)	Morphology	Proximal and Aerial	RGB	3	11	-	-	-	4
(Ziyae et al., 2021)	Disease	Proximal	RGB	3	-	-	-	-	5
(Qi et al., 2021)	Disease	Proximal	RGB	3	-	-	-	-	
(Qi et al., 2020)	LAI	Aerial	Multispectral	5	12	Yes	4608x3456 pixels	550-790	6
(Pinto et al., 2020)	Pest	Proximal	Hyperspectral	281	-	Yes	-	400-1000	7
(Chen et al., 2020)	Disease	Proximal and Aerial	Hyperspectral	5	46	Yes	RPA = 2 cm/pixel	350-2500	8
(Zhongzhi & Limiao, 2020)	Disease	Proximal	Hyperspectral	33	4	-	1392x1040 pixels	400-720	9
(Shahi et al., 2023)	Yield	Aerial	Multispectral	5	-	-	-	460-860	
(Xiong et al., 2024)	Seeds	Proximal	Hyperspectral	-	-	Yes	-	350-2500	10
(Manhando et al., 2021)	Nutrition	Proximal	Hyperspectral	256	-	Yes	1344x1024 pixels	387-1034	
(Clohessy et al., 2021)	Disease	Proximal	RGB	3	-	-	24.3 megapixels	-	
(Guan et al., 2022)	Disease	Proximal and Aerial	Hyperspectral	-	-	Yes	-	400-1000	
(Su et al., 2024)	Morphology	Proximal	Hyperspectral	-	-	Yes	-	350-2500	

Table 2.3. Main aspects of state-of-the-art research in artificial

11 intelligence for peanut applications.

Author	Application	Algorithms	Sensor	Hyperparameter	Database	Training/test	Generalization	Performance
(Wang et al., 2024)	Disease	CNN-BiLSTM, DT, SVM, RF, NB, CNN, LSTM, GRU AdaBoost	DL	Yes	250 grains	80/20	Yes	Accuracy, Recall, Specifinity, FPR e F1Score
(Jiang et al., 2024)	Disease	CNN	DL	Yes	8000 grains	70/30	-	Accuracy e Confusion Matrix
(W. Guo et al., 2024)	Disease	RF, KNN, PSO-SVM e AdaBoost	ML	-	1038 img	-	-	accuracy, precision, Recall e F1score
(Lin et al., 2024)	Disease	YOLOv8	DL	Yes	1810 img	80/20	-	Precision,Recall, AP, Map
(W. Guo et al., 2024)	Disease	DenseNet-121, ResNet-50, SqueezeNet, VGG-16, Xception e DAASST 8 e 2.	DL	Yes	3360 grains 56 img	75/25	-	Accuracy,Precision,Recall, F1 score

(Qiao et al., 2024)	LAI	ULR, SVM, RR, DTR, PLSR e RFR	ML	-	-	80/20	-	R ² e RMSE
(Chapu et al., 2024)	Disease and Improvement	SLR, PLSR, SVM, RF, KNN, ANN	ML	-	-	70/30	-	R ² , RMSE, Accuracy, Recall, Specificity, Precision
(Sun et al., 2024)	Disease	1D-CNN, SMOTE, SVM E KNN	ML and DL	Yes	610 samples	-	Yes	Kappa e Accuracy
(Oliveira et al., 2024)	Maturity and Biomass	MTR (KNN e RF)	ML	Yes	300 samples	80/20	-	MAE
(Pugh et al., 2024)	Yield and Improvement	Gompertz, RF, XGBoost	ML	Yes	~240	70/30	-	R ² e Confusion Matrices
(Rajabi-Sarkhani et al., 2023)	Seeds	LR, DT, MP, SVM, KNN, e NB	ML	-	300 seeds	-	-	R ² , RMSE, Accuracy, Precision, Sensitivity, Specificity
(Bidese-Puhl et al., 2023)	Yield	LR, RF, SVM, RBF, MLP, KNN	ML	-	3172 samples	80/20	-	R ² , RMSE, sMAPE
(Bagherian et al., 2023)	Improvement	KNN, SVR, RF, MLP, CNN 1-D	ML and DL	Yes	256 samples	90/10	-	R ² , RMSE, sMAPE
(W. Guo et al., 2023)	Disease	SVM, KNN, decision tree, RBF	ML	-	175 samples	-	-	Confusion Matrice, Kappa
(Sudki et al., 2023)	Seeds	LDA, MLP, SVM, RF	ML	-	2500 samples	75/25	-	Kappa, Accuracy, Recall, Confusion Matrice, F1
(Wu et al., 2022)	Seeds	GBDT, XGBoost, CatBoost, LightGBM e SEL	ML	-	1600 samples	70/30	-	Accuracy, Log loss, Hamming loss
(Souza et al., 2022)	Maturiy	MLP e RBF	ML	yes	150 samples	80/20	-	R ² e MAE
(Lin et al., 2022)	Morphology	YOLOv5	DL	-	1701 img	90/10	-	Precision, Recall, AP, mAP, F1
(Fonseca de Oliveira et al., 2022)	Seeds	ADQ	ML	-	170 seeds	70/30	-	Sensitivity e Specitivity
(ZOU et al., 2022)	Seeds	XGBoost, CatBoost, LightGMB, GBDT	ML	Yes	-	-	-	Confusion Matrice
(de Almeida et al., 2023)	Maturiy	LR	ML	-	-	80/20	-	R ² , MAE e ER
(Lavrinenko et al., 2022)	Disease	MLP	ML	-	1000 samples	90/10	-	-
(Santos, Lacerda, et al., 2021)	Maturity	MLR, LR, MLP e RBF	ML	-	-	80/20	-	R ² e RMSE
(Julrat & Trabelsi, 2022)	Post-Harvest	LR, MLP	ML	-	148 grains	80/20	-	SEC e SEP
(dos Santos et al., 2021)	Maturity	Gompertz	ML	-	216 sample	-	-	R ² e RMSE
(Manhando et al., 2021)	Disease	ECOC-SVM, KNN	ML	-	46500 img	-	-	Recall, F1-score, Accuracy, Precision

(Wei et al., 2021)	Disease	NB, KNN, LDA, MLP, RF, SVM, Gboost e XGBoost	ML	Yes	399 sample	80/20	-	Confusion Matrice
(Sarkar et al., 2021)	Morphology	LR	ML	-	251 img	90/10	Yes	Precision Matrice
(Ziyadeh et al., 2021)	Disease	ANN, SVM, ANFIS, MLP	ML	-	—	80/20	-	MAE, RMSE, MPE, Intensity, Saturation e Hue
(Qi et al., 2021)	Disease	CNN, AlexNet, VGG, ResNet, DenseNet, Inception, RF, Regressão Logística, SVM	ML and DL	-	6029 img	80/20	-	Out-of-Fold Prediction
(Qi et al., 2020)	LAI	SR, RNA-BP	ML	-	—	—	-	R ² e RMSE
(Pinto et al., 2020)	Pest	RF	ML	Yes	1249 samples	70/30	-	Kappa
(Chen et al., 2020)	Disease	RNA-BP, MLP	ML	-	250 samples	-	-	R ² e RMSE
(Zhongzhi & Limiao, 2020)	Disease	SVM	ML	-	144 samples	-	-	MSE e R ²
(Shahi et al., 2023)	Yield	MLR, SVM, DT, RF, ETR, AdaBoost, XGBoost, MLP	ML	Yes	485 samples	90/10	-	R ² , MAE, RMSE e MARE
(Xiong et al., 2024)	Seeds	SVM, RF, Line, RT, RBF	ML	Yes	160 grains	-	-	R ² , MSE, RMSE
(Manhanda et al., 2021)	Nutrition	XGBoost, CatBoost, LightGBM, Ridge	ML	Yes	4704 img	-	-	MAE, MEDAE, RMSE
(Clohessy et al., 2021)	Disease	CNN, Inception V3	DL	-	—	-	-	F1-score
(Guan et al., 2022)	Disease	KNN, MLR	ML	-	75 leaves	-	-	Precision, Kappa
(Su et al., 2024)	Morphology	PLSR, SVR, GBDT, XGBoost	ML	-	—	-	-	R ² , RMSE

3.5. Agricultura Digital em Foco no Amendoim: Avanços e Desafios

O gráfico de Sankey apresenta uma visão integrada da utilização de plataformas, sensores, aplicações e algoritmos no contexto da AD aplicada à cultura do amendoim (Figura 2.8). Existe uma predominância do uso de plataformas proximais para o monitoramento da cultura do amendoim, com uso complementar de plataformas aéreas e orbitais. Embora o SR proximal ofereça alta precisão em áreas específicas, há uma necessidade crescente de estudos com plataformas aéreas e orbitais para permitir escalabilidade e aplicação em larga escala. Essas tecnologias capturam dados extensivos e contínuos sobre as lavouras, possibilitando uma análise mais ampla e adaptável a diferentes regiões e condições. O uso de plataformas aéreas e orbitais facilita a padronização de práticas de monitoramento em nível de campo, o que é crucial para o desenvolvimento de estratégias de manejo sustentável e produtivo em várias localidades, promovendo assim a aplicabilidade dos resultados em diferentes contextos e regiões produtoras de amendoim.




Figura 2.8. Gráfico de Sankey representando a conexão entre plataformas, sensores, aplicações e algoritmos no monitoramento da cultura do amendoim.

Fonte: Autores (2025).

Em relação aos sensores, observa-se um uso expressivo de tecnologias, multiespectrais e hiperespectrais, refletindo a necessidade de capturar variações nas características fisiológicas da planta e detectar estresses. Sensores RGB (R-vermelho, G-

verde e B-azul) também são amplamente utilizados, sugerindo que câmeras convencionais desempenham um papel relevante em análises rápidas e práticas no campo. Outros sensores, como radar e térmico, aparecem em menor frequência, indicando um uso emergente e exploratório dessas tecnologias para finalidades específicas.

As principais aplicações evidenciam um foco em doenças, destacando a importância do vigor da planta na pesquisa de amendoim. Aplicações voltadas para maturação das vagens e qualidade das sementes também são prioritárias, refletindo o interesse em otimizar o ciclo produtivo. Áreas como, produtividade, biomassa, índice de área foliar (LAI) e pós-colheita têm menor representação, indicando um potencial para expansão futura nessas áreas.

No campo dos algoritmos, a predominância de ML destaca o papel central da IA na análise e modelagem de dados na AD. A utilização de DL para tarefas mais complexas reflete uma tendência crescente de aplicar métodos avançados para identificar padrões complexos, especialmente em aplicações de processamento de imagens e classificação, onde a capacidade de extração automática de características é essencial para capturar detalhes agrônômicos e variabilidades fisiológicas da cultura do amendoim.

4. Sensoriamento Remoto

O SR é uma das geotecnologias mais amplamente utilizadas tanto na Agricultura de Precisão (AP) quanto na AD, devido à sua capacidade de coletar dados sem a necessidade de contato físico com o alvo (Novo, 2010; Molin et al., 2015; Queiroz et al., 2022). Trata-se de um método não destrutivo que permite a obtenção de informações sobre cultivos agrícolas sem a necessidade de removê-los, como, por exemplo, no monitoramento do comportamento espectral das culturas (Formaggio; Sanches, 2017).

O foco principal do SR é a obtenção de dados de forma remota, sem contato direto com o alvo, que, neste artigo, será a planta. A coleta de informações ocorre por meio da interação da radiação eletromagnética com a planta. Essa radiação pode ser adquirida de forma natural, pela radiação solar, ou de forma artificial, utilizando sensores ópticos ativos, possibilitando o monitoramento detalhado do comportamento da vegetação.

A radiação eletromagnética é composta pelo espectro eletromagnético, que abrange um conjunto de comprimentos de onda, desde os raios gama até as ondas de rádio (Jensen, 2009). No entanto, parte desses comprimentos de onda é absorvida pela atmosfera, devido aos seus componentes, como oxigênio, ozônio, gás carbônico e vapor d'água, entre outros (Novo, 2010). Comprimentos de onda de alta frequência, como os

raios gama, raios ultravioleta e raios X, são altamente ionizantes, ou seja, possuem energia suficiente para alterar a estrutura celular de seres vivos, podendo causar mutações ou até mesmo a morte (Moreira, 2012).

Por outro lado, os comprimentos de onda que chegam à superfície terrestre possuem frequências não ionizantes e estão localizados nas regiões do visível, infravermelho, micro-ondas e ondas de rádio (Moreira, 2012; Jensen, 2009). Na agricultura, os comprimentos de ondas mais utilizados são aqueles correspondentes às regiões do visível, infravermelho e micro-ondas, devido à sua capacidade de fornecer informações importantes para o monitoramento e a análise do comportamento espectral dos cultivos agrícolas (Formaggio; Sanches, 2017).

A interação entre a radiação eletromagnética e o alvo, neste caso, a planta, pode resultar em diferentes processos: parte da radiação é absorvida (utilizada na fotossíntese), outra é transmitida, refletida, retroespalhada ou emitida na forma de calor. Sensores remotos ópticos captam a radiação refletida pelo alvo, enquanto os sensores radares registram o retroespalhamento.

O SR pode ser aplicado em diversas áreas devido ao seu método sustentável e não destrutivo, sendo amplamente utilizado em setores como o florestal, aquático, militar, geológico, meteorológico, ambiental, agrícola, entre outros. Este artigo concentra-se na aplicação do SR na agricultura, destacando as vantagens e benefícios que essa geotecnologia oferece para o setor.

O SR possibilita a estimativa de diversas características biofísicas das culturas agrícolas, como a biomassa e a produtividade, além do monitoramento dos estádios de crescimento das plantas e da detecção de anomalias na lavoura por meio do acompanhamento do comportamento espectral espaço-temporal das culturas (Brandão et al., 2009; Shiratsuchi et al., 2014).

Adicionalmente, o SR auxilia os agricultores na tomada de decisões mais assertivas e rápidas, permitindo a identificação precoce de anomalias causadas por patógenos (como doenças, insetos-praga e nematoides), infestações de plantas daninhas ou estresses hídrica, fisiológica e nutricional. Esses monitoramentos podem ser realizados com sensores remotos ópticos, sejam eles ativos ou passivos, ou com sensores de radar, ampliando a capacidade de gestão e intervenção nas lavouras.

4.1. Tipos de Sensores e Plataformas Utilizadas

Os sensores podem ser instalados em diferentes plataformas, como orbitais (satélites), aéreas (Aeronaves Remotamente Pilotadas – ARPs e aviões) e terrestres ou

proximais (acoplados a máquinas agrícolas, bicicletas, motos ou utilizados manualmente).

Os sensores podem ser classificados de acordo com sua fonte de energia (passivos ou ativos), número de bandas espectrais ou comprimento de ondas (resolução espectral), resolução espacial, tipo de polarização (no caso de sensores de radar), além de serem categorizados como imageadores ou não-imageadores (Novo, 2010).

Sensores ativos são aqueles que emitem sua própria radiação eletromagnética, permitindo sua utilização em qualquer horário do dia ou da noite, independentemente das condições de luminosidade (Jensen, 2009). Por outro lado, sensores passivos dependem de uma fonte externa de radiação eletromagnética, como a radiação solar, para captar os dados por meio de reflectância ou retroespalhamento (Novo, 2010). Contudo, os sensores passivos apresentam algumas limitações em comparação aos ativos. Por exemplo, sua operação é restrita ao período diurno, exigindo que as coletas sejam realizadas sempre no mesmo horário para garantir consistência nos dados. Além disso, a presença de nuvens durante a coleta pode comprometer a qualidade dos dados, pois a presença de nuvem reduz a intensidade da radiação refletida, tornando necessário repetir a coleta em condições ideais de luminosidade.

Quanto à resolução espectral, se refere à quantidade de comprimentos de onda que o sensor é capaz de capturar em relação ao alvo. Os sensores podem ser classificados como monoespectrais, quando coletam dados em apenas um comprimento de onda; sensores RGB, que operam na região do visível (R – vermelho, G – verde e B – azul); multiespectrais, que abrangem entre três e doze comprimentos de onda; e hiperespectrais, que capturam mais de cem comprimentos de onda (Novo, 2010), conforme ilustrado na Figura 2.9.




Figura 2.9. Comparação entre sensores RGB, multiespectral e hiperespectral em relação à reflectância e ao comprimento de onda capturado.

Fonte: Shiratsuchi et al. (2023)

Os sensores imageadores captam imagens da área em formato matricial, enquanto os não imageadores coletam apenas dados numéricos do alvo. A resolução espacial, característica dos sensores imageadores, refere-se ao tamanho do pixel: quanto menor o pixel, maior o detalhamento da imagem. Já a polarização, mais comum em sensores radar, indica a capacidade do sensor de captar diferentes tipos de polarização do alvo (planta), podendo ser simples (uma polarização), dupla (duas polarizações) ou completa (quatro polarizações).

Na cultura do amendoim, com base no levantamento bibliográfico dos estudos que utilizam SR na agricultura, foram identificados 15 sensores ativos, 27 sensores passivos e apenas dois sensores de radar. Em relação à resolução espectral, verificou-se a utilização de um sensor monoespectral, 18 sensores multiespectrais e 18 sensores hiperespectrais. Vale destacar que, quanto maior a quantidade de comprimentos de onda disponíveis no sensor, mais detalhado é o comportamento espectral capturado da cultura, permitindo resultados mais precisos e eficazes para subsidiar tomadas de decisão assertivas.

A maioria dos estudos realizados optou pelo uso de sensores ópticos devido à maior facilidade no processamento dos dados, em comparação com os sensores de radar, cujo processamento é mais complexo por envolver a polarização dos sinais retroespalhados da cultura. No entanto, pesquisas recentes têm explorado o potencial dos sensores de radar, apresentando resultados promissores para aplicações agrícolas (Julrat & Trabelsi, 2021; Bidese-Puhl et al., 2023).

Quanto ao tipo de plataforma de SR utilizada na cultura do amendoim, destacam-se 28 estudos com plataformas proximais, 12 com plataformas aéreas e três com

plataformas orbitais. As pesquisas que empregaram SR orbital nesse cultivo utilizaram imagens multiespectrais de alta resolução espacial, como as da constelação dos nanossatélites da PlanetScope, para estimativa e predição do índice de maturação do amendoim (Santos et al., 2021; Almeida et al., 2022; Freire Oliveira et al., 2024).

No caso do SR aéreo, o uso de ARPs foi aplicado ao monitoramento espectral do cultivo (Guo et al., 2024), predição de características biofísicas, como biomassa e produtividade sob condições de estresse hídrico (Bagherian et al., 2023), estimativa de maturação (Costa Souza et al., 2022), detecção de plantas daninhas (Lin et al., 2022) e doenças (Chen et al., 2020; Sarkar et al., 2021; Gua et al., 2022), além da estimativa do índice de área foliar (Qi et al., 2020), entre outras aplicações.

Em relação ao SR proximal, as pesquisas têm se concentrado, principalmente, em análises laboratoriais utilizando sensores hiperespectrais, como espectrômetros, para avaliar a qualidade das sementes. Esses estudos incluem a verificação do vigor (Xiong et al., 2024), a presença de mofo (Wu et al., 2022), além de aspectos relacionados à germinação e ao envelhecimento das sementes (Rajabi-Sarkhani et al., 2023). Outros trabalhos têm explorado a aplicação do SR proximal na detecção de doenças, tanto em sementes (Sudki et al., 2023) quanto em plantas cultivadas no campo (Guo et al., 2023). Além disso, há investigações sobre a concentração de aflatoxinas em sementes (Zhongzhi; Limiao, 2020), entre outras abordagens relevantes para o monitoramento e a melhoria da qualidade do monitoramento agrícola.

4.2. Índices de Vegetação Aplicados

Os índices de vegetação (IVs) são equações matemáticas obtidas a partir da combinação de comprimentos de onda, geralmente nas regiões do visível, infravermelho e micro-ondas do espectro eletromagnético. Esses índices são amplamente utilizados na agricultura para monitorar o comportamento espaço-temporal dos cultivos agrícolas, proporcionando informações valiosas para o manejo e a tomada de decisão.

Entre os índices de vegetação mais utilizados atualmente na cultura do amendoim destacam-se: NDVI (Índice de Vegetação por Diferença Normalizada), OSAVI (Índice de Vegetação Ajustado ao Solo Otimizado), RDVI (Índice de Vegetação por Diferença Renormalizada), NPCI (Índice Normalizado de Pigmento e Clorofila), NDRE (Índice de Diferença Normalizada na Borda Vermelha), MSR (Razão Simples Modificada), EVI (Índice de Vegetação Aprimorado), CIRE (Índice de Clorofila na Borda Vermelha), DVI (Índice de Vegetação por Diferença), MSAVI (Índice de Vegetação Ajustado ao Solo Modificado), TVI (Índice de Vegetação Transformado), GRVI (Índice de Vegetação por

Razão Verde), SAVI (Índice de Vegetação Ajustado ao Solo), MCARI (Índice de Absorção de Clorofila Modificado no Espectro de Reflectância), GNDVI (Índice de Vegetação por Diferença Normalizada Verde), NLI (Índice Não-Linear), MNLI (Índice Não-Linear Modificado), PRI (Índice de Reflectância Fotoquímica), CI (Índice de Clorofila), WI (Índice de Água), MTVI (Índice Triangular de Vegetação Modificado), VOG1 (Índice de Borda Vermelha de Vogelmann), SIPI (Índice de Pigmento Insensível à Estrutura), PSRI (Índice de Reflectância para Senescência Vegetal), SR (Razão Simples), ARI (Índice de Reflectância para Antocianina) e TCARI (Índice de Absorção de Clorofila Transformado no Espectro de Reflectância).

Entre os índices de vegetação mencionados, o NDVI foi um dos primeiros a ser desenvolvido e amplamente aplicado na agricultura. Contudo, sua suscetibilidade à saturação com o aumento da biomassa da parte aérea das plantas incentivou o desenvolvimento de novos índices para mitigar essa limitação (Gitelson et al., 2003). Um exemplo é o GNDVI, que substitui o comprimento de onda do vermelho pelo verde (Gitelson; Merzlyak, 1996), proporcionando maior sensibilidade em determinadas condições. Além disso, os índices NDRE e CIRE se destacam por explorar a região da borda do vermelho (Fitzgerald et al., 2010), menos suscetível à saturação em comparação à região do vermelho (Amaral et al., 2015), permitindo análises mais precisas em estádios avançados de crescimento das culturas.

O NDVI, em geral, é mais indicado para uso nos estádios iniciais do cultivo, especialmente antes dos 75 dias após a semeadura (DAS) (Morlin Carneiro et al., 2020), demonstrando maior eficiência na coleta de dados de reflectância da planta durante esse período.

Outros índices, como o SAVI, foram desenvolvidos para minimizar a influência da reflectância do solo (Huete, 1988), particularmente em estádios iniciais do desenvolvimento do cultivo, quando o dossel ainda não cobre completamente o solo. Esses avanços na criação de IVs têm permitido análises mais precisas e eficazes, contribuindo significativamente para a agricultura de precisão e o manejo sustentável dos recursos.

O monitoramento dos parâmetros agronômicos pode ser realizado por meio dos IVs ou diretamente pelos comprimentos de onda. Quando a planta é submetida a algum tipo de estresse, seja ele fisiológico, nutricional, ou por patógeno, a reflectância dos comprimentos de onda é alterada, especialmente nas regiões do visível, em particular no vermelho, e do infravermelho próximo (NIR). Em condições normais, sem a presença de

estresses, parte da radiação eletromagnética é absorvida pelas clorofilas *a* e *b* (Taiz; Zeiger, 2013), principalmente nos comprimentos de onda do azul e do vermelho, enquanto há maior reflectância no NIR. Nesse contexto, os valores dos IVs tendem a aumentar conforme o desenvolvimento e o incremento de biomassa na planta.

No entanto, quando a planta está sob estresse, como no caso de doenças, observa-se uma alteração nesse padrão. Estudos realizados por Guan et al. (2022) e Guo et al. (2023) identificaram que a taxa fotossintética é reduzida, resultando em menor absorção dos comprimentos de onda na região do visível e aumento na reflectância, enquanto no NIR ocorre uma redução na reflectância. Essas mudanças ressaltam a importância do uso dos IVs e da análise espectral para o diagnóstico precoce e o monitoramento ao longo dos estádios de crescimento da cultura. Essa abordagem permite detectar de forma antecipada o surgimento de doenças ou outras anomalias que impactam a taxa fotossintética e, consequentemente, o potencial produtivo da cultura.

4.3 Tecnologias Associadas ao SR

O uso integrado da Inteligência Artificial (IA), cujos fundamentos serão abordados na seção cinco deste artigo, tem se destacado como uma ferramenta poderosa para a estimativa e predição de parâmetros agrônômicos das culturas, como biomassa, produtividade e índice de área foliar, entre outros. A IA, uma área da Ciência da Computação, abrange análises estatísticas avançadas como redes neurais artificiais (RNA), aprendizado de máquina (ML – *Machine Learning*) e aprendizado profundo (DL – *Deep Learning*), que têm demonstrado grande potencial quando aplicadas ao SR. Essa integração permite uma compreensão mais detalhada do comportamento dos dados espectrais, que frequentemente não seguem uma distribuição normal, o que limita a eficácia de métodos baseados em análises estatísticas tradicionais. Dessa forma, a aplicação da IA no SR proporciona resultados mais precisos e aprofundados na análise da interação entre a radiação eletromagnética e as plantas, ampliando significativamente o potencial de tomadas de decisão no manejo agrícola.

Com base no banco de dados utilizado neste artigo, que foi analisado quarenta estudos publicados entre 2020 e 2025, apenas dois deles não empregaram a análise estatística baseada na IA evidenciando os benefícios dessa integração entre IA e SR. Entre os benefícios observados, destaca-se a detecção rápida e eficaz de substâncias tóxicas no amendoim, como aflatoxinas, por meio do uso de sensores hiperespectrais e algoritmos de *machine learning* e *deep learning* (Wang et al., 2025).

Outro exemplo é a avaliação da qualidade das sementes de amendoim, permitindo a identificação de sementes germinadas, mofadas, secas ou defeituosas por meio do SR proximal integrado ao *deep learning*, utilizando o algoritmo redes neurais convolucionais - CNN (Jiang et al., 2024). Além disso, o SR aéreo combinado com técnicas de *machine learning* tem sido empregado na detecção de doenças, demonstrando resultados promissores (Guo et al., 2024).

Outra inovação tecnológica adotada é a conectividade proporcionada por equipamentos com tecnologia 5G (Lin et al., 2024), integrados à Internet das Coisas (IoT). Essa combinação facilita a expansão dos bancos de dados e o acesso rápido e eficiente aos dados gerados pelo SR e pela IA. Essa integração tecnológica aprimora significativamente o monitoramento e a análise, promovendo avanços importantes na AD.

5. Inteligência Artificial

A inteligência Artificial (IA) pode ser classificada como uma técnica abrangente que utiliza o poder dos computadores para imitar o comportamento humano a fim de resolver problemas complexo de forma mais rápida e precisa. O aprendizado de máquina (ML) tem alta capacidade de resolver problemas complexos que se baseiam em modelos analíticos que visam gerar previsões, estimativas, respostas ou recomendações. Em ML, podemos trabalhar com quatro métodos, cada um sendo utilizado para resolver problemas específicos, que são o método supervisionado, não supervisionado, semisupervisionado e o de aprendizagem por reforço (Rene Y. Choi¹, 2020). De maneira geral, os algoritmos de ML executam tarefas com aprendizado iterativo a partir de um conjunto de dados que demonstra algum problema a ser resolvido, encontrando padrões complexos e ocultos, sendo eficiente em tarefas de classificação, regressão e agrupamento (Christopher M. Bishop, 2006; Janiesch et al., 2021).

Durante os anos essas técnicas têm evoluído de forma gradual com o desenvolvimento de algoritmos mais sofisticados e técnicas mais modernas e eficientes, o que nos levou a desenvolvimento de arquiteturas de redes neurais artificiais com capacidade de aprendizado mais aprimorada, surgindo então o aprendizado profundo (DL). Dito isto, o DL se classifica como uma subárea do ML, no entanto, por seguir uma estrutura de redes neurais, o DL oferece aprendizado automático com sua representação sendo realizada em diversos níveis hierárquicos, tornando-o mais robusto quando comparado com os métodos tradicionais de ML, principalmente em trabalhos com dados maiores e mais complexos (Sharma et al., 2021).

A IA tem transformado o setor agrícola, permitindo abordagens mais precisas, eficientes e escaláveis para o monitoramento e o manejo de culturas. Através de algoritmos avançados, a IA por meio dos métodos de ML e DL possibilita a análise de grandes volumes de dados, como dados gerados por imagens a partir do SR e dados ambientais, gerando insights que auxiliam na tomada de decisão. No cultivo do amendoim, a aplicação de IA se destaca em diversas frentes, com o ML e DL para análise preditiva. A seguir, exploraremos tópicos específicos que demonstram o impacto e as oportunidades trazidas pela IA na cultura do amendoim.

5.1. Aplicações de Machine Learning e Deep Learning para o Amendoim

Diante do que foi estudado nesta revisão, o uso de machine learning e deep learning para aplicações na cultura do amendoim tem ganhado notoriedade nos últimos anos na comunidade científica. Os estudos envolvem desde áreas como sementes, passando por parâmetros nutricionais, fitopatológicos, biofísicos e estudos relacionados a colheita e pós-colheita, o que demonstra uma ampla aplicação visando o desenvolvimento tecnológico e o manejo sustentável da cultura do amendoim.

O uso da IA tem sido destacado na literatura para manejo integrado de doenças na cultura do amendoim. A maioria dos estudos focam em utilizar técnicas de ML ao invés de DL para detectar doenças foliares e doenças fúngicas (Sarkar et al., 2021 Lavrinenko et al., 2022 Chen et al., 2020Guo et al., 2024 Sudki et al., 2023). Algoritmos de ML usados na detecção de doenças foliares como ferrugem e queimaduras demonstraram maior capacidade na identificação de doenças simultâneas na mesma folha (Qi et al., 2021). Em contrapartida, quando se comparou as duas técnicas para detectar doenças fúngicas, o uso do algoritmo CNN, mostrou-se mais confiável que os modelos SVM (Support Vector Machine), RF e AdaBoost (Wang et al., 2025). É importante ressaltar que o DL foi amplamente utilizado na investigação de doenças, o que demonstra uma lacuna no uso desta ferramenta em outras áreas de estudo para a cultura do amendoim.

Outro gargalo no manejo do amendoim é sem dúvidas determinar a qualidade dos lotes de sementes, que apresentam diversos métodos, porém, são processos com alta complexidade, que demandam um longo tempo de trabalho, com custos elevados (Jiang et al., 2024). Diante disto, modelos de aprendizado de máquinas demonstram precisão acima de 98% na identificação de lotes de sementes por meio de estresse, mofo, sementes defeituosas, secas e germinadas (Fonseca de Oliveira et al., 2022;Jiang et al., 2024). Determinar a qualidade da semente é primordial para mitigar possíveis perdas para safras

futuras. O uso de modelos de ML, podem otimizar a detecção em até 375 vezes mais rápida do que os métodos tradicionais para determinar a qualidade de sementes, demonstrando ser um método mais eficiente e não destrutivo (Jiang et al., 2024).

O ponto de colheita é determinado a partir no nível de maturidade das vagens, em que é sugerido que a colheita seja realizada quando a lavoura atingir 70% das vagens maduras (Rowland et al., 2006). Pensando nisto, técnicas que consigam identificar a variabilidade da maturação a nível de campo, para determinar o ponto ótimo de colheita tem sido potencializada com o uso de ferramentas digitais (dos Santos et al., 2021). A lentidão e a subjetividade na determinação do Índice de Maturação do Amendoim (PMI), abre uma lacuna que pode ser sanada por modelos de ML, que trazem mais assertividade e rapidez na determinação do PMI (de Almeida et al., 2023). Estimativas da maturação foram feitas utilizando Redes Neurais Artificiais (RNA) que apontam desempenho satisfatório na estimativa do PMI, utilizando algoritmos como Radial Function Bases (RBF), Multilayer Perceptron (MLP), MultiTarget Regression (MTR), Linear Regression (LR) e Linear Regression Multipler (LRM) (de Almeida et al., 2023; dos Santos et al., 2021; Oliveira et al., 2024; Santos et al., 2021; Souza et al., 2022).

5.2. Algoritmos Utilizados na Cultura do Amendoim

Os modelos desenvolvidos por IA representados por uma gama de algoritmos, são aplicados em estimativas e predições dos parâmetros que envolvem todo o manejo do amendoim. Identificar o algoritmo e qual método é o mais indicado, pode fazer toda a diferença no resultado. Dentro das alternativas, o ML e DL apresentam diversas possibilidades para o desenvolvimento de modelos. Para o ML, os algoritmos mais utilizados são KNN, RF, XGBoost, MLP e SVM (Zhongzhi & Limiao, 2020; Wei et al., 2021; Santos et al., 2021; Lin et al., 2022; Rajabi-Sarkhani et al., 2023; Pugh et al., 2024), enquanto no DL os algoritmos mais frequentes são os CNN, YOLO e o ResNet (Lin et al., 2024; W. Guo et al., 2024; Z. Guo et al., 2024; Jiang et al., 2024; Wang et al., 2024).

Para as técnicas de ML, observamos aplicações em diversos alvos de estudo para o amendoim, no entanto, o uso de ML para aplicações de âmbito patológico, apresentaram desempenho inferior quando comparado com os modelos de DL. A rede convolucional 1D-CNN (calibração – Kappa = 0,85; validação – Kappa = 0,75) estimou com maior precisão a severidade de requeima do amendoim, tanto na calibração como na generalização, em relação aos algoritmos de ML (SVM e KNN) com precisão máxima de Kappa 0,83 na calibração e 0,49 na generalização. Por outro lado, Bagherian et al., (2023),

verificaram que os algoritmos de ML foram superiores ao DL quando utilizados para estimar características fisiológicas do amendoim, em um estudo de fenotipagem de alto rendimento.

O uso de redes convolucionais para o monitoramento e detecção de doenças no amendoim tem sido amplamente considerado nos últimos anos, trazendo uma abordagem de alto rendimento nos modelos desenvolvidos. Estudos demonstram que a identificação e a avaliação da severidade de patógenos a nível de campo e laboratório, apresentam resultados satisfatórios e com alta precisão (Clohessy et al., 2021; Z. Guo et al., 2024; Wang et al., 2025). Esses achados devem diminuir a necessidade de um profissional especializado para conduzir experimento em campos, trazendo uma abordagem que potencializa a detecção de doenças de forma confiável com alta capacidade de implementação em diferentes interações de genótipo-ambiente (Clohessy et al., 2021).

Como já mencionado, o ML tem ganhado destaque no monitoramento do amendoim, possibilitando avanços em quase todas as etapas de manejo da cultura. Essa abordagem possibilita a identificação de padrões sutis que influenciam diretamente variáveis como, produtividade, maturação da vagem, e o vigor da planta. A detecção de doenças fúngicas explorando algoritmos como XGBoost, LightGBM, GBDT e CatBoost demonstram alta capacidade na identificação de sementes mofadas com alta eficiência (Wu et al., 2022).

Dos 40 artigos minuciosamente analisados, 32 trabalharam exclusivamente com ML, isso não necessariamente indica uma preferência neste tipo de técnica, mas sim, uma necessidade devido a maior simplicidade computacional e à eficiência desses algoritmos em trabalhar com conjuntos de dados moderados. Foi identificado neste estudo, que existe uma diferença significativa na quantidade de dados inseridos nos modelos (Souza et al., 2022; Jiang et al., 2024; Lavrinenko et al., 2022; Qi et al., 2021; Su et al., 2024). Algoritmos como RF, SVM e KNN, são menos exigentes em termos de recurso e demandam menos dados rotulados (Wu et al., 2022), o que é vantajoso em aplicações agrícolas, onde dados extensivos e detalhados nem sempre são fáceis de adquirir.

5.3. Pré-processamento e Qualidade dos Dados para Modelos de IA

O pré-processamento de dados é uma etapa fundamental no desenvolvimento de modelos de IA, especialmente em aplicações agrícolas que apresentam variabilidade acentuadas nos dados coletados em campo. Esta fase pode incluir uma série de técnicas para transformar os dados brutos em dados estruturados e confiáveis, o que facilita a

interpretação dos padrões, reduz o ruído nos dados e contribui para que o modelo não siga nenhum viés (Shahi et al., 2023). O pré-processamento pode envolver a normalização, padronização, remoção de outliers, tratamento de valores ausentes, e a seleção de variáveis. Um pré-processamento adequado pode reduzir significativamente o erro dos modelos, melhorar a acurácia e facilitar a generalização, tornando-os mais aplicáveis em diferentes manejos e condições de cultivo. A qualidade dos dados está diretamente relacionada com a fonte em que esses dados são extraídos, como calibração de sensores, efeitos atmosféricos, geometria das plantas, entre outros (Ram et al., 2024).

A redução de dimensionalidade e modelos que ajudem na seleção de variáveis preditivas é uma etapa realizada no pré-processamento dos dados. Entender qual variável entrada, melhor explica a variável dependente é primordial para que os algoritmos possam obter sucesso nas predições. Técnicas como, Filtragem Mediana (MF), Análise de Componentes Principais (PCA) e Aritmética ReliefF (AR) são utilizadas para diminuir a dimensionalidade e as características redundantes que podem apresentar multicolinearidade entre as variáveis preditivas, além de diminuir a demanda computacional para geração dos modelos (Sun et al., 2024; Wu et al., 2022; Xiong et al., 2024). Wu et al. (2022) observaram que o tempo de modelagem para as técnicas de machine learning foi melhorado em aproximadamente 0,8 segundos. Os autores avaliaram cinco algoritmos distintos e constataram que tanto o desempenho quanto a precisão dos modelos foram aprimorados quando o conjunto de dados de entrada era reduzido.

Um dos principais desafios no uso de CNN é a consistência e qualidade dos dados, tendo em vista que conjunto das informações adquiridas é crucial para o desempenho do modelo. Wang et al., (2025) relataram a possibilidade de uma rotulagem dos dados subjetiva, devido ao fato do método ser manual, o que poderia acarretar uma caracterização errônea de grãos saudáveis ou contaminados. Logo, tal discussão é recorrente, em que, pesquisadores atribuem o bom desempenho deste método a qualidade dos dados extraídos (Wang et al., 2025). Alguns estudos buscam alternativas para diminuir erros/viés que possam ser introduzidos pelos olhares humanos, trazendo especialistas para determinar o conjunto de dados de treinamento (Clohessy et al., 2021).

5.4. Desempenho dos Modelos

No desenvolvimento de modelos, as etapas de treinamento, validação e teste são essenciais para garantir a robustez e a precisão das predições ou estimativas,

especialmente em aplicações agrícolas, em que a variabilidade dos dados e as condições ambientais apresentam desafios únicos. O treinamento ajusta os parâmetros do modelo para identificar padrões nos dados de entrada, enquanto o teste avalia seu desempenho em dados independentes, não utilizados no treinamento. Essa abordagem permite verificar a capacidade do modelo de generalizar para novos cenários e evita o risco de overfitting, no qual o modelo se torna excessivamente ajustado aos dados de treinamento, comprometendo seu desempenho em aplicações futuras. Geralmente, o conjunto de dados é dividido aleatoriamente, com 50% a 80% destinados ao treinamento, enquanto o restante é usado para teste ou, em alguns casos, dividido entre validação e teste (Babanajad et al., 2017; Naser et al., 2012).

Apesar de amplamente empregada, a divisão dos dados carece de um método padronizado que leve em conta as características dos conjuntos de dados ou as particularidades dos algoritmos utilizados. Essa escolha, muitas vezes arbitrária, baseia-se em preferências do pesquisador, sem considerar a variabilidade dos dados ou a complexidade do problema. Portanto, há uma necessidade de estratégias fundamentadas e adaptativas, que considerem as propriedades intrínsecas dos dados e as especificidades dos modelos, para definir a divisão ideal e maximizar a eficácia dos sistemas preditivos em diferentes contextos.

A obtenção e construção de um modelo é uma tarefa crucial para que se tenha sucesso nas predições agrícolas. Existem diversas possibilidades de algoritmos, arquiteturas, hiperparâmetros e dados de treinamento (Heinrich et al., 2021). No entanto, existe ainda uma falta de critério para determinar qual a melhor forma para que um modelo seja construído levando em conta cada problema específico, pensando não só no desempenho e custo, mas também, a robustez do modelo. Logo, modelos que apresentam alta precisão e desempenho em um ambiente de laboratório ou em um conjunto de dados diferente, não necessariamente irá traduzir esse resultado em ambiente real, ou seja, uma condição de campo (Janiesch et al., 2021).

A avaliação do desempenho do modelo pode dar um direcionamento da eficácia do algoritmo para o objetivo proposto. Após o treinamento e validação do modelo é altamente generalizável, no entanto, o teste irá confirmar esta afirmação, verificando se realmente o modelo tornou-se generalizável ou memorizou apenas padrões, o que o torna superajustado (James et al., 2013; Hastie et al., 2009). O ideal é que os modelos apresentem bom desempenho em ambos os conjuntos, treinamento e teste, logo, para modelos de regressão, as métricas mais usuais para determinar o erro nas estimativas são

o erro quadrático médio (RMSE), erro médio absoluto (MAE) e o erro percentual absoluto médio (MAPE), enquanto para os modelos de classificação é calculado diferentes proporções de instancias prevista de erro e acertos, como recall, precisão, acurácia e pontuação F (Janiesch et al., 2021).

Na cultura do amendoim, onde fatores como variabilidade espacial, condições ambientais e práticas de manejo influenciam, como por exemplo, a maturação e a produtividade, a escolha adequada do método de treinamento e teste torna-se essencial para capturar essa complexidade de forma eficaz.

6. Limitações e Desafios

Embora a integração do SR e da IA tenha demonstrado grande potencial no monitoramento e manejo da cultura do amendoim, existem limitações e desafios que precisam ser superados para sua implementação plena em escala de campo. Essas limitações são inerentes tanto às características das ferramentas utilizadas quanto às condições práticas do ambiente agrícola.

Uma das principais limitações é a dependência de dados de alta qualidade para treinar modelos robustos. Dados coletados em campo muitas vezes apresentam ruídos ou erros, especialmente em função da alta variabilidade do campo e difícil controle de determinadas variáveis, além da infraestrutura limitada ou condições climáticas adversas. Além disso, essa variabilidade intrínseca dos sistemas agrícolas, incluindo a heterogeneidade do solo e mudanças climáticas, dificulta a generalização dos modelos preditivos para diferentes regiões e safras.

Outro desafio significativo está relacionado à compatibilidade entre diferentes plataformas e sensores. Sistemas de SR, tanto proximais quanto orbitais e aéreos, muitas vezes utilizam formatos de dados e padrões distintos, dificultando a integração e análise conjunta. Essa falta de padronização limita a capacidade de combinar informações de múltiplas fontes para gerar insights mais abrangentes e precisos. O custo das tecnologias, incluindo sensores proximais, ARPs, imagens orbitais de alta resolução e plataformas computacionais avançadas, é outra barreira à adoção em larga escala, especialmente para pequenos e médios produtores. Além disso, a implementação de sistemas baseados em inteligência artificial requer infraestrutura adequada, como acesso estável à internet, necessitando de uma boa conectividade no campo, além da capacidade de processamento de dados e mão de obra qualificada, condições que muitas vezes não estão disponíveis em áreas rurais.

Além das barreiras técnicas e econômicas, muitos produtores enfrentam dificuldades em acreditar no potencial transformador da agricultura digital. A resistência cultural e o desconhecimento técnico sobre como essas tecnologias podem impactar positivamente a produtividade e a sustentabilidade das operações agrícolas criam um cenário de hesitação. Essa falta de confiança, aliada à percepção de que os custos iniciais podem ser altos e os benefícios demorados, dificulta a adoção de inovações no manejo do amendoim.

Adicionalmente, a interpretação dos resultados gerados por essas tecnologias pode ser um desafio, especialmente quando se trata de traduzir informações complexas em recomendações práticas e acionáveis para o produtor. A falta de capacitação e conhecimento técnico no uso dessas ferramentas é uma barreira significativa, ressaltando a necessidade de treinamentos específicos e programas de extensão rural focados na adoção dessas inovações. Por fim, questões éticas e de segurança de dados emergem como desafios relevantes. A coleta e o armazenamento de dados agrícolas levantam preocupações sobre privacidade e o uso indevido das informações, especialmente em um cenário de agricultura cada vez mais digitalizada.

Superar essas limitações e desafios requer esforços colaborativos entre pesquisadores, desenvolvedores de tecnologia, formuladores de políticas públicas e produtores. A criação de políticas de incentivo, a democratização do acesso às tecnologias e o fortalecimento de parcerias público-privadas podem facilitar a adoção dessas ferramentas, garantindo que os avanços tecnológicos no manejo do amendoim sejam amplamente acessíveis e sustentáveis.

7. Perspectivas Futuras e Inovações

O avanço das técnicas de IA e SR integrando sensores proximais, aéreos e orbitais, deve abrir novas possibilidades para a aplicação prática em campo, especialmente no manejo da cultura do amendoim. Embora os estudos revisados tenham destacado o potencial dessas tecnologias no monitoramento e manejo da cultura, as perspectivas futuras se concentram em como essas ferramentas podem transformar práticas agrícolas diretamente no campo, promovendo decisões mais ágeis, precisas e economicamente vantajosas. Identificar a variabilidade da maturação e até mesmo da produtividade do amendoim, por exemplo, deve abrir portas para realização de uma colheita mais inteligente, em que, o produtor além de identificar o momento ideal de colher, pode direcionar regulagens em função no nível de maturação e da quantidade de vagens

produzidas, o que consequentemente aumentará a capacidade operacional e diminuirá as perdas na operação de colheita.

Pensando nisto, uma inovação promissora é a implementação de sistemas preditivos em tempo real que conectam dados de campo a plataformas de decisão. Esses sistemas podem ser integrados a sensores instalados em ARPs ou máquinas agrícolas, permitindo a identificação de melhores condições de colheita ou até mesmo cenários adversos, como estresse hídrico, em tempo hábil para intervenções localizadas e até infestação de pragas e doenças. A automação dessas respostas pode resultar em maior eficiência de tempo, uso de recursos e sustentabilidade ambiental.

Outro avanço em potencial está relacionado à personalização do manejo agrícola. Modelos baseados em aprendizado profundo podem processar grandes volumes de dados históricos e em tempo real para oferecer recomendações específicas a nível de talhão, considerando as particularidades centímetro a centímetro da lavoura. Essa abordagem possibilita o desenvolvimento de estratégias customizadas para a produtividade e a qualidade do amendoim. A criação de redes de sensores em campo, conectadas por meio de Internet das Coisas (IoT), é uma perspectiva inovadora que pode ampliar a coleta e o compartilhamento desses dados em diferentes porções da lavoura. Essa integração pode permitir o monitoramento contínuo de variáveis importantes, criando um panorama detalhado das condições da cultura ao longo do ciclo produtivo. O uso combinado dessas informações com algoritmos de aprendizado de máquina pode antecipar o rendimento e fornecer insights estratégicos para o planejamento no manejo do amendoim.

A longo prazo, a integração do SR e IA no contexto da AD pode evoluir para sistemas autônomos, capazes de executar tarefas como a semeadura, manejo nutricional, fitossanitário e colheita sem intervenção humana direta. Essa transição para a automação completa, alinhada ao uso de IA, não apenas otimizará as operações agrícolas, mas também poderá redefinir os limites do potencial produtivo da cultura do amendoim. Essas inovações, quando implementadas em escala de campo, pode potencializar e transformar o manejo da cultura, tornando-o mais dinâmico, responsivo e eficiente. O foco na aplicação prática e nos resultados tangíveis no campo fará com que essas tecnologias sejam integradas de forma efetiva à realidade do produtor, promovendo a sustentabilidade e o desenvolvimento tecnológico do amendoim.

8. Considerações Finais e Recomendações para o Avanço do Sensoriamento Remoto e IA no Manejo da Cultura do Amendoim

As tecnologias de SR e IA têm demonstrado potencial transformador no manejo do amendoim, mas sua aplicação plena depende de um alinhamento cuidadoso entre avanços científicos, viabilidade prática e integração no contexto agrícola. A revisão sistemática realizada indica que, embora a adoção dessas ferramentas esteja em ascensão, existem passos a serem seguidos para garantir e expandir sua aplicabilidade, visando melhorar sua eficiência e benefícios, para que sejam amplamente distribuídos.

Uma conclusão central é que o SR e a IA podem transcender o monitoramento pontual, permitindo a criação de sistemas de suporte à decisão mais dinâmicos e assertivos. Esses sistemas podem integrar informações em tempo real com dados históricos e previsões futuras, oferecendo aos produtores direcionamentos importantes e personalizados sobre o manejo da cultura, desde o plantio até a colheita. No entanto, para que essas tecnologias avancem de maneira impactante, é crucial promover esforços com colaboração conjunta entre especialistas das ciências agrárias, ciência de dados, engenharia e economia agrícola. Tal fato, é essencial para desenvolver soluções que sejam não apenas tecnicamente robustas, mas também acessíveis e adaptadas às condições do campo.

Do ponto de vista tecnológico, priorizar o desenvolvimento de algoritmos que sejam resilientes à variabilidade ambiental e à qualidade inconsistente dos dados agrícolas, será fundamental. Soluções que possam operar em contextos com infraestrutura limitada, como sistemas de aprendizado de máquina otimizados para dispositivos móveis ou locais, representam uma direção estratégica para aumentar o impacto dessas tecnologias e facilitar o uso no campo. Além disso, recomenda-se a ampliação de iniciativas que visem a padronização dos formatos e uso dos dados, além de protocolos de integração entre diferentes sensores e plataformas. Essa padronização pode acelerar a cooperação das ferramentas de sensoriamento remoto e IA permitindo uma utilização mais eficaz dos dados coletados em diferentes escalas e contextos.

Assim, conclui-se que o potencial dessas tecnologias será realizado não apenas pelo avanço técnico, mas também pela sua democratização e integração no cotidiano agrícola. Este movimento requer o envolvimento ativo de toda a cadeia de valor, desde pesquisadores até produtores, para garantir que as inovações contribuam efetivamente para o avanço do setor agrícola como um todo.

7. Referências

- Amaral, L. R., Molin, J. P., Portz, G., Finazzi, F. B., Cortinove, L. (2015). Comparison of crop canopy reflectance sensors used to identify sugarcane biomass and nitrogen status. *Precision Agriculture*, 16(1), 15–28. doi: 10.1007/s11119-014-9377-2.
- Babanajad, S. K., Gandomi, A. H., Alavi, A. H. (2017). New prediction models for concrete ultimate strength under true-triaxial stress states: An evolutionary approach. *Advances in Engineering Software*, 110, 55–68. <https://doi.org/10.1016/j.advengsoft.2017.03.011>
- Bagherian, K., Bidese-Puhl, R., Bao, Y., Zhang, Q., Sanz-Saez, A., Dang, P. M., Lamb, M. C., Chen, C. (2023). Phenotyping agronomic and physiological traits in peanut under mid-season drought stress using UAV-based hyperspectral imaging and machine learning. *The Plant Phenome Journal*, 6(1). <https://doi.org/10.1002/ppj2.20081>
- Bidese-Puhl, R., Butts, C. L., Rewis, M., McIntyre, J. S., Morris, J., Branch, B., Bao, Y. (2023). An mmWave radar-based mass flow sensor using machine learning towards a peanut yield monitor. *Computers and Electronics in Agriculture*, 215, 108340. <https://doi.org/10.1016/j.compag.2023.108340>
- Brandão, Z. N., Bezerra, M. V. C., Freire, E. C., Silva, B. B. (2008). Agricultura de precisão para gerenciamento do algodão. In: Azevêdo DMP, Beltrão NEM. *O agronegócio do algodão no Brasil*. Brasília: Embrapa Informação Tecnológica, 1309 p. cap. 20. v. 2.
- Chapu, I., Chandel, A., Sie, E., Okello, D., Oteng-Frimpong, R., Okello, R., Hoisington, D., Balota, M. (2024). Comparing Regression and Classification Models to Estimate Leaf Spot Disease in Peanut (*Arachis hypogaea* L.) for Implementation in Breeding Selection. *Agronomy*, 14(5), 947. <https://doi.org/10.3390/agronomy14050947>
- Chen, T., Yang, W., Zhang, H., Zhu, B., Zeng, R., Wang, X., Wang, S., Wang, L., Qi, H., Lan, Y., Zhang, L. (2020). Early detection of bacterial wilt in peanut plants through leaf-level hyperspectral and unmanned aerial vehicle data. *Computers and Electronics in Agriculture*, 177, 105708. <https://doi.org/10.1016/j.compag.2020.105708>
- Christopher M. Bishop. (2006). *Pattern Recognition and Machine Learning* (J. K. B. S. Michael Jordan, Ed.; Vol. 1). Springer Science+Business Media.
- Clohesy, J. W., Sanjel, S., O'Brien, G. K., Barocco, R., Kumar, S., Adkins, S., Tillman, B., Wright, D. L., Small, I. M. (2021). Development of a high-throughput plant disease symptom severity assessment tool using machine learning image analysis and

integrated geolocation. *Computers and Electronics in Agriculture*, 184. <https://doi.org/10.1016/j.compag.2021.106089>

Costa Souza, J. B., de Almeida, S. L. H., Oliveira, M. F., Santos, A. F., Brito Filho, A. L., Meneses, M. D., Silva, R. P. (2022). Integrating Satellite and UAV Data to Predict Peanut Maturity upon Artificial Neural Networks. *Agronomy*, 12(7), 1512. <https://doi.org/10.3390/agronomy12071512>

D. L. Rowland, R. B. Sorensen; C. L. Butts, W. H. Faircloth. (2006). Determination of Maturity and Degree Day Indices and their Success in Predicting Peanut Maturity. *Peanut Science*, 33(2), 125–136.

de Almeida, S. L. H., Costa Souza, J. B., Pilon, C., Teixeira, A. H. de C., Santos, A. F., Sysskind, M. N., Vellidis, G., Silva, R. P. (2023). Performance of the SAFER model in estimating peanut maturation. *European Journal of Agronomy*, 147, 126844. <https://doi.org/10.1016/j.eja.2023.126844>

Fonseca de Oliveira, G. R., Mastrangelo, C. B., Hirai, W. Y., Batista, T. B., Sudki, J. M., Petronilio, A. C. P., Crusciol, C. A. C., Amaral da Silva, E. A. (2022). An Approach Using Emerging Optical Technologies and Artificial Intelligence Brings New Markers to Evaluate Peanut Seed Quality. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.849986>

Fitzgerald, G., Rodriguez, D., O’Leary, G. (2010). Measuring and Predicting Canopy Nitrogen Nutrition in Wheat Using a Spectral Index—The Canopy Chlorophyll Content Index (CCCI). *Field Crops Res.* 2010, 116, 318–324. <https://doi.org/10.1016/j.fcr.2010.01.010>

Formaggio, A. R., Sanches, I. Del’Arco. (2017). *Sensoriamento remoto em agricultura*. Oficina de Textos.

Gareth James, D. W. T. H. R. T. (2013). *An Introduction to Statistical Learning* (Vol. 2).

Gitelson, A. A., Merzlyak, M. N. (1996). Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. *Journal of Plant Physiology*, v. 148, n. 3-4, p. 494-500. [https://doi.org/10.1016/S0176-1617\(96\)80284-7](https://doi.org/10.1016/S0176-1617(96)80284-7).

Gitelson, A. A., Viña, A., Arkebauer, T. J., Rundquist, D. C., Keydan, G., Leavitt, B. (2003). Remote estimation of leaf area index and green leaf biomass in maize canopies. *Geophysical Research Letters* 30:1248–1253. <https://doi.org/10.1029/2002GL016450>

Google Trends. (2025). *Sensoriamento Remoto*. Disponível em: <<https://trends.google.com.br/trends/>>. Acesso em 18 de jan. 2025.

Guan, Q., Song, K., Feng, S., Yu, F., Xu, T. (2022). Detection of Peanut Leaf Spot Disease Based on Leaf-, Plant-, and Field-Scale Hyperspectral Reflectance. *Remote Sensing*, 14(19), 4988. <https://doi.org/10.3390/rs14194988>

Guo, W., Gong, Z., Gao, C., Yue, J., Fu, Y., Sun, H., Zhang, H., Zhou, L. (2024). An accurate monitoring method of peanut southern blight using unmanned aerial vehicle remote sensing. *Precision Agriculture*, 25(4), 1857–1876. <https://doi.org/10.1007/s11119-024-10137-w>

Guo, W., Sun, H., Qiao, H., Zhang, H., Zhou, L., Dong, P., Song, X. (2023). Spectral Detection of Peanut Southern Blight Severity Based on Continuous Wavelet Transform and Machine Learning. *Agriculture*, 13(8), 1504. <https://doi.org/10.3390/agriculture13081504>

Guo, Z., Zhang, J., Wang, H., Li, S., Shao, X., Dong, H., Sun, J., Geng, L., Zhang, Q., Guo, Y., Sun, X., Xia, L., Darwish, I. A. (2024). Dual-aspect attention spatial-spectral transformer and hyperspectral imaging: A novel approach to detecting *Aspergillus flavus* contamination in peanut kernels. *Postharvest Biology and Technology*, 213, 112960. <https://doi.org/10.1016/j.postharvbio.2024.112960>

Heinrich, K., Zschech, P., Janiesch, C., Bonin, M. (2021). Process data properties matter: Introducing gated convolutional neural networks (GCNN) and key-value-predict attention networks (KVP) for next event prediction with deep learning. *Decision Support Systems*, 143, 113494. <https://doi.org/10.1016/j.dss.2021.113494>

Huete, A. R. (1998). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, v. 25, n. 3, p. 295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X).

Janiesch, C., Zschech, P., Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>

Jensen, J.R. (2009). *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. São José dos Campos: Parêntese, 598p.

Jiang, W., Wang, J., Lin, R., Chen, R., Chen, W., Xie, X., Hsiung, K.-L., Chen, H.-Y. (2024). Machine learning-based non-destructive terahertz detection of seed quality in peanut. *Food Chemistry: X*, 23, 101675. <https://doi.org/10.1016/j.fochx.2024.101675>

Julrat, S., Trabelsi, S. (2022). Determination of foreign-material content in uncleaned peanuts by microwave measurements and machine learning techniques. *Journal of Microwave Power and Electromagnetic Energy*, 56(1), 3–17. <https://doi.org/10.1080/08327823.2021.1993047>

Lavrinenko, I. A., Donskikh, A. O., Minakov, D. A., Sirota, A. A. (2022). Analysis and classification of peanuts with fungal diseases based on real-time spectral processing. *Food Additives & Contaminants: Part A*, 39(5), 990–1000. <https://doi.org/10.1080/19440049.2021.2017001>

Lin, Y., Chen, T., Liu, S., Cai, Y., Shi, H., Zheng, D., Lan, Y., Yue, X., Zhang, L. (2022). Quick and accurate monitoring peanut seedlings emergence rate through UAV video and deep learning. *Computers and Electronics in Agriculture*, 197, 106938. <https://doi.org/10.1016/j.compag.2022.106938>

Lin, Y., Wang, L., Chen, T., Liu, Y., Zhang, L. (2024). Monitoring system for peanut leaf disease based on a lightweight deep learning model. *Computers and Electronics in Agriculture*, 222, 109055. <https://doi.org/10.1016/j.compag.2024.109055>

Manhando, E., Zhou, Y., Wang, F. (2021). Early Detection of Mold-Contaminated Peanuts Using Machine Learning and Deep Features Based on Optical Coherence Tomography. *AgriEngineering*, 3(3), 703–715. <https://doi.org/10.3390/agriengineering3030045>

Molin, J. P., Amaral, L. R. do, Colaço, A. (2015). *Agricultura de precisão*. Oficina de textos.

Moreira, M. A. (2011). *Fundamentos do sensoriamento remoto e metodologias de aplicação*. Editora UFV.

Morlin Carneiro, F., Angeli Furlani, C. E., Zerbato, C., Candida de Menezes, P., da Silva Gírio, L. A., Freire de Oliveira, M. (2020). Comparison between vegetation indices for detecting spatial and temporal variabilities in soybean crop using canopy sensors. *Precision Agriculture*, 21, 979-1007. <https://doi.org/10.1007/s11119-019-09704-3>

Murad, M. H., Asi, N., Alsawas, M., & Alahdab, F. (2016). New evidence pyramid. *BMJ Evidence-Based Medicine*, 21(4), 125-127.

Naser, M., Abu-Lebdeh, G., Hawileh, R. (2012). Analysis of RC T-beams strengthened with CFRP plates under fire loading using ANN. *Construction and Building Materials*, 37, 301–309. <https://doi.org/10.1016/j.conbuildmat.2012.07.001>

Novo, E. M. L. de M. (2010). *Sensoriamento Remoto: princípios e aplicações*. Editora Blucher.

Oliveira, M. F., Carneiro, F. M., Ortiz, B. V., Thurmond, M., Oliveira, L. P., Bao, Y., Sanz-Saez, A., Tedesco, D. (2024). Predicting below and above-ground peanut biomass

and maturity using multi-target regression. *Computers and Electronics in Agriculture*, 218, 108647. <https://doi.org/10.1016/j.compag.2024.108647>

Page, Matthew J. et al. *The PRISMA 2020 statement: an updated guideline for reporting systematic reviews*. BMJ, [S. l.], v. 372, n. 71, p. n71, 2021. Disponível em: <https://doi.org/10.1136/bmj.n71>.

Pinto, J., Powell, S., Peterson, R., Rosalen, D., Fernandes, O. (2020). Detection of Defoliation Injury in Peanut with Hyperspectral Proximal Remote Sensing. *Remote Sensing*, 12(22), 3828. <https://doi.org/10.3390/rs12223828>

Pugh, N. A., Young, A., Ojha, M., Emendack, Y., Sanchez, J., Xin, Z., Puppala, N. (2024). Yield prediction in a peanut breeding program using remote sensing data and machine learning algorithms. *Frontiers in Plant Science*, 15. <https://doi.org/10.3389/fpls.2024.1339864>

Qi, H., Liang, Y., Ding, Q., Zou, J. (2021). Automatic Identification of Peanut-Leaf Diseases Based on Stack Ensemble. *Applied Sciences*, 11(4), 1950. <https://doi.org/10.3390/app11041950>

Qi, H., Zhu, B., Wu, Z., Liang, Y., Li, J., Wang, L., Chen, T., Lan, Y., Zhang, L. (2020). Estimation of Peanut Leaf Area Index from Unmanned Aerial Vehicle Multispectral Images. *Sensors*, 20(23), 6732. <https://doi.org/10.3390/s20236732>

Qiao, D., Yang, J., Bai, B., Li, G., Wang, J., Li, Z., Liu, J., Liu, J. (2024). Non-Destructive Monitoring of Peanut Leaf Area Index by Combing UAV Spectral and Textural Characteristics. *Remote Sensing*, 16(12), 2182. <https://doi.org/10.3390/rs16122182>

Queiroz, D. M. de, Valente, D. S. M., de Carvalho Pinto, F. D. A., Borém, A. (Eds.). (2022). *Agricultura digital*. Oficina de Textos.

Rajabi-Sarkhani, M., Abbaspour-Gilandeh, Y., Moinfar, A., Tahmasebi, M., Martínez-Arroyo, M., Hernández-Hernández, M., Hernández-Hernández, J. L. (2023). Identifying Optimal Wavelengths from Visible–Near-Infrared Spectroscopy Using Metaheuristic Algorithms to Assess Peanut Seed Viability. *Agronomy*, 13(12), 2939. <https://doi.org/10.3390/agronomy13122939>

Ram, B. G., Oduor, P., Igathinathane, C., Howatt, K., Sun, X. (2024). A systematic review of hyperspectral imaging in precision agriculture: Analysis of its current state and future prospects. *Computers and Electronics in Agriculture*, 222, 109037. <https://doi.org/10.1016/j.compag.2024.109037>

Rene Y. Choi^{1, *}, Aaron S. Coyner^{2, *}, Jayashree Kalpathy-Cramer³, Michael F. Chiang^{1, 2}, and J. Peter Campbell. (2020). Introduction to Machine Learning, Neural Networks, and Deep Learning. *Trans Vis Sci Tech*, 9(2).

Santos, A. F., Corrêa, L. N., Lacerda, L. N., Tedesco, D., Pilon, C., Vellidis, G., Silva, R. P. (2021). High-resolution satellite image to predict peanut maturity variability in commercial fields. *Precision Agriculture*, 22(5), 1464–1478. <https://doi.org/10.1007/s11119-021-09791-1>

Santos, A. F., Lacerda, L. N., Rossi, C., Moreno, L. de A., Oliveira, M. F., Pilon, C., Silva, R. P., Vellidis, G. (2021). Using UAV and Multispectral Images to Estimate Peanut Maturity Variability on Irrigated and Rainfed Fields Applying Linear Models and Artificial Neural Networks. *Remote Sensing*, 14(1), 93. <https://doi.org/10.3390/rs14010093>

Sarkar, S., Ramsey, A. F., Cazenave, A.-B., Balota, M. (2021). Peanut Leaf Wilting Estimation From RGB Color Indices and Logistic Models. *Frontiers in Plant Science*, 12. <https://doi.org/10.3389/fpls.2021.658621>

Shahi, T. B., Xu, C.-Y., Neupane, A., Fleischfresser, D. B., O'Connor, D. J., Wright, G. C., Guo, W. (2023). Peanut yield prediction with UAV multispectral imagery using a cooperative machine learning approach. *Electronic Research Archive*, 31(6), 3343–3361. <https://doi.org/10.3934/ERA.2023169>

Sharma, N., Sharma, R., Jindal, N. (2021). Machine Learning and Deep Learning Applications-A Vision. *Global Transitions Proceedings*, 2(1), 24–28. <https://doi.org/10.1016/j.gltp.2021.01.004>

Shiratsuchi, L. S., Brandão, Z. N., Vicente, L. E., Victoria, D. C., Ducati, J. R., Oliveira, R. P., Vilela, M. F. (2014). Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. In: Bernardi, A. C. C., Naime, J. M., Resende, A. V., Bassoi, L. H., Inamasu, R. Y. (2014). *Agricultura de precisão: resultados de um novo olhar*. Brasília: EMBRAPA. Cap. 4. p.58-73.

Shiratsuchi, L. S., Carneiro, F. M., Ferreira, F. M., Lanza, P., Rontani, F. A., Brito Filho, A. L. de, Seben Junior, G. F., Brandão, Z.N., Silva Junior, C. A., Teodoro, P. E., Dodla, S. (2023). Using remote and proximal sensor data in precision agriculture applications. In: Lobsey, C., Biswas, A. (2023). *Advances in sensor technology for sustainable crop production*. Burleigh Dodds: Science Publishing. Cap. 11. p. 1-26.

Su, T., Liu, X., Lei, B., Cao, Z., Di, J., Xu, L., Cui, X. (2024). Screening the characteristic hyperspectral wavelength variables of peanut leaves based on coupled

algorithms to predict SPAD value in peanut. *International Journal of Remote Sensing*, 1–21. <https://doi.org/10.1080/01431161.2024.2399332>

Sudki, J. M., Fonseca de Oliveira, G. R., de Medeiros, A. D., Mastrangelo, T., Arthur, V., Amaral da Silva, E. A., Mastrangelo, C. B. (2023). Fungal identification in peanuts seeds through multispectral images: Technological advances to enhance sanitary quality. *Frontiers in Plant Science*, 14. <https://doi.org/10.3389/fpls.2023.1112916>

Sun, H., Zhou, L., Shu, M., Zhang, J., Feng, Z., Feng, H., Song, X., Yue, J., Guo, W. (2024). Estimation of Peanut Southern Blight Severity in Hyperspectral Data Using the Synthetic Minority Oversampling Technique and Fractional-Order Differentiation. *Agriculture*, 14(3), 476. <https://doi.org/10.3390/agriculture14030476>

Taiz, L., Zeiger, E. (2013). *Fisiologia Vegetal*. 5th ed. Artmed: Porto Alegre, 918p.

Trevor Hastie, R. T. J. F. (2009). *The Elements of Statistical Learning* (Vol. 2).

Wang, C., Zhu, H., Zhao, Y., Shi, W., Fu, H., Zhao, Y., Han, Z. (2025). A multi-verse optimizer-based CNN-BiLSTM pixel-level detection model for peanut aflatoxins. *Food Chemistry*, 463, 141393. <https://doi.org/10.1016/j.foodchem.2024.141393>

Wei, X., Johnson, M. A., Langston, D. B., Mehl, H. L., Li, S. (2021). Identifying Optimal Wavelengths as Disease Signatures Using Hyperspectral Sensor and Machine Learning. *Remote Sensing*, 13(14), 2833. <https://doi.org/10.3390/rs13142833>

Wu, Q., Xu, L., Zou, Z., Wang, J., Zeng, Q., Wang, Q., Zhen, J., Wang, Y., Zhao, Y., Zhou, M. (2022). Rapid nondestructive detection of peanut varieties and peanut mildew based on hyperspectral imaging and stacked machine learning models. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.1047479>

Xiong, Z., Liu, S., Tan, J., Huang, Z., Li, X., Zhuang, G., Fang, Z., Chen, T., Zhang, L. (2024). Combining Hyperspectral Techniques and Genome-Wide Association Studies to Predict Peanut Seed Vigor and Explore Associated Genetic Loci. *International Journal of Molecular Sciences*, 25(15). <https://doi.org/10.3390/ijms25158414>

Zhongzhi, H., Limiao, D. (2020). Aflatoxin contaminated degree detection by hyperspectral data using band index. *Food and Chemical Toxicology*, 137. <https://doi.org/10.1016/j.fct.2020.111159>

Ziyaee, P., Farzand Ahmadi, V., Bazyar, P., Cavallo, E. (2021). Comparison of Different Image Processing Methods for Segregation of Peanut (*Arachis hypogaea* L.) Seeds Infected by Aflatoxin-Producing Fungi. *Agronomy*, 11(5), 873. <https://doi.org/10.3390/agronomy11050873>

Zou, Z., Chen, J., Wang, L., Wu, W., Yu, T., Wang, Y., Zhao, Y., Huang, P., Liu, B., Zhou, M., Lin, P., Xu, L. (2022). Nondestructive detection of peanuts mildew based on hyperspectral image technology and machine learning algorithm. *Food Science and Technology*, 42. <https://doi.org/10.1590/fst.71322>

CAPÍTULO 3 – GENERALIZAÇÃO DE MODELOS DE PREDIÇÃO DA PRODUTIVIDADE DO AMENDOIM USANDO REDES NEURAIS ARTIFICIAIS E ÍNDICES DE VEGETAÇÃO²

Resumo: A predição da produtividade de culturas é vital para o gerenciamento e auxílio à tomada de decisão dos processos agrícolas. O uso de técnicas como o Sensoriamento Remoto (SR) e Redes Neurais Artificiais (RNA) surgem como ferramentas potenciais na predição destes parâmetros agrônômicos. Diante disto, objetivou-se combinar dados de SR em modelos de RNA para acessar a produtividade de amendoim de forma remota e antecipada. O experimento foi conduzido em onze campos comerciais, divididas em seis campos na safra 2020/21 e cinco na safra 2021/22. Os dados de entrada dos modelos testados foram índices de vegetação (EVI, GNDVI, MNLI, NLI, NDVI, SAVI E SR) provenientes de imagens de satélite de alta resolução em cinco datas, sendo essas baixadas antes de trinta dias para o início da colheita do amendoim. Os índices de vegetação (IV) provenientes da safra 20/21 foram inseridos nas RNA do tipo Perceptron Multicamadas (MLP) e Função de Base Radial (RBF) para etapa de calibração. Posteriormente, as equações geradas foram aplicadas nas áreas da safra subsequente para validação, e recalibração dos modelos utilizando o conjunto de dados das duas safras. As duas redes se mostraram capazes de fazer predições utilizando os IVs como entrada nos modelos, tanto na calibração como na recalibração, onde foi observado melhora na precisão e acurácia dos modelos. A validação dos modelos demonstrou alto potencial na generalização da variabilidade da produtividade do amendoim em novas áreas. A rede MLP apresentou os melhores resultados neste estudo com MAPE aos 30 dias antes da colheita de 9,3% e coeficiente de determinação de 0,80. Os IVs que mais destacaram-se como entrada nos modelos foram o EVI, SAVI e SR. O uso do SR combinado com as RNA é um ferramenta poderosa para predizer a produtividade do amendoim e auxiliar o produtor na gestão da lavoura.

² Artigo publicado na Smart Agricultural Technology (IF: 6.3; CiteScore: 4.2).

Palavras-Chaves: Inteligência Artificial, Agricultura Digital, Índices de Vegetação, Validação de Modelos, Perceptron Multicamadas, Função de Base Radial.

Abreviações e Nomenclatura

SR: Sensoriamento Remoto; RNA: Redes Neurais Artificiais; IV: Índices de Vegetação; RBF: Função de Base Radial; MLP: Perceptron Multicamadas; RPA: Aeronave Remotamente Pilotada; GNSS: Sistema Global de Navegação de Satélite; GPS: Global positioning System; GLONASS: Global'naya Navigatsionnaya Sputnikovaya Sistema; BeiDou: Beidou Navigation Satellite System; DPC: Dias para Colheita; PS: PlanetScope; TOA: Refletância no topo da atmosfera; BOA: Refletância de Fundo da Atmosfera; NDVI: Índice de Vegetação por Diferença Normalizada; GNDVI: Índice de Vegetação por Diferença Normalizada Verde; MNLI: Índice Não Linear Modificado; EVI: Índice de Vegetação Aprimorado; NLI: Índice Não Linear; SAVI: Índice de Vegetação Ajustado; SR: Razão Simples; IPS: Intelligent Problem Solver; REM: Run Existing Model; MAE: Erro Médio Absoluto; MAPE: Erro Percentual Absoluto Médio; R^2 : Coeficiente de Determinação; IQRs Interquartis;

1. Introdução

A predição da produtividade de culturas agrícolas é de suma importância para planejamento e gestão das lavouras, auxiliando produtores, cooperativas e especialistas na tomada de decisão para otimizar práticas agrícolas (Sadenova et al., 2023). Para a cultura do amendoim, em específico, que apresenta características de crescimento indeterminado e desenvolvimento dos frutos abaixo do solo, fazer entender a dinâmica e variabilidade, torna-se um desafio (Souza et al., 2022). Isso porque as predições tradicionais de produtividade do amendoim são realizadas a partir de visitas de técnicos aos campos de produção, o que configura a estimativa como um método demorado, exaustivos e não representa a variabilidade da área, resultando em informações de valores médio. Logo, desenvolver modelos de predições confiáveis com base em imagens de satélite e inteligência artificial pode ajudar a explicar a variabilidade na produtividade de lavouras amendoim e ser uma alternativa interessante para toda a cadeia de produção da cultura.

Técnicas de análise de dados como RNA associadas ao SR tem sido empregado com sucesso em diversas culturas para estimativa de produtividade, tais como milho, soja,

trigo e arroz, (Farjam et al., 2014; Khalifani et al., 2022; Niedbala, 2019; Sadenova et al., 2023). Na maioria das vezes a associação dessas técnicas para estimativa de produtividade os dados de entrada comumente utilizados são os Índices de Vegetação (IV's) (Son et al., 2014; Taşan et al., 2022), que por sua vez, apresentam elevado potencial para explicar a variabilidade na produtividade das culturas em campo de forma remota (Shammi & Meng, 2021). Essa performance das RNA e IV juntas pode ser explicada devido a capacidade de modelar relações complexas entre as variáveis de IVs e produtividade. Apesar disso, alguns estudos sugerem o uso de IVs com outras variáveis independentes, como dados meteorológicos, atributos de solo e parâmetros biofísicos da cultura (Zhang et al., 2021; Desloires et al., 2023; Schwalbert et al., 2020).

Entre os diversos algoritmos de aprendizagem de máquina e métodos de RNA, os mais utilizados são a Função de Base Radial (RBF) e Perceptron Multicamadas (MLP) (Mokarram & Bijanzadeh 2016). O uso destas redes para predição de produtividade de culturas agrícolas tem sido recorrente e os resultados obtidos são satisfatórios (Khalifani et al., 2022; Taki et al., 2018). Nas condições de cultivo do Brasil, trabalhos utilizando estas RNAs já foram desenvolvidos para gerar modelos preditivos de parâmetros agronômicos em culturas como café (Oliveira et al., 2021). As redes MLP e RBF são cruciais para resolver problemas complexos, com a MLP aprendendo através de múltiplas camadas e a RBF se ajustando aos dados de forma não linear, oferecendo flexibilidade em análises específicas.

Em estudos anteriores, uma lacuna notável é a falta de validação dos modelos preditivos desenvolvidos, particularmente a generalização das equações propostas para novas áreas. Diante disto, a aplicabilidade destes modelos em contextos variados, incluindo áreas com distintas práticas de manejo, em anos com diferentes padrões climáticos e cultivares, permanece uma questão aberta. Esta validação é crucial para avaliar a repetibilidade e a eficácia dos modelos no que tange à previsão de produtividade. Adicionalmente, compreender o impacto do aumento do conjunto de dados reais adquiridos em campo nos modelos preditivos é crucial. Isso pode ajudar a entender sobre a importância da recalibração periódica dos modelos para melhorar sua precisão e acurácia.

Nesse contexto, a combinação de IVs com RNAs apresentam-se como ferramenta promissora para prever a produtividade do amendoim. Além disso, os modelos desenvolvidos a partir desta abordagem demonstram ser capazes de generalizar a variabilidade da produtividade em diferentes condições de campo. Isso permitiria que

ferramentas de auxílio a tomada de decisão fossem mais efetivas, principalmente relacionadas a pré-colheita e colheita, o que aumenta a segurança dos produtores ao otimizar seu planejamento estratégico. Logo, este trabalho tem como objetivos: 1) prever a produtividade do amendoim precocemente em relação à colheita, utilizando índices de vegetação extraídos de imagens obtidas de satélite por meio dos algoritmos MLP e RBF; 2) Determinar qual algoritmo apresenta melhor potencial para generalizar a variabilidade da produtividade do amendoim; 3) Gerar a calibração, validação e recalibração dos modelos a partir de índices de vegetação.

2. Material e Métodos

Os experimentos foram conduzidos em 11 áreas comerciais de produção de amendoim localizadas na região da Alta Mogiana, no estado de São Paulo, Brasil, durante duas safras (2020/2021 e 2021/2022), em ambientes favoráveis à produção de amendoim. As áreas experimentais foram selecionadas, considerando áreas com características de solos (ROSSI, 2017) e cultivares distintas. A descrição das áreas e suas características são apresentadas na Tabela 3.1.

Tabela 3.1 Informações sobre as áreas de estudo para as duas Safras.

Season 2020/2021					
Área	Local	Cultivar	Solo	Área (hectare)	Ciclo (dias)
1	Ibitinga	IAC OL3	Latossolos Vermelho Distróficos	8	120
2	Pradópolis	IAC OL3	Latossolos Vermelho Distroferricos	11	120
3	Santa Ernestina 1	IAC OL3	Latossolos Vermelho Distróficos	8,1	120
4	Taiuva 1	IAC OL3	Argissolos Vermelho Eutróficos	10	120
5	Monte Alto 1	IAC OL3	Argissolos Vermelho Eutróficos	10,5	120
6	Monte Alto 2	IAC OL3	Argissolos Vermelho Eutróficos	10,2	120
Season 2021/2022					
7	Taiuva 2	IAC OL3	Latossolos Vermelho Distroficos	8	120
8	Santa Ernestina 2	IAC OL3	Latossolos Vermelho Distroficos	8,8	120
9	Guariba	IAC 503	Latossolos Vermelho Distroficos	8,7	150
10	Jaboticabal	IAC 503	Latossolos Vermelho Distroferricos	8,1	150
11	Taquaritinga	IAC 503	Argissolos Vermelho Eutróficos	10,2	150

Para a safra 2020/2021, o experimento foi implementado em áreas com 20 pontos de coletas, equidistantes entre si em 50 metros em sistema em faixa. Na safra seguinte, as

amostras foram coletadas em 30 pontos, também equidistantes em 50 (Figura 3.1). A primeira safra gerou um banco de dados de produtividade de 120 pontos, enquanto a segunda safra apresentou 150 pontos de produtividade coletados.

Os pontos coletados em campos foram georreferenciados utilizando uma Aeronave Remotamente Pilotada (RPA) multirrotor da DJI, P4 Multispectral (Shenzhen, China), operado automaticamente via aplicativo DJ Ground Station Pro. Esse RPA possui um receptor de Sistema Global de Navegação de Satélite (GNSS) de multifrequência capaz de receber sinais de constelações como Global positioning System (GPS), Global'naya Navigatsionnaya Sputnikovaya Sistema (GLONASS), Beidou Navigation Satellite System (BeiDou) e Galileo, garantindo precisão posicional horizontal ($1\text{ cm} + 1\text{ ppm}$) e vertical ($2\text{ cm} + 1\text{ ppm}$) centimétrica (DJI D-RTK2, Shenzhen, China). Os voos foram realizados a uma altura de 90 m, com pontos de referência marcados no campo utilizando cal e bandeiras para facilitar a identificação nas imagens e a coleta de dados em campo. As coordenadas desses pontos foram extraídas do ortomosaico gerado e associadas às imagens de satélite. No software QGIS, foi aplicado um buffer de 3 m ao redor de cada ponto de referência para a extração da reflectância. Os IVs foram calculados com base nos dados de reflectância dos buffers correspondentes às localidades onde a produtividade foi medida.




Figura 3.1 Localização das áreas experimentais para a safra 2020/2021 e 2021/2022.

A determinação da produtividade do amendoim foi realizada um dia antes do arranquio mecanizado. Para isso, em cada área, foram coletadas todas as plantas presentes em uma armação de 2 m² em cada ponto amostral. As vagens desprendidas naturalmente localizadas abaixo e acima do solo foram descartadas. A coleta foi feita manualmente em

cada parcela. Posteriormente, procedeu-se à trilha manual e à limpeza do material, removendo impurezas como torrões, folhas e ramos. as amostras foram colocadas em estufa a 105 °C por 24 horas até atingirem massa constante para então, determinar o peso seco das vagens. Isso permitiu calcular a produtividade em kg ha⁻¹ com os valores sendo ajustados para a umidade de 8% (Figura 3.2).




Figura 2. Esquema representativo da metodologia.

2.3. Aquisição de Imagens de Satélite

O monitoramento das áreas via satélite obedeceu ao intervalo de 30 dias anteriores à data de colheita do amendoim, totalizando 5 datas: 30, 20, 14, 8 e 1 dias para colheita (DPC). As imagens de satélite utilizadas foram fornecidas pelo sensor da plataforma CubeSat PlanetScope (PS). A constelação do PS, atualmente com mais de 180 nanossatélites em órbita solar, é capaz de capturar imagens diárias, apresentando uma resolução espacial de 3 metros e abrangendo oito bandas espectrais, no entanto, para este estudo foram utilizadas somente as imagens PS com quatro bandas: Azul (455-515nm), Verde (500-590 nm), Vermelho (590-670 nm) e Infravermelho Próximo (780-860 nm).

A correção das imagens de satélite foi feita com o uso do produto Surface Reflectance do PlanetScope, que proporciona consistência às condições atmosféricas locais e diminui a incerteza na resposta espectral. As correções, aplicáveis a todas as cenas ortorretificadas, baseiam-se na refletância no topo da atmosfera (TOA), usando coeficientes do produto Planet Radiance. A refletância de superfície é calculada para cada

pixel utilizando Tabelas de Pesquisa (LUTs) do código 6SV2.1, que correlacionam a refletância no TOA com a Refletância de Fundo da Atmosfera (BOA) (Planet 2019).

Índices de Vegetação foram selecionados com base em evidências literárias que demonstraram sua capacidade de prever a maturação do amendoim e a produtividade de diversas culturas agrícolas, incluindo, trigo, milho, feijão, batata-doce, arroz e soja (Basso & Liu, 2019; Filla et al., 2023; Sadenova et al., 2023; Santos et al., 2022; Schwalbert et al., 2020; Souza et al., 2022; Tedesco et al., 2021; Zhou et al., 2023). Quase todas estas culturas apresentam características fenotípicas análogas ao amendoim. A semelhança na estrutura entre o amendoim e outras culturas indica que os índices de vegetação são amplamente aplicáveis para prever a produtividade do amendoim, destacando a importância da escolha destes IVs neste estudo (Tabela 2).

Tabela 3.2 Índices de Vegetação utilizados como entrada nos modelos preditivos.

IV *	Equação	Referência
NDVI	$\frac{NIR - Red}{NIR + Red}$	Rouse et al., (1974)
GNDVI	$\frac{NIR - Green}{NIR + Green}$	Gitelson e Merzlyak., (1996)
MNLI	$\frac{(NIR^2 - Red)(1 + L^{**})}{(NIR^2 + Red + L^{**})}$	Gong et al., (2003)
EVI	$\frac{2.5(NIR - Red)}{(L^{**} + NIR + C1Red - C2Blue)}$	Justice et al., (1998)
NLI	$\frac{NIR^2 - Red}{NIR^2 + Red}$	Goel and Qin., (1994)
SR	$\frac{NIR}{Red}$	Jordan., (1969)
SAVI	$\frac{(1 + L^{**})(NIR - Red)}{(L^{**} + NIR + Red)}$	Huete., (1988)

NDVI: Índice de Vegetação por Diferença Normalizada; GNDVI: Índice de Vegetação por Diferença Normalizada Verde; MNLI: Índice Não Linear Modificado; EVI: Índice de Vegetação Aprimorado; NLI: Índice Não Linear; SAVI: Índice de Vegetação Ajustado; SR: Razão Simples; *IV = Índice de Vegetação **L = 0,5; C1 = 6; C2 = 7,5.

2.4. Análise de Dados

Em nosso estudo, utilizamos a análise do Diagrama de Caixa (boxplot) para visualizar o comportamento e distribuição dos dados. Essa técnica é eficaz para identificar

medanas, quartis e potenciais outliers, em que, foi realizado a filtragem destes pontos discrepantes de produtividade. Os Boxplots foram gerados para a produtividade de cada área de interesse, permitindo uma comparação direta entre diferentes campos.

Os modelos de predição da produtividade do amendoim foram desenvolvidos utilizando o pacote StatSoft Statistica 7 (Statistica 7.0 Statsoft Inc. Tulsa) empregando dois algoritmos de RNAs, a Perceptron Multicamadas (MLP) e a Função de Base Radial (RBF).

Os dados de entrada foram os sete IVs anteriormente mencionados, para prever a variável dependente (produtividade). Inicialmente, na safra 2020/2021, foram realizados o treinamento e teste com as 120 amostras coletadas de produtividade em diferentes campos, que foram utilizadas para desenvolver modelos de predições (calibração dos modelos), em cinco datas que antecederam a colheita. Posteriormente, estas equações foram aplicadas em cinco novas áreas da safra subsequente para validação dos modelos. Foram considerados apenas modelos com erros inferiores a 1.000 kg ha^{-1} , pois estimativas acima desse valor são consideradas elevadas. Este limite foi definido com base em discussões com cooperativas, onde técnicos relataram erros similares em suas estimativas visuais. Por fim, foi realizado uma recalibração utilizando todo o conjunto de dados coletados em campo de ambas as safras, totalizando 270 amostras de produtividade para entender como a ampliação dos dados influência no desempenho dos modelos.

Em ambos os modelos desenvolvidos (calibração e recalibração) o banco de dados foi dividido em 80% para treinamento e 20% para teste. Os procedimentos realizados neste processo, foi implementado pelo pacote Neural Network do software Statistica 7. Durante a fase de treinamento e teste, as RNAs foram treinadas 3.000 vezes retendo os dez melhores modelos, cinco para MLP e cinco para RBF. O número de neurônios variou de 1 a 20 para ambos os algoritmos, enquanto o número de camada oculta para a rede MLP foi de 1 a 3. A estrutura das redes selecionadas encontra-se no material suplementar.

Escolhas como a arquitetura da rede neural, ajuste de parâmetros e algoritmo de treinamento, podem tornar o processo demorado, diante disto, a ferramenta Intelligent Problem Solver (IPS) otimiza o desenvolvimento dos modelos, evitando uma abordagem de tentativa e erro na determinação destas operações, trazendo uma abordagem de combinação heurística para acelerar a identificação da melhor topologia. A ferramenta IPS trouxe resultados da análise de sensibilidade dos modelos, que evidencia a influência das variáveis de entrada no desempenho dos modelos.

No que diz respeito a validação dos modelos, utilizou-se a ferramenta Run Existing Model (REM), que permite a utilização de equações previamente treinadas e salvas, eliminando a necessidade de repetir o processo de treinamento, podendo ser aplicado em predições em um conjunto de dados e campos diferente. A eficiência das RNAs foi analisada usando gráficos de desempenho com proporção de 1:1, em que, a precisão e acurácia e foram avaliadas usando o erro médio absoluto (MAE) e o erro percentual absoluto médio (MAPE) para o erro de predição, e o coeficiente de determinação (R^2) para precisão dos modelos, conforme as equações (1), (2) e (3), respectivamente.

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

$$MAPE = \frac{\sum_{i=1}^n (|\frac{Y_i - \bar{Y}_i}{\bar{Y}_i}| * 100)}{n} \quad (2)$$

Em que, n é o número de dados, Y_i são o valor da variável observada em campo e $\bar{Y}_i$ são o valor, da variável predita.

$$R^2 = \frac{SQR}{SQT} \quad (3)$$

Em que, SQR é a soma dos quadrados do resíduo e SQT é a soma dos quadrados totais.

3. RESULTADOS

3.1. Análise Exploratória dos Dados de Produtividade

Para os campos 2 e 3 é possível observar pouca diferença entre as produtividades média na análise exploratória dos dados (Figura 3.3). Já o campo 1 demonstrou média menor neste tipo de solo com diferença de aproximadamente 1000 kg ha⁻¹. A variabilidade da produtividade é maior nesses campos, como indicado pelos interquartis (IQRs) mais longos e pelos limites (máximos e mínimos) relativamente maiores, especialmente no campo 2 que apresentou maior variância.

Os campos 4, 5 e 6, representados em vermelho, demonstram produtividade média semelhantes quando comparados com os latossolos. No entanto, o campo 6 se destaca apresentando a maior média (7229,34 kg ha⁻¹) e mediana (7234,75 kg ha⁻¹) entre todos os campos da primeira safra. A variabilidade da produtividade é mais evidenciada para o

campo 5, como pode ser observado pelos IQRs maiores com valores de máximo de 7826,70 kg ha⁻¹ e mínimo de 3577,44 kg ha⁻¹.

Na Figura 3B temos cinco boxplots correspondentes aos campos 7 a 11 com as áreas sendo definidas a partir dos tipos de cultivar (IAC OL3 e IAC 503) e tipo de solo distinto, em que as duas primeiras caixas verdes representam a cultivar IAC OL3, e as três últimas representam a cultivar IAC 503 com a caixa marrom sendo solo argiloso. Para cultivar IAC OL3 observou-se as maiores médias e mediana de produtividade, com o campo 8 apresentando média de produtividade de 7313,98 kg ha⁻¹. Os limites máximos e mínimos do campo 9 sugerem a maior variabilidade na produtividade.

Para a Cultivar IAC 503, o IQR foi semelhante para os campos 10 e 11, assim como a variância e a produtividade média foi a menor em comparação com o campo 9. Foi observado para o campo 11, a menor produtividade média e mediana entre todos os campos 4344,68 kg ha⁻¹ e 4062,40 kg ha⁻¹, respectivamente. Tal resultado foi desencadeado devido à falta de controle na rebrota de cana de açúcar na área, o que causou competição entre as espécies culminando na diminuição da produtividade deste campo. Isso pode explicar o motivo dos latossolos terem se sobressaindo na média de produtividade. O campo 9 apresentou a maior variabilidade e a segunda maior produtividade média desta safra.




Figura 3.3 Análise exploratória da produtividade de amendoim nas safras 20/21 (A) e 21/22 (B).

3.1. Validação dos Modelos de Predição.

Os gráficos abaixo demonstram a aplicação de redes neurais artificiais (RNA), especificamente Multilayer Perceptron (MLP) e Radial Basis Function (RBF) para predição da produtividade do amendoim para a safra 2020/2021 (Figura 3.4). Os resultados são apresentados em dois conjuntos de gráficos: gráfico de dispersão que correlacionam a produtividade observada com a predita pelos algoritmos, e gráfico de linhas que traçam a produtividade observada e estimada do teste dos modelos, ponto a ponto (Figura 4).





Analisando os conjuntos de dados que comparam as previsões de produtividade do amendoim utilizando modelos MLP e RBF em diferentes dias pré-colheita (30, 20, 14, 8 e 1 DPC), observa-se que ambos os modelos mantêm coeficiente de determinação (R^2) acima de

0,60 em todos os cenários, indicando uma capacidade consistente de capturar a variabilidade nos dados de produtividade observados. O MLP, em geral, exibiu valores de R^2 ligeiramente superiores ao RBF, sugerindo correlações mais fortes com a produtividade real. Observou-se que a precisão (R^2) dos modelos gerados com a MLP variou entre 0,70 e 0,73, enquanto a precisão da RBF variou em 0,61 e 0,73.





Os valores de MAPE obtidos pelo modelo MLP foram ligeiramente superiores em comparação ao RBF, exceto no período de 20 e 14 DPC. Por outro lado, o RBF apresenta MAE ligeiramente superiores nas mesmas datas, indicando maiores erros absolutos em suas previsões. O intervalo de valores MAE para MLP é de 497 kg ha⁻¹ chegando até 628 kg ha⁻¹, enquanto que para o RBF esse intervalo é menor com um erro de 70 kg ha⁻¹. O MAPE seguiu a mesma característica do MAE (MLP = 8,1 a 12,4 %; RBF = 8,8 a 10,1%).

As flutuações periódicas observadas nos gráficos lineares não demonstram uma melhoria significativa na precisão das estimativas à medida que se aproxima a data de colheita. Em síntese, os modelos MLP e RBF provaram ser robustos para a tarefa de previsão, com o MLP demonstrando uma leve vantagem em termos de precisão. A escolha entre os dois deve ser informada por critérios adicionais como complexidade computacional, tempo de treinamento e facilidade de implementação, considerando que a diferença de precisão é relativamente pequena.





30 DPC







20 DPC



14 DPC



8 DPC



1 DPC




Figura 3.4 Calibração dos modelos preditivos da produtividade do amendoim com dados da safra 2020/21.

3.2. Importância das Variáveis de Entrada nos Modelos de Calibração

Na safra 2020/2021, os modelos MLP e RBF gerados, foram submetidos à análise de sensibilidade para identificar os índices de vegetação (IV) mais influentes na previsão de produtividade do amendoim, dentre os 7 IVs utilizados (Tabela 3.3). No modelo MLP, o NLI sobressaiu-se como o mais sensível a 30 dias para a colheita. Aos 20 dias o SAVI foi a variável de entrada mais importante, enquanto o MNLI mostrou-se preponderante aos 14 DPC. O SR foi o mais sensível em duas ocasiões, aos 8 e 1 DPC. Entre todas as datas de predição, o EVI, GNDVI e o MNLI apareceram em todas as cinco datas de predição.

Para o modelo RBF, aos 30 DPC, o SAVI destacou-se, e aos 20 dias antes da colheita, o MNLI. Aos 14 e 8 DPC, o GNDVI foi o índice mais importante, a para 1 DPC, o EVI se sobressaiu. Para o algoritmo RBF, os IVs EVI e SAVI, demonstram alta sensibilidade em praticamente todos os períodos, exceto aos 8 DPC.

Tabela 3.3 Análise de sensibilidade para determinação de variáveis importantes dentro dos modelos gerados para os algoritmos MLP e RBF na safra 2020/21.

MLP Algoritmo					
VI	Dias para Colheita (20/21)				
	30 DPC	20 DPC	14 DPC	8 DPC	1 DPC
EVI	3	5	2	4	2
GNDVI	5	4	3	6	5
MNLI	4	2	1	5	3
NDVI			4	2	4
NLI	1				
SAVI	2	1		3	
SR		3		1	1

RBF Algoritmo					
Bands e VI	Dias para Colheita (20/21)				
	30 DPC	20 DPC	14 DPC	8 DPC	1 DPC
EVI	3	4	2		1
GNDVI			1	1	7
MNLI	2	1	3		6
NDVI			6		3
NLI		3	5		4
SAVI	1	2	4		5
SR			7	2	2

3.3. Generalização dos Modelos de Predição

Os gráficos de bolha fornecem uma comparação visual entre o desempenho de modelos preditivos baseados em dados da safra 2020/2021 com a cultivar OL3 (Figura 3.5). É importante salientar que foram apresentados somente as predições na validação, que obtiveram erros abaixo de 1000 kg ha^{-1} . Os modelos foram aplicados em novas áreas da safra 2021/2022, que foram os campos 10 e 11 para IAC 503, e campos 7 e 8 para IAC OL3, para testar sua generalização. O campo 9 não apresentou erros de predição abaixo de 1000 kg ha^{-1} . O desempenho dos modelos foi validados em relação aos períodos que antecedem à colheita (30, 20, 14, 8 e 1 DPC) em cada uma destas áreas.


Para a cultivar IAC OL3, o MLP apresenta modelos de calibração com erros de 502,4, 628,3 e 497,0 kg há^{-1} para as datas 30, 14 e 1 DPC, respectivamente. Quando aplicados no campo 8 os erros na validação são de 550,5, 576,3 e 539,5 kg há^{-1} , nas mesmas datas. No campo 7, o MAE das predições de validação são de 900,0 e 733,7 para 30 e 1 DPC. Para a mesma cultivar, mas utilizando o algoritmo RBF, os erros dos modelos

de calibração são de 528,4, e 509,4 kg ha^{-1} aos 30, e 8 DPC e a predição destas datas para o campo 8 foi de 708,9 e 648,4 kg ha^{-1} , respectivamente. A predição para o campo 7 só foi possível aos 20 DPC, em que modelo de calibração obteve MAE de 508,4 e a validação foi de 869,6 kg ha^{-1} .

Considerando a cultivar IAC 503, o algoritmo MLP apresenta erros na calibração de 504,4 e 605,8 kg ha^{-1} aos 20 e 8 DPC, respectivamente. Aplicando o modelo de calibração no campo 10, o MAE na validação é de 920,5 kg ha^{-1} aos 8 DPC. Para o campo 11, os erros na validação são de 940,1 e 648,3 kg ha^{-1} aos 20 e 8 DPC. Utilizando o algoritmo RBF para a IAC 503, os modelos apresentam erros de calibração de 578,2, 528,4 e 527,8 kg ha^{-1} aos 14, 8 e 1 DPC. No campo 10, o erro na validação é consideravelmente mais alto, com 889,4 kg ha^{-1} aos 14 DPC, enquanto aos 8 e 1 o MAE foi de 697,7 e 774,3 kg ha^{-1} , respectivamente. O algoritmo RBF não apresentou predições abaixo de 1000 kg ha^{-1} em Taquaritinga em nenhuma data.

Em síntese, os modelos demonstraram um desempenho superior nos dados de calibração (2020/2021) em comparação com as novas áreas de aplicação (2021/2022). O MLP mostrou-se ligeiramente mais acurado que o RBF para o campo 8, mas ambos os algoritmos apresentaram desafios no campo 7 e 10. Além disso, os algoritmos não foram capazes de prever a produtividade em todas as datas. Estes resultados indicam a necessidade de refinamento dos modelos para melhor adaptá-los às condições específicas das novas áreas em questão. Para tal, ajustes algorítmicos ou a incrementação de mais dados representativos dessas áreas podem ser requisitados para reduzir o MAE e melhorar a robustez e a aplicabilidade dos modelos preditivos em um espectro mais amplo de condições agrícolas.

A) IAC OL3



B) IAC 503





Figura 3.5 Validação dos modelos desenvolvidos na safra 2020/2021. Em “azul” são os erros dos modelos desenvolvidos na calibração e em “vermelho” os erros da validação em áreas da safra 2021/2022.

3.4. Recalibração dos Modelos de Predição


Os seguintes gráficos demonstram os resultados dos novos modelos gerados a partir dos dados de duas safras (2020/21 e 2021/22) em um total de 11 áreas (Figura 3.6). Em que, realizou-se o incremento dos dados e realizou-se o treinamento e teste dos modelos novamente, com a hipótese de tornar as equações mais robustas e com maior acurácia. A Figura 4 demonstra maior relação dos modelos gerados com as duas safras. O algoritmo MLP demonstrou coeficiente de determinação (R^2) consistentemente acima de 0,80, indicando uma previsão muito precisa da produtividade, exceto para 20 DPC, onde o R^2 foi ligeiramente menor (0,72). A acurácia do MLP foi reforçada por MAE que variou de 418,1 a 523,4 kg ha⁻¹ e MAPE que permaneceu entre 6,3% e 9,7%, resultados muitos superiores que os encontrados nos primeiros modelos gerados como foi observado na Figura 2. Por outro lado, o RBF, apesar de mostrar boa capacidade preditiva com um R^2 de 0,53 a 0,74, obteve desempenho inferior ao do MLP em todas as datas de previsão analisadas. Este modelo registrou MAE entre 544,2 e 636,0 kg ha⁻¹ e um MAPE de 8,4% a 11,7%, indicando uma variação maior nas previsões.

De maneira geral, os resultados indicam que o modelo MLP é mais robusto e adequado para aplicações práticas na previsão da produtividade de amendoim, considerando tanto o modelo gerado com apenas uma safra, quanto com duas safras. O RBF, apesar de viável, apresenta limitações que o tornam menos preferível em comparação ao MLP. Estes resultados ressaltam a importância de escolher o modelo apropriado para maximizar a precisão e a eficácia na agricultura de precisão.





30 DPC







20 DPC



14 DPC



8 DPC



1 DPC




Figura 3.6 Recalibração e ampliação de dados para o modelo de predição da produtividade do amendoim utilizando dados das duas safras (2020/2021 e 2021/2022).

3.5. Importância das Variáveis de Entrada nos Modelos de Recalibração.

O acréscimo de dados da safra 2021/2022 ao conjunto de dados do ano anterior proporcionou uma base mais robusta e uma perspectiva ampliada nos modelos gerados, permitindo o refinamento na quantificação da influência de cada índice nos modelos de previsão (Tabela 3.4). A consequente classificação de sensibilidade, estruturada em forma de ranking, demonstra a contribuição de cada índice de vegetação, destacando a dinâmica temporal e a importância de adaptar os modelos preditivos à variabilidade, inerente aos ciclos de cultivo do amendoim.

No contexto do modelo MLP, o EVI apresentou a mais alta sensibilidade 30 dias antes da colheita, seguido pelo SR com maior relevância aos 20 e 14 DPC. À medida que o período de colheita se aproximava, aos 8 DPC, o NDVI emergiu como o índice mais sensível, enquanto o NLI destacou-se a 1 DPC. Em contrapartida, o modelo RBF indicou o SR como o índice mais sensível 30 dias antes da colheita, enquanto, o EVI tornou-se mais influente aos 20 DPC. Aproximando-se da data de colheita, as variáveis mais importantes foram o NDVI aos 14 e O MNLI aos 8 DPC. Finalmente, o EVI voltara a apresentar maior sensibilidade um dia antes da colheita.

A análise revela que a importância dos índices de vegetação é dinâmica e varia significativamente do 30 DPC até a colheita e entre os modelos utilizados, assim como foi visto nos modelos gerados para a safra 2020/21 (Figura 3.3). Observou-se que índices como NLI, SAVI, NDVI, MNLI e SR foram consistentemente destacados nos modelos MLP e RBF para previsão da produtividade do amendoim. Os resultados indicam que o EVI e o SR são particularmente mais robustos, mantendo alta sensibilidade em quase todos os períodos pré-colheita. A integração de dados de duas safras reforça a necessidade de recalibrar os modelos preditivos, garantindo previsões mais precisas.

Tabela 3.4 Análise de sensibilidade para determinação de variáveis importantes dentro dos modelos gerados para os algoritmos MLP e RBF na safra 2020 à 2022.

MLP Algoritmo					
VI	Dias para Colheita (DPC)				
	30 DPC	20 DPC	14 DPC	8 DPC	1 DPC
EVI	1	4	4	3	4
GNDVI	4	5	7	5	
MNLI	3		6	2	3
NDVI		2	2	1	
NLI		3	5		1
SAVI			3	4	
SR	2	1	1		2
RBF Algoritmo					
Bands e VI	Dias para Colheita (DPC)				
	30 DPC	20 DPC	14 DPC	8 DPC	1 DPC
EVI	4	1	7	3	1
GNDVI	7	2	5	4	7
MNLI	3	5	3	1	2
NDVI	6	4	1	7	4
NLI	5	6	2	5	6
SAVI	2	7	4	2	3
SR	1	3	6	6	5

4. Discussão

4.1. Influência do Solo e Cultivar na Predição da Produtividade

No que diz respeito à cultura do amendoim, o tipo de solo influencia diretamente na variabilidade da produtividade da cultura, principalmente pelas características de desenvolvimento da planta. De maneira geral, o amendoim tem melhor desempenho em solos com maior teor de areia, devido a sua boa drenagem, característica que solos argilosos não apresentam, podendo dificultar o crescimento das vagens e afetar negativamente a produtividade. Em contrapartida, a capacidade de retenção de água que

está diretamente relacionada com a textura do solo, pode ser prejudicial em solos mais leves em condições de seca, diminuindo a produtividade do amendoim (Woli et al., 2013).

Diante disto, observou-se com os resultados deste trabalho, uma distinção tanto na variabilidade como na média de produtividade entre os solos, sugerindo que está variável deve ser considerada. Sendo assim, a possibilidade de melhora dos modelos pode passar pela adoção de variáveis relacionadas às características do solo, podendo ajudar o modelo a diferenciar a produtividade com base nas propriedades do solo (Kross et al., 2020).

Nos campos estudados, a variedade IAC OL3 sobressaiu à IAC 503. Estas cultivares apresentam diferentes características, principalmente no que diz respeito ao ciclo. A OL3 apresenta produtividade maior que cultivares de ciclo mais longo (De Godoy et al., 2014). Em síntese, a interação entre genótipo e ambiente eleva a complexidade das predições de produtividade, que é potencializada pela variabilidade encontrada em campo, influenciada por uma gama de fatores, tanto intrínsecos quanto extrínsecos à cultura. Portanto, torna-se crucial identificar quais variáveis específicas impactam diretamente a variabilidade da produtividade do amendoim, para aprimorar ainda mais as previsões e estratégias de manejo (Hara et al., 2021).

4.2. Influência dos Índices de Vegetação nos Modelos Preditivos

A maioria das pesquisas para determinação de modelos de predição para produtividade de cereais, tubérculos e leguminosas utilizam dados de sensoriamento remoto, com os modelos meteorológicos destacando-se como a segunda técnica mais utilizada (Basso & Liu, 2019). Os resultados demonstram que todos os índices utilizados como entrada para prever a produtividade do amendoim foram selecionados em alguma data de predição. A análise de sensibilidade demonstra que os índices de vegetação são dinâmicos e variam conforme o período de previsão e o modelo utilizado (MLP ou RBF). Essa variação indica a necessidade de escolhas estratégicas das variáveis de entrada nos modelos preditivos, que devem ser adaptados aos diferentes estágios de desenvolvimento das plantas.

O EVI, por exemplo, foi um índice criado com o objetivo de aprimorar o monitoramento da vegetação, sendo menos sensível à alta densidade foliar, além de minimizar influências atmosféricas devido ao comprimento de onda do azul (Huete et al., 2002; Kaufman & Tanré, 1992). Em comparação ao NDVI, índice amplamente conhecido e utilizado, o EVI é mais responsivo às variações estruturais da copa, incluindo índice de área foliar, arquitetura da vegetação e influência de solo, enquanto NDVI é sensível à

clorofila (Gao et al., 2000) o que faz o EVI ser menos sensível à saturação. Neste estudo, observou-se que o EVI se sobressai ao NDVI na análise de sensibilidade, o que reforça o bom desempenho do EVI em culturas com alta densidade foliar, como é o caso do amendoim.

Outro IV que tem características distintas é o GNDVI, que apresenta maior sensibilidade às variações da clorofila que os índices que compõem o comprimento de onda do vermelho. Índices de vegetação que contém o espectro da banda verde em sua composição, demonstram forte correlação com o conteúdo de nitrogênio das plantas, podendo capturar estresse nutricional (Chang et al., 2019; Tong & He, 2017; Viña et al., 2011; Zhao et al., 2018).

A utilização conjunta desses índices de vegetação na geração de modelos preditivos de produtividade, apresenta grande potencial, considerando que todas essas variáveis estão, de alguma forma, relacionadas à produtividade das culturas. Oliveira et al. (2024) demonstraram que IVs, como NLI, NDVI, SAVI, GNDVI e MNLI, apresentam potencial para estimar tanto a maturação do amendoim quanto a variabilidade do peso das vagens ao longo do ciclo da cultura, evidenciando sua capacidade de capturar a variabilidade espacial e temporal do peso das vagens. Este estudo reforça a relação que os IVs podem ter com o rendimento da cultura do amendoim.

4.3.Eficácia dos Modelos de RNA na Predição da Produtividade Agrícola

Os algoritmos de RNAs utilizados demonstraram eficácia na previsão da produtividade do amendoim, evidenciando uma notável capacidade de capturar a variabilidade nos dados observados em campo. As redes MLP e RBF foram anteriormente identificadas como excelentes preditores da maturação do amendoim (Santos et al., 2022 Souza et al., 2022). Em relação ao desempenho dos algoritmos para predição de produtividade, diversos estudos apontam que a MLP tem excelentes resultados e é amplamente utilizada para previsão de produtividade agrícola (Farjam et al., 2014; Khalifani et al., 2022; Niedbała, 2019; Niedbała et al., 2019).

Este estudo revela que, os modelos desenvolvidos com o algoritmo RBF mostraram uma ligeira inferioridade nas predições, porém, está RNA já demonstrou ser mais eficiente que a rede MLP na previsão da maturação do amendoim e na produtividade da soja, conforme evidenciado em pesquisas anteriores (Yoosefzadeh-Najafabadi et al., 2021; Souza et al., 2022). Esses achados, juntamente com os deste estudo, destacam o potencial de ambos os algoritmos na previsão da produtividade de culturas agrícolas

distintas. Além disso, comparando com outros algoritmos de aprendizado de máquina (KNN, SVR, RF e AB), o uso das RNAs na previsão da produtividade da berinjela mostrou ser superior, utilizando índices de vegetação como variáveis independentes (Taşan et al., 2022), o que demonstra a força das redes neurais artificiais em previsões.

Em termos de confiabilidade e consistência das previsões de produtividade, o MLP superou o RBF em todas as janelas de previsão, não mostrando, entretanto, melhorias significativas na precisão à medida que a data da colheita se aproximava, assim como observado nos modelos da safra 2020/21. Esta observação pode ser atribuída à redução da incerteza com a proximidade da colheita, sugerindo que outros fatores além do tempo podem influenciar a produtividade.

4.4. Generalização, Aplicabilidade dos Modelos de Predição

A criação de modelos de predição de produtividade e a validação destas equações em diferentes áreas agrícolas, são passos fundamentais para assegurar a eficácia, precisão e aplicabilidade desses modelos. A capacidade destas técnicas de predição em se adaptar às variações climáticas, tipos de solo e diferentes manejos, torna a generalização dos modelos um desafio.

Poucos estudos são encontrados na literatura que apresentem além dos modelos gerados, a validação em novas áreas, garantindo a robustez da proposta. Becker-Reshef et al., (2010) e Schwalbert et al., (2018), utilizando equações empíricas de regressão, validaram os modelos gerados em outros países e estados, para a predição da cultura do trigo e do milho utilizando IVs. No entanto, é importante destacar que modelos derivados de relações empíricas simples apresentam limitações na predição de áreas novas que apresentam características diferentes, ou seja, estes modelos apresentam resultados satisfatórios apenas em áreas para as quais foram calibradas (Doraiswamy et al., 2003).

4.5. Impacto da Recalibração dos Modelos com Dados Ampliados

Nossos resultados demonstram que a ampliação dos dados nos modelos trouxe aumento significativo na precisão e na acurácia das previsões. À medida que novos dados são coletados, parâmetros e características que influenciam na produtividade são atualizados, e este processo de recalibração com novos dados, não apenas melhora a precisão e acurácia das previsões, mas também, enriquece o entendimento das RNAs em relação à complexidade das interações entre diferentes fatores agronômicos e ambientais.

A quantidade de dados que devem ser inseridos em modelos de predição ainda gera bastante discussão no meio científico. Na agricultura, o problema de “pequenos dados” está associado principalmente aos desafios nas coletas destes dados, que na

maioria das vezes exige muita mão de obra (Safonova et al., 2023), em alguns casos, tornando a coleta de uma grande quantidade de dados humanamente impossível.

A capacidade de desenvolver modelos de predição da produtividade do amendoim que sejam robustos, mas também facilmente aplicáveis em novas áreas, e que permitam predições com até 30 dias de antecedência, representa um avanço significativo para o campo científico desta cultura. Este artigo foca na concepção de modelos de predição caracterizados por sua robustez, simplicidade de aplicação e pela capacidade de fornecer a produtividade antecipadamente. Buscou-se, portanto, a criação de modelos que ofereçam confiabilidade e precisão, sem a necessidade de um extenso conjunto de dados e de variáveis de entrada.

5. Conclusão

O uso em conjunto de ferramentas de SR e IA demonstrou grande potencial para predição e generalização dos dados observados em campo da produtividade do amendoim. O algoritmo MLP se sobressaiu, apresentando os melhores modelos preditivos, enquanto o IV mais importante nestas predições foi o EVI, seguido do SAVI e SR.

Os resultados mostram que é possível determinar a produtividade do amendoim em até 30 dias antes da colheita utilizando redes neurais artificiais e índices de vegetação. A utilização dos modelos desenvolvidos em outras áreas de produção, demonstrou grande potencial na generalização em novos campos, no entanto, foram observadas diferenças entre o que foi predito pelos modelos na primeira safra em relação às predições em novas áreas, principalmente nas áreas com a cultivar IAC 503.

A recalibração dos modelos foi satisfatória, demonstrando incremento significativo de precisão e acurácia. Logo, a ampliação de dados é necessária para tornar o modelo ainda mais robusto, ajudando as RNAs no entendimento das características de manejo, influências agronômicas e características ambientais de cada área. De toda forma, o uso de mais variáveis de entrada que influenciam de forma significativa a produtividade das culturas, como por exemplo, clima e solo, não devem ser descartadas e podem ser aplicadas em trabalhos futuros para entender como estas variáveis influenciam na predição da produtividade do amendoim.

6. Referências

- Basso, B., & Liu, L. (2019). Seasonal crop yield forecast: Methods, applications, and accuracies. *Advances in Agronomy*, 154, 201–255. <https://doi.org/10.1016/BS.AGRON.2018.11.002>
- Becker-Reshef, I., Vermote, E., Lindeman, M., & Justice, C. (2010). A generalized regression-based model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data. *Remote Sensing of Environment*, 114(6), 1312–1323. <https://doi.org/10.1016/J.RSE.2010.01.010>
- Chang, Q., Xiao, X., Jiao, W., Wu, X., Doughty, R., Wang, J., Du, L., Zou, Z., & Qin, Y. (2019). Assessing consistency of spring phenology of snow-covered forests as estimated by vegetation indices, gross primary production, and solar-induced chlorophyll fluorescence. <https://doi.org/10.1016/j.agrformet.2019.06.002>
- De Godoy, I. J., Dos Santos, J. F., De Carvalho, C. R. L., Michelotto, M. D., Bolonhezi, D., De Freitas, R. S., Kasai, F. S., Ticelli, M., Finoto, E. L., & Melo Martins, A. L. (2014). IAC OL 3 and IAC OL 4: new Brazilian peanut cultivars with the high oleic trait. *Crop Breeding and Applied Biotechnology*, 14(3), 200–203. <https://doi.org/10.1590/1984-70332014V14N3A30>
- Desloires, J., Ienco, D., & Botrel, A. (2023). Out-of-year corn yield prediction at field-scale using Sentinel-2 satellite imagery and machine learning methods. *Computers and Electronics in Agriculture*, 209, 107807. <https://doi.org/10.1016/J.COMPAG.2023.107807>
- Doraiswamy, P. C., Moulin, S., Cook, P. W., & Stern, A. (2003). Crop Yield Assessment from Remote Sensing. *Photogrammetric Engineering and Remote Sensing*, 69(6), 665–674. <https://doi.org/10.14358/PERS.69.6.665>
- Farjam, A., Omid, M., Akram, A., & Fazel Niari, Z. (2014). A Neural Network Based Modeling and Sensitivity Analysis of Energy Inputs for Predicting Seed and Grain Corn Yields. *Journal of Agricultural Science and Technology*, 16(4), 767–778. <http://jast.modares.ac.ir/article-23-5916-en.html>
- Gao, X., Huete, A. R., Ni, W., & Miura, T. (2000). Optical–Biophysical Relationships of Vegetation Spectra without Background Contamination. *Remote Sensing of Environment*, 74(3), 609–620. [https://doi.org/10.1016/S0034-4257\(00\)00150-4](https://doi.org/10.1016/S0034-4257(00)00150-4)

Gitelson, A.A.; Merzlyak, M.N. Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. *Journal of Plant Physiology* 1996, 148, 494–500, doi:10.1016/S0176-1617(96)80284-7.

Goel, N.S.; Qin, W. Influences of Canopy Architecture on Relationships between Various Vegetation Indices and LAI and Fpar: A Computer Simulation. *Remote Sensing Reviews* 1994, 10, 309–347, doi:10.1080/02757259409532252.

Gong, P.; Pu, R.; Biging, G.S.; Larrieu, M.R. Estimation of Forest Leaf Area Index Using Vegetation Indices Derived from Hyperion Hyperspectral Data. *IEEE Transactions on Geoscience and Remote Sensing* 2003, 41, 1355–1362, doi:10.1109/TGRS.2003.812910.

Hara, P., Piekutowska, M., & Niedbała, G. (2021). Selection of Independent Variables for Crop Yield Prediction Using Artificial Neural Network Models with Remote Sensing Data. *Land* 2021, Vol. 10, Page 609, 10(6), 609. <https://doi.org/10.3390/LAND10060609>

Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1–2), 195–213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)

Huete, A.R. A Soil-Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment* 1988, 25, 295–309, doi:10.1016/0034-4257(88)90106-X.

Justice, C.O.; Vermote, E.; Townshend, J.R.G.; Defries, R.; Roy, D.P.; Hall, D.K.; Salomonson, V.V.; Privette, J.L.; Riggs, G.; Strahler, A.; et al. The Moderate Resolution Imaging Spectroradiometer (MODIS): Land Remote Sensing for Global Change Research. *IEEE Transactions on Geoscience and Remote Sensing* 1998, 36, 1228–1249, doi:10.1109/36.701075.

Kaufman, Y. J., & Tanré, D. (1992). Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 261–270. <https://doi.org/10.1109/36.134076>

Khalifani, S., Darvishzadeh, R., Azad, N., & Seyed Rahmani, R. (2022). Prediction of sunflower grain yield under normal and salinity stress by RBF, MLP and, CNN models. *Industrial Crops and Products*, 189, 115762. <https://doi.org/10.1016/J.INDCROP.2022.115762>

Kross, A., Znoj, E., Callegari, D., Kaur, G., Sunohara, M., Lapen, D. R., & McNairn, H. (2020). Using Artificial Neural Networks and Remotely Sensed Data to

Evaluate the Relative Importance of Variables for Prediction of Within-Field Corn and Soybean Yields. *Remote Sensing* 2020, Vol. 12, Page 2230, 12(14), 2230. <https://doi.org/10.3390/RS12142230>

Niedbała, G. (2019). Simple model based on artificial neural network for early prediction and simulation winter rapeseed yield. *Journal of Integrative Agriculture*, 18(1), 54–61. [https://doi.org/10.1016/S2095-3119\(18\)62110-0](https://doi.org/10.1016/S2095-3119(18)62110-0)

Niedbała, G., Nowakowski, K., Rudowicz-Nawrocka, J., Piekutowska, M., Weres, J., Tomczak, R. J., Tyksiński, T., & Pinto, A. Á. (2019). Multicriteria Prediction and Simulation of Winter Wheat Yield Using Extended Qualitative and Quantitative Data Based on Artificial Neural Networks. *Applied Sciences* 2019, Vol. 9, Page 2773, 9(14), 2773. <https://doi.org/10.3390/APP9142773>

Oliveira, M. F. de, Santos, A. F. dos, Kazama, E. H., Rolim, G. de S., & Silva, R. P. da. (2021). Determination of application volume for coffee plantations using artificial neural networks and remote sensing. *Computers and Electronics in Agriculture*, 184, 106096. <https://doi.org/10.1016/J.COMPAG.2021.106096>

Prediction of biological and grain yield of barley using multiple regression and artificial neural network models | *Australian Journal of Crop Science*. (n.d.). Retrieved January 21, 2024, from <https://search.informit.org/doi/abs/10.3316/INFORMIT.324323941945826>

São Paulo: Instituto Florestal, 2017. V.1. 118p

Rouse, J.W., Jr.; Haas, R.H.; Schell, J.A.; Deering, D.W. Monitoring Vegetation Systems in the Great Plains with ERTS. NASA Special Publication 1974, 351, 309.

Application of Machine Learning and Neural Networks to Predict the Yield of Cereals, Legumes, Oilseeds and Forage Crops in Kazakhstan. *Agriculture (Switzerland)*, 13(6), 1195. <https://doi.org/10.3390/AGRICULTURE13061195/S1>

Safonova, A., Ghazaryan, G., Stiller, S., Main-Knorn, M., Nendel, C., & Ryo, M. (2023). Ten deep learning techniques to address small data problems with remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 125, 103569. <https://doi.org/10.1016/J.JAG.2023.103569>

Santos, A. F., Lacerda, L. N., Rossi, C., Moreno, L. D. A., Oliveira, M. F., Pilon, C., Silva, R. P., & Vellidis, G. (1993). Using UAV and Multispectral Images to Estimate Peanut Maturity Variability on Irrigated and Rainfed Fields Applying Linear Models and Artificial Neural Networks. *Volume 14, Issue 1, 14(1)*. <https://doi.org/10.3390/rs14010093>

Forecasting maize yield at field scale based on high-resolution satellite imagery. *Biosystems Engineering*, 171, 179–192. <https://doi.org/10.1016/J.BIOSYSTEMSENG.2018.04.020>

Satellite-based soybean yield forecast: Integrating machine learning and weather data for improving crop yield prediction in southern Brazil. *Agricultural and Forest Meteorology*, 284, 107886. <https://doi.org/10.1016/J.AGRFORMET.2019.107886>

Shammi, S. A., & Meng, Q. (2021). Use time series NDVI and EVI to develop dynamic crop growth metrics for yield modeling. *Ecological Indicators*, 121, 107124. <https://doi.org/10.1016/J.ECOLIND.2020.107124>

Son, N. T., Chen, C. F., Chen, C. R., Minh, V. Q., & Trung, N. H. (2014). A comparative analysis of multitemporal MODIS EVI and NDVI data for large-scale rice yield estimation. *Agricultural and Forest Meteorology*, 197, 52–64. <https://doi.org/10.1016/J.AGRFORMET.2014.06.007>

Souza, J. B. C., de Almeida, S. L. H., Freire de Oliveira, M., Dos Santos, A. F., Filho, A. L. de B., Meneses, M. D., & Silva, R. P. da. (2022). Integrating Satellite and UAV Data to Predict Peanut Maturity upon Artificial Neural Networks. *Agronomy*, 12(7), 1512. <https://doi.org/10.3390/agronomy12071512>

Taki, M., Rohani, A., Soheili-Fard, F., & Abdeslahi, A. (2018). Assessment of energy consumption and modeling of output energy for wheat production by neural network (MLP and RBF) and Gaussian process regression (GPR) models. *Journal of Cleaner Production*, 172, 3028–3041. <https://doi.org/10.1016/J.JCLEPRO.2017.11.107>

Taşan, S., Cemek, B., Taşan, M., & Cantürk, A. (2022). Estimation of eggplant yield with machine learning methods using spectral vegetation indices. *Computers and Electronics in Agriculture*, 202, 107367. <https://doi.org/10.1016/J.COMPAG.2022.107367>

Tong, A., & He, Y. (2017). *Estimating and mapping chlorophyll content for a heterogeneous grassland: Comparing prediction power of a suite of vegetation indices across scales between years.*

Viña, A., Gitelson, A. A., Nguy-Robertson, A. L., & Peng, Y. (2011). *Comparison of different vegetation indices for the remote assessment of green leaf area index of crops.* <https://doi.org/10.1016/j.rse.2011.08.010>

Woli, P., Paz, J. O., Hoogenboom, G., Garcia y Garcia, A., & Fraisse, C. W. (2013). The ENSO effect on peanut yield as influenced by planting date and soil type. *Agricultural Systems*, 121, 1–8. <https://doi.org/10.1016/J.AGSY.2013.06.005>

Yoosefzadeh-Najafabadi, M., Tulpan, D., & Eskandari, M. (2021). Application of machine learning and genetic optimization algorithms for modeling and optimizing soybean yield using its component traits. *PLOS ONE*, 16(4), e0250665. <https://doi.org/10.1371/JOURNAL.PONE.0250665>

Zhao, B., Duan, A., Tahir Ata-Ul-Karim, S., Liu, Z., Chen, Z., Gong, Z., Zhang, J., Xiao, J., Liu, Z., Qin, A., & Ning, D. (2018). *Exploring new spectral bands and vegetation indices for estimating nitrogen nutrition index of summer maize*.

7. Material Suplementar

Figure 1. Architectures and Parameters of MLP and RBF Models for the 2020-2021 Growing Season

Predictive	Profile	Train Perf.	Select Perf.	Test Perf.	Train Error	Select Error	Test Error	Training/Members	Inputs	Hidden(1)	Hidden(2)
30 DBH	MLP 5:5-12-8-1:1	0.547884	0.00	0.641249	0.117813	0.00	0.176981	BP100,CG20,CG609b	5	12	8
	RBF 3:3-12-1:1	0.796480	0.00	0.628975	0.000677	0.00	0.000652	KM,KN,PI	3	12	0
20 DBH	MLP 5:5-12-8-1:1	0.673662	0.00	0.796845	0.145898	0.00	0.151170	BP100,CG20,CG426b	5	12	8
	RBF 4:4-12-1:1	0.864885	0.00	0.702821	0.000611	0.00	0.000468	KM,KN,PI	4	12	0
14 DBH	MLP 4:4-12-8-1:1	0.723574	0.00	0.777126	0.154762	0.00	0.219956	BP100,CG20,CG256b	4	12	8
	RBF 7:7-12-1:1	0.829614	0.00	0.770107	0.000633	0.00	0.000756	KM,KN,PI	7	12	8
8 DBH	MLP 6:6-12-8-1:1	0.634485	0.00	0.823302	0.138691	0.00	0.164505	BP100,CG20,CG401b	6	12	8
	RBF 2:2-12-1:1	0.835127	0.00	0.827196	0.000590	0.00	0.000532	KM,KN,PI	2	12	0
1 DBH	MLP 5:5-12-9-1:1	0.649563	0.00	0.939691	0.142828	0.00	0.186216	BP100,CG20,CG490b	5	12	9
	RBF 7:7-12-1:1	0.786426	0.00	0.728932	0.000546	0.00	0.000458	KM,KN,PI	7	12	0

Figure 2. Architectures and Parameters of MLP and RBF Models for the 2021-2022 Growing Season

Predictive	Profile	Train Perf.	Select Perf.	Test Perf.	Train Error	Select Error	Test Error	Training/Members	Inputs	Hidden(1)	Hidden(2)
30 DBH	MLP 4:4-12-4-1:1	0.674973	0.00	0.566334	0.163374	0.00	0.145661	BP100,CG20,CG327b	4	12	4
	RBF 7:7-12-1:1	0.715552	0.00	0.639291	0.000488	0.00	0.000433	KM,KN,PI	7	12	0
20 DBH	MLP 5:5-12-8-1:1	0.799145	0.00	0.801100	0.181801	0.00	0.181093	BP100,CG20,CG316b	5	12	8
	RBF 7:7-12-1:1	0.861639	0.00	0.860065	0.000723	0.00	0.000717	KM,KN,PI	7	12	0
14 DBH	MLP 7:7-12-9-1:1	0.736843	0.00	0.693826	0.160765	0.00	0.160696	BP100,CG20,CG207b	7	12	9
	RBF 7:7-11-1:1	0.822524	0.00	0.727502	0.000628	0.00	0.000592	KM,KN,PI	7	11	0
8 DBH	MLP 5:5-12-11-1:1	0.774412	0.00	0.658424	0.180611	0.00	0.155674	BP100,CG20,CG185b	12	11	7
	RBF 7:7-12-1:1	0.786719	0.00	0.681432	0.000583	0.00	0.000510	KM,KN,PI	12	0	0
1 DBH	MLP 4:4-12-6-1:1	0.785432	0.00	0.739370	0.174962	0.00	0.176854	BP100,CG20,CG247b	4	12	6
	RBF 7:7-12-1:1	0.823134	0.00	0.725754	0.000628	0.00	0.000595	KM,KN,PI	7	12	0

CAPÍTULO 4 – PREDIÇÃO MULTIALVO DA MATURAÇÃO E PRODUTIVIDADE DO AMENDOIM USANDO SENSORIAMENTO REMOTO INTEGRADO A IA PARA O AVANÇO DA COLHEITA INTELIGENTE³

Resumo: A antecipação na determinação de variáveis como a maturação e a produtividade do amendoim é crucial para que os produtores possam gerenciar eficazmente a operação de colheita. A previsão dessas variáveis fornece informações valiosas que orientam as configurações das máquinas e definem o melhor momento e as condições ideais para realizar uma colheita inteligente. Este trabalho tem como objetivo prever simultaneamente a produtividade e a maturação do amendoim com uma antecedência de até 30 dias, utilizando a regressão multialvo e dados de sensoriamento remoto. O experimento foi realizado em 11 áreas comerciais no Estado de São Paulo, a principal região produtora de amendoim no Brasil. A produtividade e a maturação foram determinadas em um total de 270 amostras coletadas em todas as áreas. Para garantir a robustez da modelagem, as áreas foram selecionadas considerando a diversidade de tipos de solo, manejo, cultivares e duas safras distintas. O monitoramento das áreas foi realizado por meio de imagens de satélite de alta resolução obtidas pela plataforma PlanetScope, em cinco datas anteriores à colheita, permitindo o cálculo de sete índices de vegetação que serviram como variáveis de entrada para os modelos. Foram utilizados dois algoritmos para prever as variáveis dependentes: Random Forest e K-Nearest Neighbors. O conjunto de dados foi dividido em 80% para treinamento e 20% para validação, e o desempenho dos modelos foi avaliado com base no erro médio absoluto. Os resultados demonstraram que a regressão multialvo (MTR) possui potencial para antecipar variáveis complexas, como o índice de maturação e a produtividade do amendoim, com erros aceitáveis em até 30 dias antes da colheita. Contudo, ambos os algoritmos enfrentaram desafios ao tentar capturar a variabilidade presente em campo. Apesar dessas dificuldades, os resultados são satisfatórios, considerando a complexidade intrínseca do estudo. Este trabalho representa um dos primeiros esforços para antecipar a determinação de variáveis que impactam diretamente o desenvolvimento da colheita inteligente de forma simultânea.

³ Capítulo foi submetido como artigo na revista Computers and Electronics in Agriculture (IF: 7.7; CiteScore: 15.3).

Palavras-chaves: Colheita Inteligente, Regressão Multi-alvo, Predição, Agricultura Digital, Sensoriamento Remoto.

1. Introdução

O incremento de novas tecnologias e a integração de ferramentas como Sensoriamento Remoto (SR) e Inteligência Artificial (IA) no manejo da cultura do amendoim, pode potencializar ainda mais o cultivo desta, que é a segunda oleaginosa mais cultivada do mundo, ficando atrás somente da soja (USDA, 2024). A predição de variáveis como a maturação e a produtividade têm potencial de alavancar o cultivo do amendoim e tornar a cultura ainda mais atrativa, tendo em vista que, são importantes indicadores para direcionar uma colheita mais inteligente e assertiva. A colheita inteligente pode ser entendida como a utilização de ferramentas tecnológicas, como SR e IA visando atuar diretamente nas regulagens das máquinas para obter aumento de eficiência e rentabilidade

Determinar o ponto de colheita do amendoim e garantir uma melhor gestão nesta operação, é um dos principais gargalos no ciclo produtivo da cultura. A maturação do amendoim determina qual é o melhor momento para realização da colheita, sendo que o ponto ideal é quando as plantas atingem 70 % no Índice de Maturação do Amendoim (PMI) (Rowland et al., 2006). Realizar a colheita antes ou depois do momento ideal, pode acarretar perdas qualitativas e quantitativas consideráveis, com vagens imaturas apresentando menor teor de compostos fenológicos totais e antioxidantes reduzidos (Yen et al., 1993), enquanto, o excesso de vagens maduras pode causar perdas na operação de arranquio do amendoim (Santos et al., 2019).

Da mesma forma, a predição da produtividade pode auxiliar o produtor no momento da colheita, com a gestão da operação, e além de auxiliar a tomada de decisão para safras futuras. Entender de forma antecipada o rendimento de culturas pode apoiar o produtor na definição de estratégias pós-colheita, como, logística para escoamento e armazenamento do produto e mão de obra necessária (Tedesco et al., 2021a). Além disto, oferece meios de identificar a variabilidade espacial e delimitar zonas menos produtivas, a fim de fazer correções a partir de investigações direcionadas (Bantchina et al., 2024).

Identificar o melhor momento para colheita e o rendimento da lavoura de forma antecipada ainda é uma realidade a ser buscada não só para a cultura do amendoim. De maneira geral, estimativas são realizadas através de métodos tradicionais que envolvem avaliações destrutivas e pouco assertivas (Barbosa Júnior et al., 2024). Outra abordagem,

utilizando técnicas mais avançadas são as estimativas através da integração de sensores em colhedoras, que são adaptáveis em culturas específicas como, milho, soja, trigo e sorgo (McFadden et al., 2023). Para a cultura do amendoim ambas as técnicas são pouco aplicáveis, principalmente pelas características fisiológicas da cultura e pela dinâmica da colheita mecanizada do amendoim, realizada em duas etapas, o que dificulta o desenvolvimento de sensores que possam auxiliar na estimativa.

Diversos trabalhos utilizaram uma abordagem menos complexa, desenvolvendo estimativas com alvo-único e técnicas de machine learning e SR, para determinar parâmetros biofísicos de culturas como soja, milho, trigo e amendoim (Desloires et al., 2023; Farjam et al., 2014; Santos et al., 2021; Schwalbert et al., 2018; Son et al., 2014; Souza et al., 2022; Tedesco et al., 2021b; Tong & He, 2017; Zhang et al., 2021; Zhao et al., 2018). Pesquisas utilizando técnicas de predição multialvo foram pouco exploradas na agricultura. Os únicos trabalhos que abordaram o tema, utilizaram regressão multialvo (RMA) para estimar a biomassa e maturação do amendoim, rendimento da batata e parâmetro de qualidade da farinha de trigo (Oliveira et al., 2024; Tedesco et al., 2021b; Barbon Junior et al., 2020).

A estimativa refere-se à inferência de valores desconhecidos com base em dados atuais ou passados, geralmente utilizando amostras e cálculos estatísticos para aproximar o valor real. Em contraste, a predição projeta valores futuros com base em padrões históricos e modelos preditivos, envolvendo maior incerteza por se tratar de eventos que ainda não ocorreram. Assim, enquanto a estimativa se aplica ao presente ou passado, a predição foca em antecipar resultados futuros, muitas vezes exigindo modelos mais complexos (Michaelides, 2008). Embora existam métodos de estimativa de parâmetros biofísicos da cultura do amendoim, nenhum trabalho abordou a predição de duas variáveis simultaneamente, visando auxiliar o produtor na gestão da colheita inteligente. Diante disto, acreditamos que existe uma lacuna para antecipar a determinação da produtividade e maturação do amendoim levando em consideração a interação genótipo e ambiente, com diferentes manejos, tipos de solo e cultivares, utilizando Índices de Vegetação (IV) oriundos de diferentes plataformas de SR.

A integração de dados de sensores orbitais com técnicas de aprendizado máquinas já é uma realidade, no entanto, van Klompenburg et al., (2020) verificaram em 50 trabalhos de 2008 a 2019 que as variáveis preditivas mais utilizadas para determinar o rendimento de culturas utilizando aprendizado de máquinas são dados climáticos e de solo. Considerando a complexidade envolvida na obtenção desses dados, o uso de dados

espectrais surge como uma alternativa viável e promissora. A literatura demonstra que modelos com IVs tendem a apresentar resultados satisfatórios na predição e estimativa de parâmetros agronômicos (Desloires et al., 2023; Schwalbert et al., 2018; Shammi & Meng, 2021; Son et al., 2014; Souza et al., 2022; Taşan et al., 2022; Tedesco, de Oliveira, et al., 2021), sem a necessidade de coleta de diversas variáveis independentes, tornando o processo de desenvolvimento de modelos menos moroso, porém, robusto.

A utilização da MTR oferece vantagens significativas em relação aos métodos de predição univariada, especialmente pela sua capacidade de reduzir o risco de overfitting e por considerar as interações entre diferentes tipos de variáveis (Borchani et al., 2015). Essa característica é crucial, uma vez que as áreas de produção agrícola exibem variabilidades temporais e espaciais. A incorporação de variáveis independentes (IVs) pode ser especialmente útil para abordar essas variabilidades, uma vez que o sensoriamento remoto é amplamente utilizado para identificação da variabilidade. Assim, integrar IVs como variáveis preditoras à técnica de MTR pode permitir a identificação eficaz da variabilidade de múltiplas variáveis em campos comerciais de amendoim. Disto isto, os objetivos desta pesquisa são: 1) Antecipar em até 30 dias antes da colheita a predição de múltiplas variáveis em áreas comerciais de amendoim para subsidiar a adoção da colheita inteligente. 2) Determinar qual algoritmo melhor explica a variabilidade do PMI e da produtividade do amendoim. 3) Ver o potencial uso do MTR com IVs para determinar o ponto ótimo de colheita e o rendimento do amendoim.

2. Material e Métodos

Os experimentos foram realizados em 11 áreas comerciais dedicadas ao cultivo de amendoim em sucessão a cana-de-açúcar, situadas na Mesorregião de Ribeirão Preto e Araraquara, no estado de São Paulo, Brasil, ao longo de duas safras consecutivas (2020/2021 e 2021/2022). Essas áreas foram escolhidas com base em suas características específicas, incluindo tipos de solo e diferentes cultivares, conforme descrito na Tabela 4.1.

Tabela 4.1. Informações sobre as áreas de estudo para as duas Safras.

AÁrea	Local	Cultivar	Solo	Data de colheita (dias após a semeadura)	Ciclo (dias)
Season 2020/2021					
1	Ibitinga	IAC OL3	Latossolos Vermelho Distróficos	120 DAS	120
2	Pradópolis	IAC OL3	Latossolos Vermelho Distroferricos	132 DAS	120
3	Santa Ernestina 1	IAC OL3	Latossolos Vermelho Distróficos	115 DAS	120
4	Taiuva 1	IAC OL3	Argissolos Vermelho Eutróficos	115 DAS	120
5	Monte Alto 1	IAC OL3	Argissolos Vermelho Eutróficos	117 DAS	120
6	Monte Alto 2	IAC OL3	Argissolos Vermelho Eutróficos	115 DAS	120
Season 2021/2022					
7	Taiuva 2	IAC OL3	Latossolos Vermelho Distroficos	122 DAS	120
8	Santa Ernestina 2	IAC OL3	Latossolos Vermelho Distroficos	118 DAS	120
9	Guariba	IAC 503	Latossolos Vermelho Distroficos	145 DAS	150
10	Jaboticabal	IAC 503	Latossolos Vermelho Distroferricos	145 DAS	150
11	Taquaritinga	IAC 503	Argissolos Vermelho Eutróficos	148 DAS	150

Na safra 2020/2021, os experimentos foram conduzidos com grid amostral de 20 pontos de coleta, distribuídos uniformemente a cada 50 metros em sistema de faixas. Já na safra subsequente, 2021/2022, o número de pontos de amostragem foi ampliado para 30, mantendo-se a distância de 50 metros entre os pontos (Figura 4.1). No total, o banco de dados adquirido nas duas safras foi de 270 amostras.




Figura 4.1. Figura 4.1. Localização das áreas experimentais utilizadas nas análises das safras 2020/2021 e 2021/2022. A figura (A) apresenta a localização do estado de São Paulo no contexto do território nacional brasileiro. A figura (B) destaca a divisão das mesorregiões do estado de São Paulo, com ênfase nas regiões de Ribeirão Preto e Araraquara, onde os experimentos foram conduzidos. A figura (C) detalha a distribuição espacial das áreas experimentais nas duas safras analisadas. Os pontos amarelos representam as áreas monitoradas na safra 2020/2021, enquanto os pontos verdes correspondem às áreas da safra 2021/2022.

Os pontos de coleta em campo foram georreferenciados utilizando uma Aeronave Remotamente Pilotada (RPA) do tipo multirrotor, modelo DJI P4 Multispectral (Shenzhen, China), que foi operada de forma automática por meio do aplicativo DJI Ground Station Pro. Esse RPA encontrava-se equipado com um receptor GNSS multifrequencial, capaz de captar sinais de diversas constelações, como GPS, GLONASS, BeiDou e Galileo, garantindo uma precisão posicional horizontal de 1 cm + 1 ppm e vertical de 2 cm + 1 ppm (DJI D-RTK2, Shenzhen, China). Em todas as áreas, utilizou-se cal para demarcar os pontos amostrados, assim como os pontos de controle nos limites da área para melhor precisão no georreferenciamento. Após o processamento, os ortomosaicos foram usados para identificar os pontos amostrados em campo e criar um arquivo vetorial com o grid amostral.

A determinação da produtividade e da maturação do amendoim foi realizada um dia antes do arranquio mecanizado. Para a produtividade, em cada ponto amostral, foram coletadas manualmente todas as plantas presentes em uma armação de 2 m². As vagens desprendidas naturalmente localizadas abaixo e acima do solo foram descartadas por representarem perdas na colheita. Posteriormente, procedeu-se à trilha manual e à limpeza do material, removendo impurezas como torrões, folhas e ramos. As amostras foram colocadas em estufa a 105 °C por 24 horas até atingirem massa constante para então, determinar a massa seca das vagens. Isso permitiu calcular a produtividade em kg ha⁻¹ com os valores sendo ajustados para a umidade de 8% (Figura 2).

Para a análise de maturação, oito plantas foram coletadas em cada ponto de amostragem. Todos os frutos presentes nas plantas da amostra foram removidos, resultando em uma média de 150 a 250 vagens para cada ponto. Os pontos de coleta foram escolhidos aleatoriamente dentro de um raio de 10 metros a partir do centro de cada parcela. Posteriormente, todas as vagens passaram pelo processo de remoção do exocarpo, utilizando uma lavadora de alta pressão, de acordo com o método Hull-Scrape. Após a remoção do exocarpo, as vagens foram classificadas na tabela de maturação, utilizando a coluna de cores que indica o grau de maturação das vagens de amendoim. Para determinar o índice de maturação do amendoim (PMI), calculou-se a quantidade de vagens maduras, que são as cores marron e preta, dividido pelo total de vagens imatura e madura. As cores que determinam os níveis de maturidade do amendoim encontram-se na Figura 4.2.




Figure 4.2. Esquema representativo da metodologia aplicada.

2.1. Aquisição da Imagem de Satélite

O monitoramento das áreas de cultivo foi realizado em cinco datas distintas antes da colheita do amendoim, utilizando imagens de satélite capturadas a 30, 20, 14, 8 e 1 dia antes da colheita (DBH). As imagens de reflectância da superfície foram fornecidas pelo sensor da plataforma CubeSat PlanetScope (PS), que conta com uma constelação de mais de 180 nanossatélites capazes de capturar imagens diárias com resolução espacial de 3 metros. Para este estudo, foram utilizadas quatro bandas espectrais adquiridas de imagens do sensor PS2.SD: Azul (465-515nm), Verde (547-585nm), Vermelho (650-680nm) e Infravermelho Próximo (845-885nm).

Para este estudo, foram selecionados exclusivamente Índices de Vegetação (IVs) com base em evidências científicas que comprovam sua eficácia na predição da maturação do amendoim de forma isolada (Santos et al., 2022; 2020; Souza et al.). O objetivo central é avaliar se a integração do sensoriamento remoto com técnicas de inteligência artificial é suficientemente robusta para prever simultaneamente duas variáveis biofísicas críticas, como a maturação e a produtividade, no contexto do cultivo de amendoim.

Para a extração dos valores de reflectância, foi utilizado o software QGIS (Free software Inc, Boston, Estados Unidos), uma ferramenta de código aberto amplamente empregada em análises geoespaciais. Primeiramente, foram gerados buffers de 3 metros dos pontos georreferenciados em todas as áreas de estudo. Após a criação dos buffers, foi utilizada a função "Calculadora Raster" do QGIS para calcular os Índices de Vegetação (IVs) (Tabela 4.2).

Tabela 4.2. Índices de Vegetação utilizados como entrada nos modelos preditivos.

IV *	Equação	Referência
NDVI	$\frac{NIR - Red}{NIR + Red}$	Rouse et al., (1974)
GNDVI	$\frac{NIR - Green}{NIR + Green}$	Gitelson e Merzlyak., (1996)
MNLI	$\frac{(NIR^2 - Red)(1 + L^{**})}{(NIR^2 + Red + L^{**})}$	Gong et al., (2003)
EVI	$\frac{2.5(NIR - Red)}{(L^{**} + NIR + C1Red - C2Blue)}$	Justice et al., (1998)
NLI	$\frac{NIR^2 - Red}{NIR^2 + Red}$	Goel and Qin., (1994)
SR	$\frac{Red}{NIR}$	Jordan., (1969)
SAVI	$\frac{Red}{(1 + L^{**})(NIR - Red)}$	Huete., (1988)
	$(L^{**} + NIR + Red)$	

NDVI: Índice de Vegetação por Diferença Normalizada; GNDVI: Índice de Vegetação por Diferença Normalizada Verde; MNLI: Índice Não Linear Modificado; EVI: Índice de Vegetação Aprimorado; NLI: Índice Não Linear; SAVI: Índice de Vegetação Ajustado; SR: Razão Simples; *IV = Índice de Vegetação **L = 0,5; C1 = 6; C2 = 7,5.

2.2. Análise de Dados

Em nosso estudo, utilizamos a análise de Diagramas de Caixa (boxplots) para explorar o comportamento e a distribuição dos dados, além de identificar e filtrar todos os pontos discrepantes relacionados à produtividade e maturação em cada área de estudo (Material Suplementar). Boxplots foram gerados tanto para a produtividade quanto para o PMI em todos os modelos aplicados nas diferentes datas de predição. Essa visualização permitiu uma comparação clara e direta entre os dados observados em campo e as predições geradas pelos algoritmos, facilitando a avaliação da acurácia e consistência dos modelos preditivos.

A Regressão Multivariada (MTR) é fundamental para a análise de questões complexas que envolvem múltiplas variáveis de resposta contínuas, o que significa que vários alvos contínuos são considerados simultaneamente. Normalmente, essas situações apresentam características específicas (Borchani et al., 2015). Um conjunto de entrada X com m características, de tal forma que cada exemplo j esteja associado a um vetor de

entrada ($X_j = (X_{j1}, X_{j2}, X_{j3}... X_{jm})$); Um conjunto de entrada Y com d alvos contínuos, de tal forma que cada exemplo j esteja associado a um vetor de entrada ($Y_j = (Y_{j1}, Y_{j2}, Y_{j3}... Y_{jd})$); Um conjunto de amostras D com n pares de X_j e Y_j , com $1 \leq j \leq n$, ou seja, $D = \{(X_1, Y_1), ..., (X_n, Y_n)\}$.

O amendoim é uma cultura caracterizada por um crescimento indeterminado, que resulta em uma considerável variabilidade tanto na maturação quanto na produtividade. Essa variabilidade dificulta a determinação do momento ideal para a colheita, bem como a estimativa da quantidade de vagens que se desenvolvem abaixo do solo. Para enfrentar esses desafios, a Regressão Multi-Alvo (MTR) foi empregada com o intuito de prever o rendimento e o PMI. Neste contexto, foram utilizados os algoritmos Random Forest (RF) e K-Nearest Neighbors (KNN) para analisar a variabilidade das variáveis dependentes, utilizando variáveis independentes (IVs) como entradas. Essas técnicas são reconhecidas pela sua capacidade de resolver problemas complexos em múltiplas tarefas, evitando viés e problemas de viabilidade computacional (Chlingaryan et al., 2018).

O treinamento (80% dos dados) e o Teste (20 % dos dados) dos modelos foram realizados por meio de ferramentas oferecidas pelo pacote Scikit-learn (Pedregosa et al., 2011), uma biblioteca Python voltada para aprendizado de máquina, que se baseia na SciPy. Os conjuntos de dados foram normalizados na faixa de 0 a 1 utilizando o método StandardScaler, e a otimização dos hiperparâmetros foi realizada com o GridSearchCV. A validação cruzada foi aplicada em dez iterações, assegurando um número adequado de passagens para mitigar o risco de overfitting (Duan et al., 2014).

A análise do diagrama de Sankey foi realizada para visualizar o fluxo de dados, proporcionando uma compreensão mais profunda dos modelos gerados em função da rede hierárquica das simulações testadas. O diagrama de Sankey ilustra as relações multiníveis e classifica os nós por nível. A primeira classe de nós representa os algoritmos testados, enquanto a segunda classe exibe as variáveis independentes do modelo. A terceira classe apresenta as datas possíveis para as previsões, e, finalmente, a última classe de nós demonstra as variáveis de saída. Essa abordagem visual permite a identificação clara das interações entre os componentes do modelo, facilitando a interpretação dos resultados e a validação das simulações.

A eficiência dos algoritmos foi avaliada por meio de gráficos de resíduos, que permitiram analisar a discrepância nos erros obtidos em cada modelo. Além disso, utilizou-se o gráfico de radar para visualizar e comparar a acurácia dos modelos, com base no cálculo do Erro Médio Absoluto (MAE), conforme apresentado na equação (1).

Essa abordagem possibilitou identificar padrões de erro, fornecendo uma análise detalhada do desempenho preditivo dos algoritmos.

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

Em que, n é o número de dados, Y_i são o valor da variável observada em campo e $\bar{Y}_i$ são o valor, da variável predita.

3. Resultados

No gráfico do PMI para os modelos RF e KNN (Figura 4.4), observa-se que as previsões seguem de perto a distribuição dos valores observados ao longo dos diferentes dias antes da colheita (DBH). Contudo, o modelo RF apresenta uma menor variabilidade nas previsões em comparação ao KNN, especialmente nos dias 16 e 01 DBH, como indicado pela amplitude mais estreita dos boxplots. Isso sugere que o RF oferece previsões mais consistentes e menos dispersas ao longo do tempo, no entanto, ambos os modelos têm dificuldade para determinar a variabilidade dos dados de campos nas previsões. As medianas dos valores preditos pelo RF estão mais alinhadas com as medianas dos valores observados em datas mais próximas à colheita. Outro ponto a destacar é a presença de outliers em todas as datas de previsões para o KNN, o que pode influenciar negativamente os modelos para este algoritmo.

Para a Produtividade, os resultados seguem uma tendência similar, com o RF mostrando novamente uma menor variabilidade nas previsões comparadas ao KNN. Em ambos os modelos, há uma correspondência razoável entre os valores observados e previstos principalmente quando comparamos as médias observadas e preditas, mas o RF se destaca por apresentar menos outliers e uma distribuição mais concentrada em torno da mediana. No entanto, é notável que as previsões para ambos os modelos tendem a mostrar maior variabilidade nos dias mais próximos à colheita, o que pode refletir a crescente complexidade de prever a produtividade com precisão à medida que o ciclo da cultura avança. Esses resultados indicam que o modelo RF é menos eficaz em capturar as variações nas variáveis biofísicas, apresentando menor variabilidade nas previsões tanto para o PMI quanto para a Produtividade ao longo do tempo.




Figura 4.4. Comparação entre os valores observados e preditos para o índice de maturação fisiológica (PMI) e a produtividade (Yield) de amendoim durante a fase de teste dos modelos Random Forest (RF) e K-Nearest Neighbors (KNN). Cada boxplot apresenta os dados observados (Obs.) e preditos (Pred.) para diferentes momentos antes da colheita (DBH – dias antes da colheita): 30, 22, 16, 07 e 01 DBH. Os gráficos superiores mostram o desempenho preditivo para o PMI nos modelos RF (esquerda) e KNN (direita), enquanto os gráficos inferiores exibem os resultados para a produtividade, também com RF (esquerda) e KNN (direita).


A análise dos resíduos dos modelos KNN e RF ao longo de diferentes datas antes da colheita revela uma tendência consistente de maior variabilidade nos resíduos da produtividade em comparação ao PMI (Figura 4.5). Ambos os modelos demonstram desafios nas previsões da produtividade, especialmente em períodos mais próximos da colheita, onde a variabilidade dos resíduos é acentuada, com amplitudes que variam entre -4500 kg/ha a +3000 kg/ha para a produtividade. No entanto, o modelo RF mostrou-se ligeiramente mais robusto em manter os resíduos mais centralizados em torno de zero, especialmente nos dias 16 e 7 DPC.

O modelo KNN, embora capaz de seguir as tendências gerais dos dados observados, apresentou maior dispersão dos resíduos, particularmente em 1 DPC. Essa maior variabilidade indica uma menor consistência do KNN na predição das variáveis biofísicas. Isso é evidente na predição de produtividade, em que as flutuações dos resíduos sugerem uma menor assertividade do modelo para apoiar decisões próximas à colheita.

A um dia da colheita, tanto o KNN quanto o RF demonstram dificuldades para diminuir o erro das previsões, com ambos os modelos mostrando aumentos na dispersão

dos resíduos. No entanto, o RF ainda mantém uma vantagem relativa sobre o KNN, com uma menor amplitude dos resíduos e uma maior centralização, o que demonstra sua adequação para predições em fases avançadas do ciclo de crescimento.

Observou-se que ambos os algoritmos (KNN e RF) apresentaram comportamentos na dispersão dos dados semelhantes aos 16, 7 e 1 DBH para a produtividade. Outra característica observada é a presença de pontos críticos de erro em ambas as variáveis. Quando ocorre um pico de superestimação na produtividade, o PMI exibe um pico oposto, de subestimação. Isso significa que, em datas próximas à colheita, esses comportamentos de erro se invertem entre as variáveis, sugerindo uma relação inversa entre os picos de erro de produtividade e maturação.






Figura 4.5. Análise de resíduos para os algoritmos RF e KNN para análise de subestimação e superestimação do PMI e produtividade do amendoim.

Ao observar os valores de MAE para a produtividade, verifica-se que o modelo KNN apresenta menores valores de MAE nos dias mais distantes da colheita (30 e 22 DBH), indicando uma maior precisão nessas etapas iniciais (Figura 4.5). Especificamente, o KNN tem um MAE de 800,356 kg/ha aos 30 DBH, enquanto o RF

mostra um MAE de 954,123 kg/ha, sugerindo que o KNN é mais eficaz para predições antecipadas de produtividade. No entanto, à medida que a colheita se aproxima (especialmente a 1 DBH), o RF demonstra uma maior precisão, com um MAE de 1005,791 kg/ha comparado aos 1094,255 kg/ha do KNN, o que indica ligeira vantagem na predição com o RF em datas próximas ao período de colheita.

Quanto ao Índice de Maturação do Amendoim (PMI), o KNN apresenta um desempenho ligeiramente superior nos dias 30 e 22 DBH, com MAEs de 0,098% e 0,082%, respectivamente, em comparação com os MAEs de 0,104% e 0,086% do RF. Contudo, à medida que o período de colheita se aproxima, o RF torna-se novamente mais preciso, particularmente a 1 DBH, com um MAE de 0,087% em comparação aos 0,113% do KNN. Os gráficos de radar reforçam essas observações, mostrando que o KNN tem uma vantagem inicial na previsão tanto de produtividade quanto de PMI, mas essa vantagem diminui à medida que a colheita se aproxima, com o RF se destacando em previsões mais próximas da colheita.

	DAYS BEFORE HARVEST (DBH)	YIELD (KG/HA)		PEANUT MATURITY INDEX (PMI)	
		KNN	RF	KNN	RF
MAE	30 DBH	800,356	954,123	0,098	0,104
	22 DBH	954,869	1007,949	0,082	0,086
	16 DBH	876,026	1071,330	0,105	0,086
	7 DBG	1039,236	1036,361	0,115	0,117
	1 DBH	1094,255	1005,791	0,113	0,087




Figura 4.5. Desempenho dos modelos KNN e RF para produtividade e maturação

4. Discussão

Até o presente momento nenhum estudo desenvolveu modelos de predição das variáveis de maturação e produtividade do amendoim integrando sensoriamento remoto e Regressão Multialvo (MTR). Na literatura, foram desenvolvidos métodos para estimar parâmetros biofísicos da cultura do amendoim, como a maturação (Santos et al., 2021; Souza et al., 2022). Oliveira et al., 2024, utilizou técnicas de MTR para também estimar a biomassa e a maturação do amendoim utilizando IVs e Bandas espectrais verificando potencial neste método. No entanto, nosso trabalho encontrou resultados distintos com erros menores e apresentou outras respostas, principalmente no que diz respeito ao poder de predição, o qual é o primeiro desenvolvido para a cultura do amendoim.

Observamos que a utilização de algoritmos MTR dificulta a identificação da variabilidade dos dados de campo, tendo em vista que, quando se faz estimativas de

apenas uma variável dependente, a precisão e acurácia são melhores (Santos et al., 2021; Souza et al., 2022). Quando nos referimos à estimativa, trata-se da inferência de valores desconhecidos com base em dados da data correspondente. No caso da maturação, observa-se um comportamento de crescimento linear dos dados, o que facilita o ajuste dos modelos estimados (Santos et al., 2021; Santos et al., 2022; Souza et al., 2022; Oliveira et al., 2014). Esse padrão linear permite que os modelos sejam mais bem ajustados.

Compreender o funcionamento dos algoritmos e diversificar o aprendizado deles é essencial para melhorar a robustez nas predições de variáveis complexas. Nosso estudo apresentou um conjunto de dados composto por onze áreas comerciais de cultivo de amendoim, com variações em práticas de manejo, tipos de solo e cultivares. Além disto, criaram-se modelos específicos em cinco datas que antecederam a colheita para prever as variáveis dependentes. Essa diversidade de condições e a variabilidade espaço-temporal tende a oferecer um cenário favorável para avaliar o desempenho e a robustez dos algoritmos, a fim de tornar a predição escalável (Tedesco, et al., 2021).

O uso dos algoritmos KNN e RF demonstraram ser eficazes na predição do PMI e produtividade em até 30 dias antes da colheita. Para os modelos gerados, o KNN apresentou os melhores resultados em datas mais distantes da colheita, enquanto o RF melhorou o seu desempenho ao ponto que se aproximava o final do ciclo, principalmente para o PMI. Estes achados contrastam com os encontrados por Tedesco et al., (2021) que observaram resultados superiores do RF em estádios iniciais no cultivo da batata.

Oliveira et al. (2024) relataram que o algoritmo KNN superou o RF na estimativa de maturação e biomassa do amendoim também usando MTR. No entanto, não foi possível comparar diretamente o comportamento dos modelos em datas específicas, pois o estudo adotou uma abordagem diferente, sem a geração de modelos preditivos por datas. Essa abordagem por datas é de suma importância quando se pensa na aplicação da predição visando a colheita inteligente, pois a determinação antecipada da maturação e produtividade permite melhor planejamento da gestão, logística e regulagens de máquinas. Essa diferença de abordagem limita uma análise temporal mais detalhada, que em nosso estudo evidenciou o KNN como mais eficaz em fases iniciais do ciclo, enquanto o RF mostrou superioridade nas fases finais. Esses mesmos autores observaram que a biomassa do amendoim não segue um padrão linear, com comportamento decrescente registrado no final do ciclo. Essa variação pode ter sido um fator decisivo para o

desempenho divergente dos algoritmos ao longo do tempo, dado que a biomassa afeta diretamente os valores dos IVs.

O KNN, por sua natureza, baseia as predições nos exemplos de treinamento mais próximos no conjunto de dados, calculando a média dos k-vizinhos mais próximos (Tedesco et al., (2021). Isso funciona bem em situações em que os padrões são regulares, como em datas mais longes da colheita, quando as variáveis biofísicas ainda estão em estágios de crescimento mais lineares (Oliveira et al., 2024). Em contraste, o RF, como modelo baseado em árvores de decisão, tem uma vantagem na manipulação de dados complexos e não lineares, especialmente em estágios mais avançados do ciclo de cultivo, em que a variabilidade dos dados aumenta. Embora o RF possa enfrentar desafios ao lidar com dados colineares, sua habilidade de processar muitas variáveis e suas interações o torna mais eficaz nas fases finais do desenvolvimento do amendoim, quando a biomassa e outros fatores se tornam mais complexos. Nessas condições, o RF supera o KNN, que perde eficiência à medida que a variabilidade dos dados cresce.

Os resultados deste estudo ressaltam uma nova abordagem que integra dados de Índices de Vegetação com técnicas de modelo MTR para predizer de forma simultânea duas variáveis biofísicas críticas, como a maturação e a produtividade. A antecipação dessas variáveis-chave pode revolucionar a prática da colheita inteligente, especialmente ao enfrentar o desafio de identificar o ponto ideal de colheita e predizer o rendimento com antecedência. Esse avanço é particularmente relevante para culturas como o amendoim, que apresenta características complexas, como o crescimento indeterminado e o desenvolvimento subterrâneo dos frutos (Boote, 1982).

Observa-se que os modelos de estimativa de outros estudos demonstram maior precisão e acurácia em comparação com o modelo de predição, no entanto, a predição foi mais eficiente quando comparado com a estimativa realizada em estudo que utilizou o MTR. Diante disso, é fundamental realizar estudos adicionais que comparem o desempenho de modelos preditivos com alvo único e multi-alvo para a cultura do amendoim. Esses estudos permitirão identificar qual abordagem possui maior potencial para determinar o ponto ótimo de colheita, visando a gestão na colheita e pós-colheita. Outra questão para ser levada em consideração é a possibilidade de inserir outras variáveis preditivas, tendo em vista que, o uso exclusivo de IVs demonstrou não ser suficiente para acompanhar a variabilidade existente em campo usando o MTR.

5. Conclusão

Os achados deste estudo destacam a complexidade da predição simultânea de duas variáveis, evidenciando o potencial do uso de modelos de regressão multialvo (MTR) aliados a dados de sensoriamento remoto. A predição antecipada da maturação e da produtividade apresentou erros inferiores a 0.10 e 1000 kg.ha⁻¹, respectivamente, demonstrando o potencial dos modelos. Os algoritmos KNN e RF foram eficazes na antecipação da maturação e da produtividade do amendoim em até 30 dias antes da colheita, proporcionando informações valiosas para a tomada de decisão antecipada na gestão da colheita. O uso integrado das ferramentas de SR e MTR apresentou potencial para prever ambas as variáveis simultaneamente, no entanto, os modelos apresentam dificuldades para identificar a variabilidade em campos de produção tão diversos.

Estudos futuros devem explorar a utilização de outras variáveis que possam ajudar os algoritmos a identificar a variabilidade de campo para determinar o ponto ótimo de colheita, levando em consideração essa variabilidade, para auxiliar o produtor com ajustes nas regulagens das máquinas buscando desenvolver práticas de colheita inteligente para o amendoim. Isso poderá otimizar tanto a gestão da colheita quanto o pós-colheita, reduzindo perdas quali-quantitativas e aumentando a eficiência na cadeia produtiva.

6. Referências

- Bantchina, B. B., Qaswar, M., Arslan, S., Ulusoy, Y., Gündoğdu, K. S., Tekin, Y., & Mouazen, A. M. (2024). Corn yield prediction in site-specific management zones using proximal soil sensing, remote sensing, and machine learning approach. *Computers and Electronics in Agriculture*, 225, 109329. <https://doi.org/10.1016/J.COMPAG.2024.109329>
- Boote, K. J. (1982). Growth Stages of Peanut (*Arachis hypogaea* L.)1. *Peanut Science*, 9(1), 35–40. <https://doi.org/10.3146/i0095-3679-9-1-11>
- Borchani, H., Varando, G., Bielza, C., & Larranaga, P. (2015). A survey on multi-output regression. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 5(5), 216-233.
- Chlingaryan, A., Sukkarieh, S., & Whelan, B. (2018). Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. *Computers and electronics in agriculture*, 151, 61-69.
- Desloires, J., Ienco, D., & Botrel, A. (2023). Out-of-year corn yield prediction at field-scale using Sentinel-2 satellite imagery and machine learning methods. *Computers*

and *Electronics in Agriculture*, 209, 107807.
<https://doi.org/10.1016/J.COMPAG.2023.107807>

Duan, H., & Qiao, P. (2014). Pigeon-inspired optimization: a new swarm intelligence optimizer for air robot path planning. *International journal of intelligent computing and cybernetics*, 7(1), 24-37.

Farjam, A., Omid, M., Akram, A., & Fazel Niari, Z. (2014). A Neural Network Based Modeling and Sensitivity Analysis of Energy Inputs for Predicting Seed and Grain Corn Yields. *Journal of Agricultural Science and Technology*, 16(4), 767–778.
<http://jast.modares.ac.ir/article-23-5916-en.html>

Gitelson, A. A., & Merzlyak, M. N. (1996). Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. *Journal of plant physiology*, 148(3-4), 494-500.

Goel, N.S.; Qin, W. Influences of Canopy Architecture on Relationships between Various Vegetation Indices and LAI and Fpar: A Computer Simulation. *Remote Sensing Reviews* 1994, 10, 309–347, doi:10.1080/02757259409532252.

Gong, P.; Pu, R.; Biging, G.S.; Larrieu, M.R. Estimation of Forest Leaf Area Index Using Vegetation Indices Derived from Hyperion Hyperspectral Data. *IEEE Transactions on Geoscience and Remote Sensing* 2003, 41, 1355–1362, doi:10.1109/TGRS.2003.812910

Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1–2), 195–213.
[https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)

Jordan, C. F. (1969). Derivation of leaf-area index from quality of light on the forest floor. *Ecology*, 50(4), 663-666.

Júnior, M. R. B., de Almeida Moreira, B. R., dos Santos Carreira, V., de Brito Filho, A. L., Trentin, C., de Souza, F. L. P., ... & Shiratsuchi, L. S. (2024). Precision agriculture in the United States: A comprehensive meta-review inspiring further research, innovation, and adoption. *Computers and Electronics in Agriculture*, 221, 108993.

Junior, S. B., Mastelini, S. M., Barbon, A. P. A., Barbin, D. F., Calvini, R., Lopes, J. F., & Ulrici, A. (2020). Multi-target prediction of wheat flour quality parameters with near infrared spectroscopy. *Information processing in agriculture*, 7(2), 342-354.

Justice, C.O.; Vermote, E.; Townshend, J.R.G.; Defries, R.; Roy, D.P.; Hall, D.K.; Salomonson, V.V.; Privette, J.L.; Riggs, G.; Strahler, A.; et al. The Moderate Resolution

Imaging Spectroradiometer (MODIS): Land Remote Sensing for Global Change Research. *IEEE Transactions on Geoscience and Remote Sensing* 1998, 36, 1228–1249, doi:10.1109/36.701075.

McFadden, J., Njuki, E., & Griffin, T. (2023). *Precision Agriculture in the Digital Era: Recent Adoption on U.S. Farms*. <https://doi.org/10.22004/AG.ECON.333550>

Michaelides, S. C. (Ed.). (2008). *Precipitation: advances in measurement, estimation and prediction*. Springer Science & Business Media.

Oliveira, M. F., Carneiro, F. M., Ortiz, B. V., Thurmond, M., Oliveira, L. P., Bao, Y., Sanz-Saez, A., & Tedesco, D. (2024). Predicting below and above-ground peanut biomass and maturity using multi-target regression. *Computers and Electronics in Agriculture*, 218, 108647. <https://doi.org/10.1016/J.COMPAG.2024.108647>

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12, 2825-2830.

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec. Publ*, 351(1), 309.

Santos, A. F., Lacerda, L. N., Rossi, C., Moreno, L. D. A., Oliveira, M. F., Pilon, C., Silva, R. P., & Vellidis, G. (1993). Using UAV and Multispectral Images to Estimate Peanut Maturity Variability on Irrigated and Rainfed Fields Applying Linear Models and Artificial Neural Networks. *Volume 14, Issue 1, 14(1)*. <https://doi.org/10.3390/rs14010093>

Schwalbert, R. A., Amado, T. J. C., Nieto, L., Varela, S., Corassa, G. M., Horbe, T. A. N., Rice, C. W., Peralta, N. R., & Ciampitti, I. A. (2018). Forecasting maize yield at field scale based on high-resolution satellite imagery. *Biosystems Engineering*, 171, 179–192. <https://doi.org/10.1016/J.BIOSYSTEMSENG.2018.04.020>

Shammi, S. A., & Meng, Q. (2021). Use time series NDVI and EVI to develop dynamic crop growth metrics for yield modeling. *Ecological Indicators*, 121, 107124. <https://doi.org/10.1016/J.ECOLIND.2020.107124>

Son, N. T., Chen, C. F., Chen, C. R., Minh, V. Q., & Trung, N. H. (2014). A comparative analysis of multitemporal MODIS EVI and NDVI data for large-scale rice yield estimation. *Agricultural and Forest Meteorology*, 197, 52–64. <https://doi.org/10.1016/J.AGRFORMET.2014.06.007>

Souza, J. B. C., de Almeida, S. L. H., Freire de Oliveira, M., Dos Santos, A. F., Filho, A. L. de B., Meneses, M. D., & Silva, R. P. da. (2022). Integrating Satellite and

UAV Data to Predict Peanut Maturity upon Artificial Neural Networks. *Agronomy*, 12(7), 1512. <https://doi.org/10.3390/agronomy12071512>

Taşan, S., Cemek, B., Taşan, M., & Cantürk, A. (2022). Estimation of eggplant yield with machine learning methods using spectral vegetation indices. *Computers and Electronics in Agriculture*, 202, 107367. <https://doi.org/10.1016/J.COMPAG.2022.107367>

Tedesco, D., Almeida Moreira, B. R. de, Barbosa Júnior, M. R., Papa, J. P., & Silva, R. P. da. (2021). 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. <https://doi.org/10.1016/j.compag.2021.106544>

Tedesco, D., de Oliveira, M. F., dos Santos, A. F., Costa Silva, E. H., de Souza Rolim, G., & da Silva, R. P. (2021). Use of remote sensing to characterize the phenological development and to predict sweet potato yield in two growing seasons. *European Journal of Agronomy*, 129, 126337. <https://doi.org/10.1016/J.EJA.2021.126337>

Tong, A., & He, Y. (2017). *Estimating and mapping chlorophyll content for a heterogeneous grassland: Comparing prediction power of a suite of vegetation indices across scales between years*. <https://doi.org/10.1016/j.isprsjprs.2017.02.010>


van Klompenburg, T., Kassahun, A., & Catal, C. (2020). Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agriculture*, 177, 105709. <https://doi.org/10.1016/J.COMPAG.2020.105709>

Zhang, L., Zhang, Z., Luo, Y., Cao, J., Xie, R., & Li, S. (2021). Integrating satellite-derived climatic and vegetation indices to predict smallholder maize yield using deep learning. *Agricultural and Forest Meteorology*, 311, 108666. <https://doi.org/10.1016/J.AGRFORMET.2021.108666>

Zhao, B., Duan, A., Tahir Ata-Ul-Karim, S., Liu, Z., Chen, Z., Gong, Z., Zhang, J., Xiao, J., Liu, Z., Qin, A., & Ning, D. (2018). *Exploring new spectral bands and vegetation indices for estimating nitrogen nutrition index of summer maize*. <https://doi.org/10.1016/j.eja.2017.12.006>

7. Material Suplementar

Figura 4.7. Gráfico de boxplot para análise do comportamento dos dados adquiridos em campo para Produtividade e PMI.



CAPÍTULO 5 – INTEGRANDO ZONAS DE MANEJO, REDES NEURAIS ARTIFICIAIS E SENSORIAMENTO REMOTO PARA A COLHEITA INTELIGENTE DE AMENDOIM

Resumo: A cultura do amendoim ainda enfrenta limitações tecnológicas, particularmente no que se refere ao manejo da colheita. Este estudo teve como objetivo desenvolver um modelo de estimativa da maturação baseado em índices de vegetação integrando redes neurais artificiais, para determinar o melhor momento da colheita e criar mapas de colheita levando em consideração zonas de manejo e a variabilidade da maturação. O experimento foi realizado em uma área de 54,76 hectares no estado do Alabama, EUA, durante a safra de 2022. Mapas de C_{Ea} foram gerados em profundidades rasas (0-30 cm) e profundas (0-90 cm) com o sensor Veris 3100, combinadas com imagens de solo exposto para identificar 3 zonas de manejo. A maturação do amendoim foi avaliada semanalmente entre 97 e 139 DAS pelo método Hull-Scrape, e o PMI foi estimado utilizando redes neurais Perceptron Multicamadas e Função de Base Radial, com índices de vegetação (NDVI, GNDVI, NLI, MNLI) como variáveis de entrada. O desempenho dos modelos foi avaliado por métricas como Erro Médio Absoluto e coeficiente de determinação. Os resultados indicaram alta precisão e acurácia na estimativa, com o MLP sendo ligeiramente melhor ao RBF ($R^2=0,95$ e $MAE=0,05$ contra $R^2=0,93$ e $MAE=0,06$). A variabilidade espacial influenciou significativamente a maturação; a zona de manejo três atingiu o ponto ótimo de colheita aos 132 DAS, sete dias antes das demais zonas. Os mapas interpolados por IDW destacaram padrões claros de variabilidade temporal e espacial.

Palavras-chave: Agricultura de Precisão, Unidade de Gestão Diferenciada, Redes Neurais, Satélite

1. Introdução

O uso de tecnologias integradas vem gerando oportunidades para o desenvolvimento agrícola de forma substancial, principalmente no que diz respeito às práticas agrícolas mais sustentáveis. Entender a variabilidade do campo já é uma realidade em diversas aplicações da agricultura de precisão, como o uso racional da água, fertilizantes e adubos, além do monitoramento detalhado do rendimento de culturas como soja, trigo, arroz e milho (Arévalo-Hernández et al., 2024; Bondesan et al., 2023; Peralta et al., 2015). Tais informações podem ser valiosas para gestão de safras futuras e da colheita, no entanto, essas tecnologias se limitam a apenas algumas culturas (Barbosa

Júnior et al., 2024). O amendoim por exemplo, apresenta um déficit tecnológico significativo em quase todas as suas operações de manejo.

Pensando nisto, o uso de ferramentas como Sensoriamento Remoto e Inteligência Artificial (IA) combinadas com técnicas de Agricultura de Precisão (AP), podem potencializar a colheita inteligente para a cultura do amendoim que enfrenta diversos desafios, seja a falta de tecnologias na colheita, ou pelas características intrínsecas da cultura, como o crescimento indeterminado e o desenvolvimento das vagens abaixo do solo. Estudo realizado por Jordan et al., (2024) nas regiões da Carolina do Norte, Carolina do Sul e Virgínia, nos EUA, revelou que a grande maioria dos 166 produtores entrevistados apontou a maturação das vagens como o principal indicador para o sucesso da colheita do amendoim. Além disso, Jordan et al., (2016) destacaram que colheitas realizadas de forma antecipada resultam em diminuição de 5-8% do potencial produtivo, enquanto o adiamento do arranquio pode potencializar ainda mais os prejuízos. O ponto ótimo de colheita é alcançado quando a planta atinge entre 70% e 75% das vagens maduras, garantindo maior eficiência e qualidade na operação.

Nos Estados Unidos, as regiões produtoras de amendoim apresentam alta variabilidade do solo, o que pode influenciar significativamente o momento ideal de colheita, devido aos diferentes tipos de solo existentes nos talhões. O desempenho das culturas é amplamente dependente de propriedades do solo, como textura, disponibilidade de nutrientes e capacidade de armazenamento de água (Butcher et al., 2018; Sen et al., 2023). Abordagens de agricultura de precisão, como a geração de zonas de manejo (MZ) baseadas em dados de solo, podem fornecer um direcionamento mais eficaz para a gestão da colheita do amendoim. Estudos sobre a adoção de técnicas de AP nos Estados Unidos indicam que a cultura do amendoim já apresenta boa adesão ao uso de mapas de variabilidade do solo (Schimmelpfennig & Lowenberg-DeBoer, 2020), embora ainda necessite de maior incentivo para a ampliação e implementação desse tipo de análise.

A fisiologia da planta de amendoim tem influência direta na variabilidade da maturação do amendoim, fazendo com que em uma mesma planta ao final do ciclo, exista frutos maduros e imaturos, o que pode potencializar perdas quantificadas e qualitativas (Santos et al., 2022). Entender como a maturação se comporta em áreas de diferentes propriedades de solo, e sua influência com o desenvolvimento da maturação, é fundamental para compreender a dinâmica da evolução da maturação em relação à variabilidade do solo.

A determinação da maturação do amendoim é feita através do método Hull-Scrape, amplamente empregado por produtores e pesquisadores, porém, depende da experiência do operador para a classificação da maturação, sendo considerado subjetivo, demorado e pouco adequado para escalas maiores (Colvin et al., 2014). Essa técnica que é destrutiva não representa a variabilidade existente no campo de produção (dos Santos et al., 2021; Santos et al., 2022), tendo em vista que, apenas alguns pontos são coletados, sendo atribuída a maturação média para toda área.

Dito isto, identificar o ponto ótimo de colheita de maneira rápida e eficiente é um desafio que tem sido investigado em diversos estudos, que verificaram potencial no uso do SR e técnicas de Machine Learning (ML) para mapear a maturação do amendoim e determinar o melhor momento para realizar a colheita (de Almeida et al., 2023; dos Santos et al., 2021; Santos et al., 2022; Souza et al., 2022). A utilização de bandas espectrais, índices de vegetação (IVs), diferentes plataformas, como sensores orbitais, aéreo e proximais, integrados a métodos de estimativa com Machine Learning, apresentam estimativas da maturação com erro médio absoluto variando entre 0.05 a 0.10 % (de Almeida et al., 2023; dos Santos et al., 2021; Oliveira et al., 2024; Santos et al., 2022; Souza et al., 2022).

Embora o uso de tecnologias como SR e IA tenha demonstrado grande potencial em estimar a maturação e otimizar o manejo do amendoim, ainda não há estudos que avaliem a dinâmica da maturação do amendoim em áreas com alta variabilidade de solo. Estudos existentes focam na estimativa geral da maturação, mas não abordam como a interação da variabilidade do solo influencia o comportamento espacial e temporal da maturação. Verificar o potencial da integração de SR e IA para desenvolver modelos de estimativa que considerem essa variabilidade do solo, com o objetivo de gerar zonas específicas para colheita, permanece inexplorado.

Diante disto, a integração de dados de sensoriamento remoto, inteligência artificial e variabilidade do solo pode gerar modelos preditivos capazes de identificar zonas específicas prontas para a colheita dentro de áreas heterogêneas, aumentando a precisão e a eficiência da operação. Assim, objetivou-se desenvolver e avaliar um modelo de estimativa de maturação baseado em SR e IA considerando a variabilidade espacial do solo para criar zonas de manejo direcionadas à colheita inteligente do amendoim.

2. Material e Métodos

2.1. Área de Estudo e Delimitação das Zonas de Manejo

O estudo foi conduzido em um campo comercial de 54,76 ha, localizado em Eufaula, Alabama (AL), EUA, durante a safra de 2022 em área irrigada (Figura 5.1). O campo foi semeado em maio com a cultivar de amendoim tipo runner Georgia-O6G, que possui um ciclo de crescimento aproximado de 140 dias.

Realizou-se o mapeamento da condutividade elétrica aparente (ECa) do solo em toda a área de estudo com o sensor Veris 3100 (Veris Technologies, Salina, Kan., EUA). O VERIS 3100 aferiu a ECa do solo em duas profundidades, 0-30 cm (ECa-raso) e 0-90 cm (ECa-profundo). Tais informações foram utilizadas para identificar a variabilidade existente do solo a fim de gerar zonas de manejo. Além dos dados coletados de ECa (raso e profundo), utilizou-se imagens orbitais de solo exposto, em que usou-se a banda do infra-vermelho próximo (Figura 1 – material suplementar) para delimitar as zonas de manejo utilizando o software Management Zone Analyst (MZA) (Figura 5.1). Os dados de satélites de solo exposto foram adquiridos na mesma safra do estudo, para avaliar a variabilidade do solo com informações da reflectância do solo utilizando a banda do NIR para melhor identificação dos contrastes existentes na área. O MZA utiliza um algoritmo não supervisionado (fuzzy c-means) para dividir o campo em classes ou clusters (Fridgen et al., 2004) com base nas características espaciais e variáveis de entrada. Após a geração das zonas de manejo, foi realizada a alocação de 20 pontos na área de forma direcionada para representar a variabilidade espacial do campo, como apresentado a seguir.




Figura 5.1. Zonas de manejo geradas a partir da condutividade elétrica do solo e reflectância de solo exposto (NIR) com imagens PlanetScope.

2.2. Amostragem de Solo Direcionada

Após a delimitação e a definição estratégica dos pontos amostrais, realizou-se a coleta de solo nos 20 pontos previamente georreferenciados com o GNSS da Trimble (Geo 7X Handheld) e distribuídos de forma representativa nas zonas de manejo (Figura 1 – material suplementar). As análises de solo foram realizadas com trado holandês em duas profundidades, 0,30 e 0,90 cm para determinar o tipo de solo em relação a textura do solo levando em conta a proporção de argila, silte e areia. Após a coleta, as amostras foram devidamente acondicionadas, rotuladas e transportadas para o laboratório, onde foram submetidas a análises granulométricas padrão.




Figure 5.2. Mapa de localização dos pontos e da área de estudo.

2.3. Análise da Maturação do Amendoim

Após definição dos 20 pontos amostrais no campo, considerando as características contrastantes do solo, amostras de amendoim foram coletadas semanalmente a partir de 97 dias após a semeadura até a data de colheita (97, 104, 111, 118, 125, 132 e 139 DAS), utilizando uma malha amostral de 2 m². Todas as plantas dentro da área demarcada foram removidas, e as vagens foram separadas manualmente das plantas para posterior avaliação do índice de maturação do amendoim, utilizando o método Hull-Scrape descrito por (Williams & Drexler, 1981). Esse método consiste na raspagem do exocarpo do

amendoim, procedimento que foi realizado com o auxílio de uma máquina de lavar de alta pressão. As amostras utilizadas no estudo consistiram em 150 a 250 vagens, garantindo representatividade para as análises. O índice de maturação do amendoim (PMI) foi calculado usando a razão entre o somatório das vagens marrons e pretas dividido pelo total de vagens da amostra (Eq. 1):

$$PMI_{BB} = \frac{NBB}{T} \quad \text{Eq.1}$$

PMI_BB é o índice de maturação do amendoim considerando as classes de vagens marrom a preto; NBB é o número de vagens nas classes marrom e preto; T é o número total de vagens.

2.4. Imagens de Satélite e Índices de Vegetação.

A aquisição das imagens foi realizada em cinco datas antes da colheita (DBH) a partir dos 97 DAS. Devido à interferência de nuvens, as datas 104 e 111 DAS não foram monitoradas. Dito isto, as datas utilizadas para estimativa do PMI foram, 1, 7, 14, 21 e 42 DBH, durante os estádios de enchimento e desenvolvimento da maturação dos grãos. As imagens adquiridas foram do produto Super Dove (Nível 3B) da constelação de nanos satélites do PlanetScope. As imagens foram ortorretificadas calibradas radiometricamente e feita as correções no topo da atmosfera (TOA), que são os valores de reflectância calculados a partir dos dados brutos do sensor, incluindo interferências atmosféricas, como gases, vapor d'água e aerossóis. Além disto, os valores de reflectância que representam as condições diretamente na superfície terrestre (BOA) também foram corrigidos utilizando o produto refletância de superfície (SR).

As imagens PlanetScope Super Dove possuem 8 bandas multiespectrais, incluindo Coastal Blue (431-452 nm), Blue (465–515 nm), Green I (513–549 nm), Green II (547–583 nm), Yellow (600–620 nm), Red (650–680 nm), Red-Edge (697–713 nm) e NIR (845–885 nm) com resolução de 3 m (Planet, 2017). Neste estudo, quatro índices de vegetação (VIs) foram calculados a partir das imagens PlanetScope para estimar o PMI utilizando o software livre QGIS (Tabela 5.1). Inicialmente, as imagens foram exportadas para o QGIS e realizado o escalonamento dos dados, em que, transformou-se os valores de número digitas (ND) de cada banda, dividindo-os por dez mil. Posteriormente, extraiu-se as informações de reflectância das bandas a partir de um buffer

de 3 m. Para calcular o IVs, utilizou-se a ferramenta “Raster Calculator” que permiti inserir expressões matemáticas baseadas nos valores das bandas.

Tabela 5.1. Índices de Vegetação utilizados como entrada nos modelos de estimativa.

IV	Equação	Referência
NDVI	$\frac{NIR - Red}{NIR + Red}$	Rouse et al., (1974)
GNDVI	$\frac{NIR - Green}{NIR + Green}$	Gitelson e Merzlyak., (1996)
MNLI	$\frac{(NIR^2 - Red)(1 + L **)}{(NIR^2 + Red + L **)}$	Gong et al., (2003)
NLI	$\frac{NIR^2 - Red}{NIR^2 + Red}$	Goel and Qin., (1994)

2.5. Análise Estatística

A análise do comportamento dos dados de maturação do amendoim ao longo do tempo foi realizada por meio de gráficos de caixa (boxplot), que permitem visualizar a distribuição, a tendência central e a variabilidade dos dados, bem como identificar outliers. Cada boxplot representou o índice de maturação (PMI) nas diferentes datas, com a mediana indicada pela linha central da caixa e os quartis superior e inferior delimitando a dispersão central. Realizou-se ainda o gráfico de barras com a porcentagem da maturação por classes (branco, amarelo, amarelo 2, laranja, marron e preto) para entender a dinâmica temporal da maturação dentro de cada classe.

A análise de componentes principais (PCA) foi aplicada com o objetivo de reduzir a dimensionalidade dos dados e interpretar os padrões de variabilidade espacial e temporal do índice de maturação do amendoim (PMI), assim como suas relações com propriedades do solo e características espectrais. Foram consideradas 14 variáveis: o PMI aferido em cinco datas distintas, as frações texturais do solo (argila, silte e areia) em duas profundidades, a condutividade elétrica aparente (CEa) e a reflectância do solo exposto. Os dados foram coletados em 20 pontos de amostragem estrategicamente distribuídos na área experimental para capturar a variabilidade do campo.

A PCA foi realizada utilizando a matriz de correlação, assegurando a comparabilidade entre variáveis com diferentes escalas. A matriz de dados final consistiu em 20 observações (linhas) e 14 variáveis (colunas). O número de componentes principais (PCs) significativos foi determinado com base na análise dos autovalores, utilizando a

regra de Kaiser (autovalores > 1) e considerando a variância acumulada explicada (Kaiser, 1960; Jolliffe, 2002).

A análise foi implementada no software R por meio da função *prcomp*, que calcula autovalores e autovetores diretamente a partir da matriz de correlação. Embora o número de observações (20 pontos) atendesse ao critério mínimo ($m > n$), o conjunto de dados não alcançou o ideal ($m \geq 10n$), o que pode limitar a robustez estatística dos resultados. De toda forma, essa limitação foi considerada cuidadosamente na interpretação dos padrões identificados, reforçando a necessidade de cautela ao generalizar os achados. Uma vez que a matriz de dados foi concluída, os escores dos PCs individuais foram correlacionados com elevação, CEa e textura do solo. A análise de correlação foi implementada utilizando a linguagem de programação Python.

2.6. Estimativa de PMI Usando RNAs

Para construção dos modelos de estimativa do PMI, utilizou-se para a camada de entrada das redes neurais artificiais (ANNs) os índices de vegetação (VIs) mencionados anteriormente, enquanto a saída foi o PMI. Não foi necessário realizar padronização ou normalização dos dados de entrada tendo em vista que estes estão na mesma escala. Os neurônios variaram entre 1 e 25 para as redes RBF e 1 a 20 para MLP. O número de camadas ocultas para a MLP foi de 1 a 3, enquanto as interações e ciclos foram de dois mil para cada algoritmo no treinamento dos modelos. Os Hiperparâmetros foram definidos e ajustados automaticamente pelo Intelligent Problem Solver (IPS), uma ferramenta integrada ao software Statistica 7 que simplifica o processo de modelagem explorando arquiteturas e algoritmos visando encontrar a melhor solução para o problema.

A ferramenta IPS determina os números de neurônios nas camadas intermediária e usa algoritmos de clustering no treinamento como K-means (KM) e Pseudo-Inverse (PI) para a rede RBF, em que utilizou-se a função de ativação gaussiana. Para a MLP, a função de ativação foi sigmoide, no treinamento, utilizou-se o critério de seleção do melhor algoritmo de otimização (Backpropagation, Conjugate Gradient e Quick Propagation), a taxa de aprendizado e momento (Momentum), e por fim as possíveis funções de ativação (sigmoide, tangente hiperbólicas). Todos os parâmetros usados no processo encontram-se no material suplementar (Tabela 1).

O conjunto de dados foi dividido em 80% para o treinamento dos modelos e 20% para teste. Após o treinamento o desempenho dos modelos foi avaliado no conjunto de

teste, em que, as métricas empregas para tal avaliação foram o Erro Médio Absoluto (MAE) e o Coeficiente de Determinação (R^2), além disso, gerou-se mapas interpolados pelo método do inverso do quadrado (IDW) dos valores observados e estimados para verificar a aderência dos modelos aos dados de reais de campo. Por fim, gerou-se mapas de resíduo para cada algoritmo, para verificar se existem padrões sistemáticos nos erros, ou seja, regiões onde o modelo consistentemente subestima ou superestima os valores. A interpolação foi realizada utilizando o software Qgis e o coeficiente p utilizado para interpolar foi 2. O método IDW usa a média ponderada de vizinhos mais próximos com pesos proporcionais à distância inversa (Cho et al., 2021). O esquema completo da metodologia está ilustrado na Figura 5.2.





Figura 5.2. Esquema representativo da metodologia apresentada

3. Resultados

O boxplot mostra que a maturidade média cresce gradualmente entre 97 e 139 DAS, refletindo o avanço do desenvolvimento das vagens (Figura 5.3a). A variabilidade é mais evidenciada entre 111 e 132 DAS, demonstrada por intervalos interquartis maiores. Os outliers observados para as datas 132 e 139 DAS indicam que algumas áreas ou plantas apresentam maturação atrasada em relação à maioria, de toda forma, é perceptível que a variabilidade no final do ciclo diminui consideravelmente. A figura 5.3b detalha essa variabilidade, mostrando que entre 97 e 111 DAS, as vagens imaturas (branca, amarelo,

amarelo 2 e laranja) dominam. A transição das laranjas para marrons já ocorre aos 104 DAS, com as vagens marrons apresentando uma crescente, enquanto as laranjas diminuem ao longo do tempo. Os estágios pretos (maturidade máxima) se consolidam aos 125 DAS, quando a porcentagem de vagens maduras é superior as vagens imaturas com 53.2 %. Por fim, aos 139 DAS, o ponto de colheita é atingindo com 80% das vagens maduras.

a)



b)





Figura 5.3. Comportamento dos dados de maturação por boxplot (a) e desenvolvimento da maturação ao longo do tempo em área total (b)

Os resultados por zonas de manejo (MZ1, MZ2 e MZ3) evidenciam diferenças na evolução da maturação do amendoim, destacando a influência da variabilidade espacial no campo (Figura 5.4). O boxplot mostra que a maturidade média aumenta progressivamente em todas as zonas ao longo dos dias após o plantio (DAS). No entanto, MZ1 apresenta a mais datas com alta variabilidade (97, 104 e 125 DAS), com maior número de outliers que indicam pontos com maturação acelerada ou atrasada. Por outro lado, MZ3 exibe menor amplitude interquartil, em todas as datas, sugerindo maior uniformidade na maturação ao longo do tempo. A MZ2 apresenta comportamento intermediário, com maior dispersão apenas para as datas 111 e 118 DAS. É importante destacar que o comportamento dos dados apresenta a MZ2 largando atras com média de PMI menor que as demais zonas até a data 132, enquanto a MZ3 apresentou maiores médias de PMI em todas as datas.

O gráfico de barras detalha as mudanças na proporção de classes de maturação para cada zona. Em MZ1, as vagens pretas começam a predominar mais cedo, especialmente a partir de 125 DAS, sugerindo uma maturação mais acelerada nesta zona quando comparado a MZ2, que apresenta uma transição mais gradual entre os estágios de maturação, com maior proporção de vagens marrons e pretas a partir do período 132 DAS, indicando uma maturação moderada. Já em MZ3, a proporção de vagens pretas também se consolida apenas aos 125 DAS, no entanto, a porcentagem de vagens maduras está em 62%, ou seja, quase 10% acima da zona 1. Estes resultados demonstram que a todas as zonas atingiram PMI acima de 75%, com a MZ3 superando a média de 80% de maturação.

a)



b)




Figura 5.4. Comportamento dos dados de maturação por boxplo (a) e desenvolvimento da maturação ao longo do tempo dentro de cada zona de manejo (b)

A matriz de correlação evidencia as principais inter-relações entre as propriedades físicas do solo e as variáveis ambientais que influenciam a variabilidade da área de estudo (Figura 5.5a). A areia apresenta forte correlação negativa com o silte e argila, com

correlação de -0,875 e -0,937, respectivamente em 20 cm. Para a profundidade de 40 cm de areia e argila a correlação foi alta para o silte a 20 cm, enquanto, para condutividade elétrica e profundidade, a correlação foi moderada para 20 cm, enquanto para 40 cm as variáveis de condutividade elétrica apresentaram alta correlação com areia e argila.


Além disso, os índices de shallow e deep estão bem correlacionados ($r=0.675$) e possuem relação direta com a componente principal 1 (PCA1), que explicam a maior parte da variância nos dados. Estas variáveis são determinantes para caracterizar as diferenças entre zonas de manejo. Para o shal e deep, as correlações foram negativas com -0.843 e 0.754, respectivamente, enquanto, para as variáveis de textura o PCA1 apresentou correlação moderada com a areia e o silte a 8 inches, e alta correlação com areia e argila a 16 inches. A variável de elevação teve correlação positiva com o PCA1 de 0.470.

O gráfico de análise de componentes principais (PCA) apresentado mostra a separação de três zonas de manejo (MZ1, MZ2 e MZ3) no espaço dos dois primeiros componentes principais (PCA1 e PCA2), que juntos explicam 98,51% da variância total dos dados (Figura 5.5b). O PCA1 é responsável por 54,4% da variância, enquanto o PCA2 contribui com 31,4%, indicando que esses dois componentes capturam quase toda a variabilidade relevante nas características analisadas de textura solo, elevação e condutividade elétrica, fornecendo uma visão robusta da organização espacial das zonas.

A MZ1 está localizada predominantemente nos quadrantes negativos de PCA1 e PCA2, evidenciando características distintas, possivelmente associadas a maiores teores de argila e menores elevações (Tabela 1). Em contraste, a MZ2 ocupa valores elevados no eixo PCA1, próximos ao eixo horizontal de PCA2, indicando que esta zona é dominada por variáveis correlacionadas ao PCA1. A MZ3 se destaca por valores positivos elevados de PCA2, diferenciando-a significativamente de MZ1 e MZ2.

Os agrupamentos observados mostram que as zonas de manejo foram bem delimitadas com baixa sobreposição, confirmando a eficiência do método utilizado. A MZ1 apresenta maior uniformidade interna, sugerindo homogeneidade nas características do solo, enquanto MZ2 e MZ3 possuem maior dispersão dentro de suas respectivas zonas, indicando variabilidade interna que pode exigir estratégias de manejo mais específicas. A análise ressalta que as características capturadas por PCA1 e PCA2, como textura do solo, elevação e condutividade elétrica, são determinantes para a variabilidade espacial e, consequentemente, para a definição das zonas de manejo.

a)



b)




Figura 5.5. Correlação (a) e Análise de Componentes Principais (b) para validação das zonas de manejo geradas.

Os resultados destacam o momento ideal de colheita para cada zona de manejo (MZ1, MZ2 e MZ3), considerando a progressão da maturação (PMI%) e a variabilidade espacial das zonas ao longo dos dias após a semeadura (Figura 5.6). O gráfico de regressão indica um aumento contínuo da maturação em todas as zonas, com taxas

similares entre elas, mas diferentes pontos ótimos de colheita devido à variabilidade nas características do solo.

Aos 132 DAS, a MZ3 apresenta áreas prontas para colheita (verde), indicando que esta zona atinge o ponto ideal de colheita mais cedo (Figura 6). A MZ1, apesar de também mostrar alta maturação, possui 68% de maturação, o que ainda não seria o indicado para realizar a colheita, no entanto, por estar próximo do ponto ótimo, esta zona poderia ser indicada para realizar a colheita aos 132 DAS pensando no operacional. A MZ2, por sua vez, exibe ponto de maturação ideal aos 139 DAS, com a maior parte da área classificada como pronta para colheita, indicando um atraso na maturação em relação às outras zonas.

A integração dessas análises confirma que o momento ótimo de colheita varia entre as zonas devido às diferenças espaciais no solo e nas condições de maturação. Para MZ1, a colheita poderia ser realizada antes dos 139 DAS, no entanto, o mais indicado seria na última data. Para MZ2 a única possibilidade de colheita é aos 139 DAS. Já a MZ3, por outro lado, deve ser colhida somente aos 132 DAS, tendo em vista que, aos 139 DAS a zona apresenta “over maturity”, o que pode dificultar a colheita causando perdas significativas.




Figura 5.6. Evolução da média da maturação ao longo do tempo (97 a 139 DAS) (a) e mapas do momento ótimo de colheita para 7 e 1 dias antes da colheita (b).

Os resultados mostram a performance de modelos baseados em redes neurais para estimar o índice de maturação do amendoim na configuração de vagens maduras para os estágios marrons e pretos (Figura 5.7). O modelo baseado em Funções Base Radial (RBF) apresentou coeficiente de determinação $R^2=0,93$, enquanto o modelo MLP (Perceptron Multicamadas) alcançou um R^2 superior, de 0,95, indicando maior precisão do MLP na estimativa da maturação. O erro médio absoluto (MAE) foi de 0,06 para o RBF e 0,05 para o MLP, reforçando a maior acurácia do modelo MLP. Os gráficos de dispersão entre valores observados e estimados mostram que ambos os modelos seguem bem a linha de 1:1, indicando estimativas próximas aos valores reais. Os gráficos de linha ao longo das amostras indicam que o MLP mantém maior consistência nos erros estimados, enquanto o RBF tende a subestimar PMI maiores.




Figura 5.7. Gráficos de desempenho dos modelos de estimativa da maturação com RBF (a) e MLP (b)

No cenário de 7 dias antes da colheita, quando os padrões de maturação são menos desenvolvidos, o MLP se mostrou superior, ajustando-se bem às regiões com PMI moderado (0,3 a 0,7). Apesar disso, houve uma leve tendência de superestimação nas bordas das áreas de maturação avançada, com resíduos positivos entre 0,05 e 0,1. Já o modelo RBF apresentou padrões mais suavizados, porém também representou bem a maturação do amendoim no mapa (Figura 5.8).

No caso de 1 dia antes da colheita, o MLP apresentou uma representação mais fiel das áreas maduras ($PMI > 0,7$), localizadas predominantemente nas regiões centrais e sul do campo. Os resíduos gerados pelo MLP estão concentrados em valores baixos, entre -0,05 e 0,05, indicando uma baixa subestimação ou superestimação em todo o campo. Em contraste, o modelo RBF apresentou dificuldades em capturar adequadamente os padrões observados, resultando em uma superestimação nas áreas centrais e sul, com resíduos maiores que 0,15, e subestimação pontual em áreas de maior maturação, destacada pelos resíduos negativos.

De maneira crítica, os resultados indicam que o MLP é mais eficaz em capturar a complexidade dos dados observados, particularmente em fases avançadas da maturação, onde os padrões espaciais são mais definidos. O modelo RBF, por outro lado, tende a suavizar os resultados, mostrando limitações na representação de áreas com alta variabilidade espacial, tanto em períodos próximos quanto mais distantes da colheita.




Figura 5.8. Mapas de colheita e resíduos interpolados por IDW do PMI para dados observados, MLP e RBF para 7 (a) e 1 (b) dias antes da colheita (DBH).

4. Discussão

O tipo de solo influencia diretamente a produção agrícola e demanda manejos específicos para maximizar a eficiência produtiva. No entanto, quando há uma elevada heterogeneidade nos tipos de solo em uma mesma área, técnicas de agricultura de precisão

tornam-se essenciais para alcançar melhores resultados no manejo. Este estudo identificou zonas de manejo em uma área cultivada com amendoim a partir da condutividade elétrica aparente e da análise de solo exposto. Os resultados mostraram que a maturação do amendoim responde de forma distinta em cada zona, com a área de maior CEa, identificada como zona 3, atingindo a maturação ideal de forma mais rápida (Figura 1-material suplementar). A CEa têm sido utilizadas para entender a variabilidade do solo e gerar zonas de manejo, devido a sua relação com parâmetros do solo (teor de argila, teor de água, salinidade, materiais condutores do solo etc.). Além do mais, a condutividade elétrica do solo tem alta correlação com a produtividade das culturas (Clay et al., 2001).

A determinação de MZ pode ser crucial para compreender o ponto ótimo de colheita do amendoim em cada porção da lavoura. Pela média da maturação, foi possível identificar que a zona 3 apresentou potencial para colheita aos 132 DAS, ou seja, 7 dias antes da colheita realizada na área de estudo. As demais zonas só estavam aptas para colheita aos 139 DAS e observou-se que, na zona 3, a maturação já havia ultrapassado 80% nessa data, o que pode gerar perdas significativas caso as regulagens do arrancador não sejam ajustadas adequadamente (dos Santos et al., 2019; Santos et al., 2016). A maturação elevada compromete o ginóforo dos frutos, resultando em perdas no processo de inversão do amendoim, enfatizando a necessidade de realizar a colheita no momento ideal (Colvin et al., 2018; dos Santos et al., 2019) Dito isto, o melhor momento para colheita do amendoim deve ser entre 70 e 75% de maturação (Sanders et al., 1980)

A integração de ferramentas digitais como o sensoriamento remoto (SR) e a inteligência artificial (IA) com técnicas de agricultura de precisão pode direcionar a colheita do amendoim, minimizando perdas quantitativas e qualitativas e permitindo ao produtor uma gestão mais antecipada e eficiente da colheita. Estudos demonstram o potencial dessas tecnologias, seja por meio de estimativas e previsões de parâmetros agrônômicos, seja pela identificação da variabilidade espacial em áreas de cultivo, o que possibilita intervenções localizadas para otimização do manejo. As estimativas deste estudo apresentam boa precisão e acurácia, Souza et al., (2022) utilizaram os mesmos algoritmos (RBF e MLP) e índices de vegetação, e encontraram resultados semelhantes ao deste estudo, demonstrando uma consistência no uso das RNA e o SR para estimativa da maturação. Isso demonstra o potencial uso dessas técnicas visando gerar mapas estimados da maturação para realizar a colheita inteligente do amendoim.

Os mapas interpolados por IDW evidenciaram o padrão de variabilidade nas zonas de manejo, indicando que a zona 3 atingiu o ponto ótimo de colheita antes das demais

(Figura 8a). Os mapas gerados com estimativas dos algoritmos MLP e RBF representaram muito bem a variabilidade observada em campo. Esses resultados sugerem que é possível gerar mapas precisos para apoiar uma colheita mais assertiva e inteligente para o amendoim. O uso de mapas interpolados já é amplamente utilizado em trabalhos de estimativa espacial para rendimento de grãos (Bazzi et al., 2015; Cho et al., 2021b). Outro aspecto a considerar é a amostragem em zonas utilizada neste estudo, que demonstrou ser assertiva identificando a variabilidade da maturação em cada zona de manejo. Essa abordagem de amostragem baseada em zonas pode ser recomendada para análises com baixa densidade amostral, o que torna o método mais econômico e gera resultados satisfatório (Valente et al., 2024).

Embora os resultados tenham demonstrado o potencial da integração de CEa, SR e IA para direcionar a colheita, algumas limitações precisam ser abordadas em trabalhos futuros. A quantidade de pontos amostrais e a interpolação utilizada poderiam ser refinadas para aumentar ainda mais a precisão dos mapas gerados. Assim, este direciona para o desenvolvimento de estratégias ainda mais robustas e eficazes, alinhadas à agricultura digital e às demandas por sustentabilidade no campo.

5. Conclusão

A definição de zonas de manejo baseada na condutividade elétrica aparente (CEa) e na análise de solo exposto permitiu identificar diferenças significativas no comportamento da maturação entre as zonas, com a zona 3 alcançando o ponto ótimo de colheita aos 132 dias após a semeadura (DAS), enquanto as demais zonas atingiram esse estágio apenas aos 139 DAS. Esses resultados confirmam que a variabilidade do solo influencia diretamente a maturação e reforçam a necessidade de intervenções específicas em cada zona para evitar perdas associadas à maturação avançada.

Os algoritmos de redes neurais, MLP e RBF, foram eficazes na estimativa da maturação, apresentando alta precisão (R^2 de 0,95 para MLP e 0,93 para RBF) e baixos erros médios absolutos. Apesar das limitações na quantidade de pontos amostrais, os mapas interpolados capturaram os padrões de variabilidade observados em campo. Trabalhos futuros devem abordar a ampliação dos pontos de amostragem e explorar diferentes algoritmos de interpolação para melhorar a precisão dos mapas. Esses resultados destacam que a integração de SR, IA e agricultura de precisão é uma ferramenta poderosa para otimizar a colheita, aumentando a eficiência da colheita do amendoim.

6. Referências

- Arévalo-Hernández, J. J., Oliveira, E. M. de, Ferraz, G. A. e S., Polanía-Montiel, D. C., Liscano Solano, A. L., & Silva, M. L. N. (2024). The delineation of management zones using soil quality indices for the cultivation of irrigated rice (*Oryza sativa* L.) in Huila, Colombia. *Geoderma Regional*, 39, e00886. <https://doi.org/10.1016/j.geodrs.2024.e00886>
- Barbosa Júnior, M. R., Moreira, B. R. de A., Carreira, V. dos S., Brito Filho, A. L. de, Trentin, C., Souza, F. L. P. de, Tedesco, D., Setiyono, T., Flores, J. P., Ampatzidis, Y., Silva, R. P. da, & Shiratsuchi, L. S. (2024). Precision agriculture in the United States: A comprehensive meta-review inspiring further research, innovation, and adoption. *Computers and Electronics in Agriculture*, 221, 108993. <https://doi.org/10.1016/j.compag.2024.108993>
- Bazzi, C. L., Souza, E. G., Khosla, R., Uribe-Opazo, M. A., & Schenatto, K. (2015). Profit maps for precision agriculture. *Ciencia e Investigación Agraria*, 42(3), 7–7. <https://doi.org/10.4067/S0718-16202015000300007>
- Bondesan, L., Ortiz, B. V., Morlin, F., Morata, G., Duzy, L., van Santen, E., Lena, B. P., & Vellidis, G. (2023). A comparison of precision and conventional irrigation in corn production in Southeast Alabama. *Precision Agriculture*, 24(1), 40–67. <https://doi.org/10.1007/s11119-022-09930-2>
- Butcher, K., Wick, A. F., DeSutter, T., Chatterjee, A., & Harmon, J. (2018). Corn and Soybean Yield Response to Salinity Influenced by Soil Texture. *Agronomy Journal*, 110(4), 1243–1253. <https://doi.org/10.2134/agronj2017.10.0619>
- Valente, D. S. M., Pereira, G. W., Queiroz, D. M., Zandonadi R. S., Amaral, L. R., Bottega, E. L. Costa, M. M. Coelho, A. L. F., and Grift, T., (2024). Accuracy of Various Sampling Techniques for Precision Agriculture: A Case Study in Brazil. *Agriculture*, 14(12), 1–2198.
- Cho, J. B., Guinness, J., Kharel, T. P., Sunoj, S., Kharel, D., Oware, E. K., van Aardt, J., & Ketterings, Q. M. (2021). Spatial estimation methods for mapping corn silage and grain yield monitor data. *Precision Agriculture*, 22(5), 1501–1520. <https://doi.org/10.1007/s11119-021-09793-z>
- Clay, D. E., Chang, J., Malo, D. D., Carlson, C. G., Reese, C., Clay, S. A., Ellsbury, M., & Berg, B. (2001). Factors influencing spatial variability of soil apparent

electrical conductivity. *Communications in Soil Science and Plant Analysis*, 32(19–20), 2993–3008. <https://doi.org/10.1081/CSS-120001102>

Colvin, B. C., Rowland, D. L., Ferrell, J. A., & Faircloth, W. H. (2014). Development of a Digital Analysis System to Evaluate Peanut Maturity. *Peanut Science*, 41(1), 8–16. <https://doi.org/10.3146/PS13-9.1>

Colvin, B. C., Tseng, Y.-C., Tillman, B. L., Rowland, D. L., Erickson, J. E., Culbreath, A. K., & Ferrell, J. A. (2018). Consideration of peg strength and disease severity in the decision to harvest peanut in southeastern USA. *Journal of Crop Improvement*, 32(3), 287–304. <https://doi.org/10.1080/15427528.2017.1422073>

de Almeida, S. L. H., Souza, J. B. C., Pilon, C., Teixeira, A. H. D. C., dos Santos, A. F., Sysskind, M. N., Vellidis, G., & da Silva, R. P. (2023). Performance of the SAFER model in estimating peanut maturation. *European Journal of Agronomy*, 147. <https://doi.org/10.1016/j.eja.2023.126844>

dos Santos, A. F., Corrêa, L. N., Lacerda, L. N., Tedesco-Oliveira, D., Pilon, C., Vellidis, G., & da Silva, R. P. (2021). High-resolution satellite image to predict peanut maturity variability in commercial fields. *Precision Agriculture*, 22(5), 1464–1478. <https://doi.org/10.1007/s11119-021-09791-1>

dos Santos, A. F., da Silva, R. P., Zerbato, C., de Menezes, P. C., Kazama, E. H., Paixão, C. S. S., & Voltarelli, M. A. (2019). Use of real-time extend GNSS for planting and inverting peanuts. *Precision Agriculture*, 20(4), 840–856. <https://doi.org/10.1007/s11119-018-9616-z>

Fridgen, J. J., Kitchen, N. R., Sudduth, K. A., Drummond, S. T., Wiebold, W. J., & Fraisse, C. W. (2004). Management zone analyst (MZA) software for subfield management zone delineation. *Agronomy Journal*, 96(1), 100–108.

Jolliffe, I. T. (2002). "Principal Component Analysis." Springer Series in Statistics.

Jordan, D. L., Anco, D., Balota, M., & Brandenburg, R. L. (2024). Farmer insights on harvesting peanut: A survey from the Virginia–Carolina region of the United States. *Crop, Forage & Turfgrass Management*, 10(1). <https://doi.org/10.1002/cft2.20262>

Jordan, D. L., Shew, B. B., & Johnson, P. D. (2016). Response of the Peanut (*Arachis hypogaea* L.) Cultivar Gregory to Interactions of Digging Date and Disease Management. *Advances in Agriculture*, 2016, 1–9. <https://doi.org/10.1155/2016/5839090>

Kaiser, H. F. (1960). "The Application of Electronic Computers to Factor Analysis." *Educational and Psychological Measurement*, 20(1), 141–151.

McFadden, J., Njuki, E., & Griffin, T. (2023). Precision agriculture in the digital era: recent adoption on US farms.

Oliveira, M. F., Carneiro, F. M., Ortiz, B. V., Thurmond, M., Oliveira, L. P., Bao, Y., Sanz-Saez, A., & Tedesco, D. (2024). Predicting below and above-ground peanut biomass and maturity using multi-target regression. *Computers and Electronics in Agriculture*, 218. <https://doi.org/10.1016/j.compag.2024.108647>

Peralta, N. R., Costa, J. L., Balzarini, M., Castro Franco, M., Córdoba, M., & Bullock, D. (2015). Delineation of management zones to improve nitrogen management of wheat. *Computers and Electronics in Agriculture*, 110, 103–113. <https://doi.org/10.1016/j.compag.2014.10.017>

Sanders, T. H., Williams, E. J., Schubert, A. M., & Pattee, H. E. (1980). Peanut Maturity Method Evaluations. I. Southeast. *Peanut Science*, 7(2), 78–82. <https://doi.org/10.3146/i0095-3679-7-2-5>

Santos, A. F., Kazama, E. H., Ormond, A. T. S., Tavares, T. O., & Silva, R. P. (2016). Quality of mechanized peanut digging in function of the auto guidance. *African Journal of Agricultural Research*, 11(48), 4894–4901. <https://doi.org/10.5897/AJAR2016.11442>

Santos, A. F., Lacerda, L. N., Rossi, C., Moreno, L. A., Oliveira, M. F., Pilon, C., Silva, R. P., & Vellidis, G. (2022). Using UAV and Multispectral Images to Estimate Peanut Maturity Variability on Irrigated and Rainfed Fields Applying Linear Models and Artificial Neural Networks. *Remote Sensing*, 14(1). <https://doi.org/10.3390/rs14010093>


Schimmelpfennig, D., & Lowenberg-DeBoer, J. (2020). Farm Types and Precision Agriculture Adoption: Crops, Regions, Soil Variability, and Farm Size. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3689311>

Sen, R., Zambreski, Z. T., & Sharda, V. (2023). Impact of Spatial Soil Variability on Rainfed Maize Yield in Kansas under a Changing Climate. *Agronomy*, 13(3), 906. <https://doi.org/10.3390/agronomy13030906>

Souza, J. B. C., de Almeida, S. L. H., Freire de Oliveira, M., Dos Santos, A. F., Filho, A. L. d. B., Meneses, M. D., & Silva, R. P. d. (2022). Integrating Satellite and UAV Data to Predict Peanut Maturity upon Artificial Neural Networks. *Agronomy*, 12(7). <https://doi.org/10.3390/agronomy12071512>

Williams, E. J., & Drexler, J. S. (1981). A Non-Destructive Method for Determining Peanut Pod Maturity. *Peanut Science*, 8(2), 134–141. <https://doi.org/10.3146/i0095-3679-8-2-15>

7. Material Suplementar






Figura 1.

Tabela 5.2. Análise de textura de solo para 20 cm profundidade

Amostra	Areia (%)	Silte (%)	Argila (%)	Tipo de Solo
Ponto 1	78.00	8.00	14.00	Franco Arenoso
Ponto 2	70.20	13.68	16.16	Franco Arenoso
Ponto 3	84.20	9.64	6.16	Areia Franco
Ponto 4	74.20	13.68	12.16	Franco Arenoso
Ponto 5	76.00	15.76	8.24	Franco Arenoso
Ponto 6	81.80	7.92	10.24	Areia Franco
Ponto 7	81.80	12.12	6.08	Franco Arenoso
Ponto 8	87.70	6.12	6.16	Franco Arenoso
Ponto 9	85.60	8.28	6.24	Franco Arenoso
Ponto 10	85.50	8.28	6.24	Franco Arenoso
Ponto 11	85.50	8.36	6.16	Franco Arenoso
Ponto 12	73.80	14.16	12.08	Areia Franco
Ponto 13	83.60	10.28	6.16	Franco Arenoso
Ponto 14	43.40	24.40	32.20	Franco Argiloso
Ponto 15	83.3	10.52	6.20	Franco Arenoso
Ponto 16	81.2	6.52	12.28	Areia Franco
Ponto 17	73.00	10.76	16.28	Areia Franco

Tabela 5.3. Análise de textura de solo para 40 cm profundidade

Amostra	Areia (%)	Silte (%)	Argila (%)	Tipo de Solo
---------	-----------	-----------	------------	--------------

Ponto 1	78.1	5.84	16.08	Franco Arenoso
Ponto 2	78.2	7.64	14.16	Franco Arenoso
Ponto 3	82.2	9.64	8.16	Areia Franco
Ponto 4	80.1	7.76	12.16	Franco Arenoso
Ponto 5	67.9	13.84	18.24	Franco Arenoso
Ponto 6	69.80	8.04	22.16	Franco Argiloso
Ponto7	79.7	8.12	12.16	Franco Arenoso
Ponto 8	81.7	10.04	8.24	Areia Franco
Ponto 9	85.6	8.20	6.24	Areia Franco
Ponto 10	81.40	10.40	8.16	Areia Franco
Ponto 11	83.80	10.16	6.00	Areia Franco
Ponto 12	71.60	12.28	18.20	Franco arenoso
Ponto 13	81.50	12.36	6.16	Areia Franco
Ponto 14	69.30	12.48	18.20	Franco Arenoso
Ponto 15	81.30	0.44	18.28	Franco Arenoso
Ponto 16	77.1	12.60	10.28	Franco Arenoso
Ponto 17	77.0	10.76	12.28	Franco Arenoso

Tabela 5.4. Métricas de Avaliação dos Modelos

Métricas	RBF	MLP
Média	0.53	0.53
Desvio Padrão	0.27	0.27
Média do Erro	-0.02	-0.01
Desvio Padrão do Erro	0.07	0.06
Erro Médio Absoluto	0.06	0.05
Razão do Desvio Padrão	0.26	0.23
Correlação	0.96	0.97
Coeficiente de Determinação	0.93	0.95

Tabela 5.5. Configuração dos algoritmos RBF e MLP

Modelos	Perfil	Treino	Teste	Erro Treino	Erro Teste	Métodos	Input	Neurônios
RBF	1:1-4-1:1	0.41	0.26	1.36	0.91	KM, KN, PI	1	4
MLP	4:4-20-16-1:1	0.39	0.23	0.13	0.08	BP100, CG20, CG3b	4	20-16

Tabela 5.6 Análise de Sensibilidade das Variáveis de Entrada

Rank Algoritmo	NDVI	GNDVI	NLI	MNLI
RBF	1	-	-	-
MLP	1	2	3	4

CAPÍTULO 6 – CONSIDERAÇÕES FINAIS

A presente tese demonstrou o potencial do sensoriamento remoto e da inteligência artificial na predição e estimativa da produtividade e maturação do amendoim, permitindo uma nova abordagem para o manejo da cultura em diferentes condições edafoclimáticas. A utilização de índices de vegetação aliados a algoritmos de aprendizado de máquina proporcionou um avanço na modelagem preditiva da maturação e na otimização da colheita, com maior eficiência e possibilitando decisões mais assertivas para determinar o ponto ótimo de colheita. A partir desse avanço, a implementação de tecnologias digitais na cultura do amendoim se apresenta como um caminho promissor para aumentar a competitividade da cultura em escala global. Tal fato pode ser evidenciado no Brasil, com o amendoim migrando para regiões como produtores de Minas Gerais, Mato Grosso do Sul e Mato Grosso.

A integração da agricultura digital ao cultivo do amendoim permite a identificação e quantificação da variabilidade espacial da lavoura, possibilitando o ajuste de manejos específicos dentro da caia produtiva da cultura. O uso de imagens de satélite de alta resolução, ARPs equipados com sensores multiespectrais para análise de dados pode melhorar significativamente a eficiência operacional. A evolução dos modelos de predição da maturação abre novas oportunidades para colheitas cada vez mais precisas, minimizando perdas e melhorando a qualidade do amendoim colhido. Além disso, a segmentação da lavoura em zonas de manejo em áreas que apresentem alta variabilidade como demonstrado neste estudo, deve oferecer alternativas de manejos para aumentar a rentabilidade do produtor.

O amendoim, historicamente considerado uma cultura de importância regional em algumas áreas produtoras, como é o caso do estado de São Paulo, tem potencial para expandir sua relevância no cenário agrícola global. Além de ser uma importante fonte de proteína e óleo vegetal, o amendoim desempenha um papel estratégico na rotação de culturas e na melhoria da estrutura do solo, contribuindo para a sustentabilidade dos sistemas produtivos. No entanto, sua produção ainda enfrenta desafios relacionados à variabilidade climática, ao manejo fitossanitário e principalmente às perdas na colheita. A implementação de tecnologias digitais pode mitigar essas limitações, permitindo uma adaptação mais eficiente às condições ambientais e um planejamento mais estratégico da produção. A adoção de ferramentas digitais voltadas ao monitoramento da cultura pode favorecer a expansão do cultivo em novas fronteiras agrícolas, tornando a cultura mais competitiva e fortalecendo sua participação no comércio internacional.

A ciência desempenha um papel fundamental na consolidação do amendoim como uma cultura de alto valor agregado, fornecendo bases para o desenvolvimento de novas tecnologias e estratégias de manejo. A ampliação das pesquisas envolvendo inteligência artificial, análise espectral e modelagem preditiva pode proporcionar avanços significativos na predição da produtividade, reduzindo a dependência de métodos convencionais e aumentando a confiabilidade das informações. A utilização de redes neurais artificiais e algoritmos de aprendizado profundo pode aprimorar a interpretação da variabilidade da lavoura, permitindo a integração de dados multiespectrais e informações climáticas em tempo real. Além disso, a fusão de dados provenientes de diferentes sensores, como imagens de satélite, LiDAR e radar de abertura sintética (SAR), pode proporcionar uma caracterização ainda mais detalhada da cultura, auxiliando no desenvolvimento de estratégias mais eficientes para o manejo do amendoim.

Os avanços na digitalização da agricultura abrem caminho para um novo mundo na produção do amendoim, onde a automação e a análise preditiva desempenham papéis importantes na otimização dos processos produtivos. A incorporação de tecnologias emergentes, como sensores conectados à Internet das Coisas (IoT), plataformas de big data e modelos de inteligência artificial de última geração, permitirá um controle mais preciso de todas as etapas da produção, desde o plantio até a colheita. A conectividade rural, que ainda representa um desafio em algumas regiões produtoras, será um fator determinante para a implementação dessas tecnologias em larga escala, exigindo esforços conjuntos entre setor produtivo, academia e órgãos governamentais para viabilizar o acesso a essas inovações.

Os resultados obtidos nesta pesquisa demonstram que a integração da agricultura digital ao cultivo do amendoim pode revolucionar a forma como a cultura é monitorada e manejada, tornando o sistema produtivo mais eficiente, resiliente e sustentável. A partir das abordagens desenvolvidas, novas pesquisas podem ser conduzidas para validar e expandir os modelos apresentados, explorando diferentes condições de campo e ajustando os parâmetros dos algoritmos para ampliar sua capacidade de generalização. Estudos futuros também podem investigar a viabilidade econômica da adoção dessas tecnologias pelos produtores, quantificando os ganhos financeiros e a redução dos custos operacionais proporcionados pelo uso de sistemas automatizados e de sensoriamento remoto.

Por fim, a agricultura digital oferece um caminho promissor para a modernização do cultivo do amendoim. A continuidade das pesquisas na área será essencial para consolidar o uso dessas tecnologias no campo e garantir que os benefícios proporcionados

pela digitalização alcancem um número cada vez maior de produtores. O avanço da ciência aplicada à agricultura, aliado ao desenvolvimento de políticas públicas voltadas para a inovação no setor agropecuário, pode contribuir significativamente para que o amendoim se torne uma das culturas mais tecnológicas e produtivas do mundo, promovendo benefícios tanto para a economia agrícola quanto para a segurança alimentar global. No entanto, a transição para uma agricultura digital exige que o desenvolvimento da mecanização seja tratado como um elemento fundamental, garantindo que as inovações tecnológicas não sejam limitadas pela falta de equipamentos compatíveis. O futuro do amendoim como uma cultura altamente produtiva e eficiente dependerá, portanto, da relação entre o avanço da digitalização e a modernização da mecanização para o manejo do amendoim.

