

**UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL**

**COLHEITA MECANIZADA DE AMENDOIM: DESAFIOS E
OPORTUNIDADES NO DESENVOLVIMENTO DE
TECNOLOGIAS PARA AVALIAÇÃO DE PERDAS**

Armando Lopes de Brito Filho
Engenheiro Agrícola

2024

T
E
S
E
/
B
R
I
T
O

F
I
L
H
O

A.
L.
D
E

2
0
2
4

**UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL**

**COLHEITA MECANIZADA DE AMENDOIM: DESAFIOS E
OPORTUNIDADES NO DESENVOLVIMENTO DE
TECNOLOGIAS PARA AVALIAÇÃO DE PERDAS**

Doutorando: Me. Armando Lopes de Brito Filho

Orientador: Prof. Dr. Rouverson Pereira da Silva

Coorientador: Prof. Dr. Luciano Shozo Shiratsuchi

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
(Ciência do Solo)

Brito Filho, Armando Lopes de
L864 Colheita mecanizada de amendoim: desafios e oportunidades no desenvolvimento de tecnologias para avaliação de perdas / Armando Lopes de Brito Filho. -- Jaboticabal, 2024
iv, 107 p. : il. ; 29 cm

Tese (doutorado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal
Orientador: Rouverson Pereira da Silva
Coorientador: Luciano Shozo Shiratsuchi

1. Agricultura digital. 2. *Arachis hypogaea*. 3. Colheita mecanizada. 4. Inteligência artificial. 5. Perdas na colheita. I. Título

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor.

Essa ficha não pode ser modificada.

POTENCIAIS IMPACTOS DESTA PESQUISA

Social: A otimização do monitoramento e quantificação de perdas na colheita mecanizada de amendoim gera impactos sociais profundos ao promover uma agricultura mais sustentável. Os avanços tecnológicos nas técnicas de gerenciamento de perdas, reforçam a conscientização sobre o desperdício e sustentabilidade, facilitando a troca de conhecimentos entre produtores e colaborando para a construção de comunidades agrícolas mais fortes e integradas. Além disso, a implementação de uma plataforma digital intuitiva fortalece o incentivo do desenvolvimento de habilidades e a educação tecnológica no campo.

Ambiental: A introdução de novas tecnologias para a quantificação de perdas na colheita do amendoim promove uma agricultura mais equilibrada e sustentável, ajudando a minimizar perdas. A partir do controle de perdas pode-se reduzir a pressão por expansão de áreas cultiváveis, o que contribui para a preservação de ecossistemas e da biodiversidade. Além disso o desenvolvimento dessas tecnologias automatizadas de monitoramento, incentivam o avanço tecnológico por parte do melhoramento dos maquinários agrícolas de colheita, desenvolvendo tecnologia que possibilite regulagens automáticas das máquinas no campo e reduzindo o uso excessivo de energia e combustível.

Econômico: Ao reduzir as perdas durante a colheita, os agricultores conseguem melhorar o aproveitamento da produção e obter maiores retornos financeiros. A implementação de tecnologias acessíveis que minimizam a necessidade de processos manuais também contribui para a redução de custos operacionais, tornando o sistema de colheita mais economicamente viável e escalável, especialmente para pequenas propriedades. Com uma gestão de colheita mais eficiente e orientada por dados, os produtores são capazes de responder melhor às exigências do mercado, promovendo um crescimento econômico mais sustentável e equitativo no setor agrícola.

CERTIFICADO DE APROVAÇÃO DA TESE



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Jaboticabal



CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: COLHEITA MECANIZADA DE AMENDOIM: DESAFIOS E OPORTUNIDADES NO DESENVOLVIMENTO DE TECNOLOGIAS PARA AVALIAÇÃO DE PERDAS

AUTOR: ARMANDO LOPES DE BRITO FILHO
ORIENTADOR: ROVERSON PEREIRA DA SILVA
COORIENTADOR: LUCIANO SHOZO SHIRATSUCHI

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

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

Documento assinado digitalmente
ROVERSON PEREIRA DA SILVA
Data: 22/11/2024 15:48:26-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. TIAGO RODRIGO FRANCETTO (Participação Virtual)
Departamento de Engenharia Agrícola / Universidade Federal de Santa Maria (UFSM)

Documento assinado digitalmente
TIAGO RODRIGO FRANCETTO
Data: 23/11/2024 08:49:47-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. ANDERSON CHAGAS MAGALHAES (Participação Virtual)
Departamento de Produção Vegetal / FCAT UNESP Dracena

Documento assinado digitalmente
ANDERSON CHAGAS MAGALHAES
Data: 25/11/2024 11:32:23-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. DENISE MAHL PORCEL (Participação Virtual)
Departamento de Engenharia Agrícola / Universidade Estadual de Maringá (UEM)

Documento assinado digitalmente
DENISE MAHL PORCEL
Data: 25/11/2024 10:29:08-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. LUAN PEREIRA DE OLIVEIRA (Participação Virtual)
Department of Horticulture / University of Georgia (UGA) - Tifton/EUA

Documento assinado digitalmente
LUAN PEREIRA DE OLIVEIRA
Data: 23/11/2024 14:47:27-0300
Verifique em <https://validar.iti.gov.br>

Jaboticabal, 22 de novembro de 2024

DADOS CURRICULARES DO AUTOR

ARMANDO LOPES DE BRITO FILHO – nascido em 13 de novembro de 1995 na cidade de São Luís, Maranhão. Em 2014, ingressou no Centro de Ciências Agrárias e Ambientais da Universidade Federal do Maranhão – CCAA/UFMA – câmpus de Chapadinha, no curso de Engenharia Agrícola. Em julho de 2019, obteve o título de Engenheiro Agrícola. Durante a graduação possuiu bolsa de monitoria das disciplinas de Ecologia; Hidráulica Agrícola; e Irrigação e Drenagem, por conseguinte obteve bolsa de iniciação científica PIBIC/FAPEMA - Fundação de Amparo à Pesquisa ao Desenvolvimento Científico e Tecnológico – MA. Com a obtenção dessas bolsas o permitiu o desenvolvimento de trabalhos científicos, participações de eventos e projetos na área de irrigação e sustentabilidade na agropecuária com produção de energia renovável. Em março de 2019, iniciou o mestrado no Programa de Pós-Graduação em Agronomia (Ciência do Solo), pela Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal, sendo bolsista da CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, sob a supervisão e orientação do Prof. Dr. Rouverson Silva. Durante o mestrado participou e desenvolveu pesquisas voltadas para a área de máquinas e mecanização agrícola, avaliando a qualidade operacional do recolhimento mecanizado de amendoim. Nesse mesmo período, também participou de diversas pesquisas com ênfase Agricultura de Digital e Sensoriamento Remoto. Em março de 2021, ele iniciou seu doutorado no Programa de Pós-Graduação em Agronomia (Ciência do Solo), pela Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal, sendo bolsista da CAPES. Ao longo de seu doutorado, ele continuou integrante do Laboratório de Máquinas e Mecanização Agrícola – LAMMA, onde manteve seu foco no desenvolvimento de novas tecnologias para colheita mecanizada de amendoim sob a supervisão e orientação Prof. Dr. Rouverson Silva. Em 2022 realizou estágio sanduíche por 10 meses na Universidade do Estado de Louisiana (LSU), EUA, sob a supervisão do Prof. Dr. Luciano Shiratsuchi. Ele participou e contribuiu com diversas pesquisas voltadas para área de Agricultura de Precisão e Sensoriamento Remoto. Por fim, ele está submetendo esta Tese de doutorado para obter o título de Doutor em Agronomia (Ciência do Solo) em 2024.

“Não espere com medo as mudanças na vida; em vez disso, olhe para eles com plena esperança de que, à medida que surgem, Deus, a quem você pertence, irá guiá-lo com segurança por todas as coisas; e quando você não aguentar, Deus o carregará em Seus braços”

São Francisco de Sales

DEDICATÓRIA

Aos meus pais, meus irmãos, minha noiva e futura esposa que sempre acreditaram nos meus sonhos e me apoiaram em toda minha trajetória.

Dedico

AGRADECIMENTOS

A Deus, por me amar primeiro e, a todo momento, demonstrar o Seu amor e cuidado comigo. Seu zelo me constrange de tal forma que me faz querer ser um homem novo a cada dia da minha vida. Senhor, sem Vós ao meu lado, eu não conseguiria vencer as tribulações cotidianas da minha vida. Desde o começo desta trajetória, a Vós confiei tudo, porque sei que somente Contigo poderia chegar até o final desta etapa. Por isso, Vos louvo e Vos bendigo todos os dias da minha vida, pois, Senhor, Tu és meu tudo e o meu querer. Agradeço, também, à Santíssima Virgem Maria, minha Mãe, que me ensina, todos os dias, a amar Seu Filho Jesus como ela amou, e, por esse imenso amor, posso dar o meu melhor.

Aos meus pais, Armando Lopes de Brito e Ana Valéria Albuquerque Arruda de Brito, por toda a minha criação, pelos ensinamentos e incentivos que contribuíram para que eu chegasse até aqui. Aos meus irmãos, João Fialho de Brito Neto e Elza Carolinne Arruda de Brito, por todo apoio, carinho e amizade durante esses meus 29 anos de vida. À minha noiva e futura esposa, Franciele Carneiro, por todo apoio e incentivo; ao seu lado, aprendo diariamente a ser uma pessoa melhor.

Ao meu orientador, Prof. Dr. Rouverson Pereira da Silva, por quem tenho uma profunda admiração. Agradeço por todo o período em que tive a oportunidade de trabalhar ao seu lado. Hoje sei que escolher vir para Jaboticabal foi a melhor decisão que eu poderia ter tomado. Com sua orientação, aprendi a ser mais que um profissional; aprendi a ser um ser humano melhor, que pode ver a vida de uma perspectiva totalmente diferente daquela que o mundo transmite. Aprendi a ser detentor das minhas próprias escolhas. Obrigado, professor, por todos os conselhos e conhecimentos transmitidos.

Ao meu coorientador, Prof. Dr. Luciano Shiratsuchi, agradeço profundamente pela disposição em me acolher nos EUA durante meu período de doutorado sanduíche. Sua colaboração foi essencial para o meu desenvolvimento, tanto profissional quanto pessoal, proporcionando-me uma experiência de crescimento e aprendizado que levarei para toda a vida.

Aos meus amigos e parceiros do Laboratório de Máquinas e Mecanização Agrícola, com quem tive o prazer de conviver durante toda a jornada da pós-

graduação. Sem a ajuda de vocês, não teria sido capaz de realizar este trabalho. Obrigado pelo espírito de união, parceria, amizade e pelos ensinamentos que transmitiram. Hoje, saio com a certeza de que formei grandes amizades.

Aos amigos da República Toca Fogo, com quem construí amizades sinceras e duradouras ao longo dessa jornada. Compartilhamos inúmeras experiências, e cada momento vivido foi essencial para o meu crescimento pessoal e profissional. Agradeço pelo companheirismo e pela amizade genuína, que sei que levarei para a vida toda. Obrigado por cada instante e por todo o aprendizado compartilhado. Vocês foram e sempre serão parte fundamental dessa caminhada.

A todos os amigos que conquistei nesse período que estive aqui em Jaboticabal.

À Universidade Estadual Paulista, Campus de Jaboticabal, em especial ao Programa de Pós-Graduação em Agronomia (Ciência do Solo).

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

A todos que contribuíram de forma direta e indiretamente, o meu muito obrigado e os meus sinceros agradecimentos.

SUMÁRIO

Página

LISTA DE ABREVIACÕES	iv
LISTA DE TABELAS.....	vii
LISTA DE FIGURAS	viii
RESUMO	xii
ABSTRACT	xiii
CAPÍTULO 1 - Considerações gerais	1
CAPÍTULO 2 - Perdas na colheita mecanizada de amendoim: uma meta-revisão sistemática e diretrizes para pesquisas futuras	5
1. Introdução	5
2. Protocolo de revisão sistemática.....	7
2.1. Fonte de dados e estratégia de busca	7
2.2. Critérios de elegibilidade	8
2.3. Extração e análise de dados	8
3. Evolução das publicações sobre perdas na colheita mecanizada de amendoim	10
3.1. Mecanização da Colheita do Amendoim	12
3.2. Arranquio de amendoim	15
3.3. Recolhimento do amendoim	16
3.3. Fatores identificados na colheita mecanizada de amendoim	20
4. Fatores associados às perdas na colheita mecanizada de amendoim	22
4.1. Fatores ambientais	23
4.2. Fatores relacionados a matéria-prima	24
4.3. Fatores da máquina.....	27
5. Monitoramento de perdas na colheita mecanizada de amendoim.....	28
6. Principais lacunas identificadas	30
6.1. Colheita mecanizada	30
6.2. Influências ambientais	31
6.3. Colheita de amendoim.....	32
6.4. Quantificações de perdas.....	32

7. Direção e orientação para pesquisas futuras	33
8. Conclusões.....	34
9. Referências.....	35
CAPÍTULO 3 – Otimização da estimativa de perdas na colheita mecanizada de amendoim por meio da contagem de vagens	39
1. Introdução	39
2. Material e Métodos.....	42
2.1 <i>Descrição das áreas de estudo</i>	42
2.2. <i>Estimativa de perdas no arranquio</i>	44
2.3.1. <i>Experimento 1</i>	45
2.3.2. <i>Experimento 2</i>	45
2.4. <i>Análise de dados</i>	45
2.4.1. <i>Transformação de dados</i>	45
2.4.2. <i>Análise de Correlação</i>	46
2.4.3. <i>Remoção de outliers</i>	46
2.4.4. <i>Modelagem das perdas.....</i>	47
2.5. <i>Generalização</i>	47
3.1. <i>Correlação entre os diferentes tipos de perdas e quantidade de vagens em solos de diferente classe</i>	49
3.2. <i>Estimativas de perdas a partir da contagem do número de vagens</i>	51
3.3. <i>Estimativa de perdas invisíveis por meio das perdas visíveis.....</i>	54
3.4. <i>Avaliação do desempenho da generalização dos modelos criados.....</i>	57
3.5. <i>Aplicação dos modelos por meio de uma plataforma de servidor web</i>	62
4. Conclusões.....	64
5. Referências.....	66
Material Suplementar.....	69
CAPÍTULO 4 – Redes convolucionais profundas baseadas em YOLOv8 para detecção e estimativa de perdas de amendoim a partir de imagens em ambientes pós-colheita.....	72
1. Introdução	72
2. Material e Métodos.....	75

2.1. <i>Configuração Experimental</i>	75
2.1.1. <i>Aquisição de imagens</i>	76
2.1.2. <i>Construção de conjunto de dados</i>	77
2.2. <i>Construção de modelo de detecção de perdas de amendoim</i>	79
2.3. <i>Configurações ambientais</i>	80
2.4. <i>Teste de campo</i>	81
2.5. <i>Avaliação de desempenho</i>	82
2.6. <i>Mapas de perdas de amendoim</i>	84
3. Resultados	85
3.1. <i>Comparação de desempenho dos algoritmos de última geração</i>	85
3.2. <i>Desempenho do conjunto de dados de validação em função do tempo de aquisição da imagem</i>	86
3.3. <i>Desempenho de teste de campo</i>	88
3.3.1. <i>Contagem manual versus automática de perdas de amendoim</i>	88
3.3.2. <i>Estimativa de perdas de amendoim por imagem</i>	89
3.3.3. <i>Mapas de perdas de amendoim</i>	90
4. Discussão	92
4.1. <i>Dificuldades na identificação de perdas de amendoim</i>	92
4.2. <i>Estimativas e mapas de perdas de amendoim</i>	95
4.3. <i>Implicações e perspectivas futuras</i>	96
5. Conclusões	98
6. Referências	99
Material Suplementar	103
CAPÍTULO 5 – Considerações finais e trabalhos futuros	106

LISTA DE ABREVIACÕES**Página**

UNESP	Universidade Estadual Paulista "Júlio de Mesquita Filho"
UFLA	Universidade Federal de Lavras
UEMG	Universidade Estadual de Minas Gerais
NPRL	Laboratório Nacional de Pesquisa de Amendoim
USDA-ARS	Serviço de Pesquisa Agrícola do Departamento de Agricultura dos Estados Unidos
UGA	Universidade da Geórgia
IA	Inteligência Artificial
R ²	Coeficientes de Determinação
ODS	Objetivos de Desenvolvimento Sustentável
Aw	Clima subtropical
TS	textura do solo
NP	Número de pontos de perdas coletados em cada área
P	Produtividade
TAS	Teor de água no solo
VT	número total de vagens
1g	1 grão
2g	2 grãos

3g	3 grãos
PVA	Perdas visíveis no arranquio
PIA	Perdas invisíveis no arranquio
LOF	Fator Local de Outlier
MAE	Erro Médio Absoluto
MMV	Massa media por vagem
Quant	Quantidade de vagens em cada classe de vagens encontradas
Figuras S	Material Suplementar
PVA+PIA	União dos dados perdas visíveis e invisíveis
NV	número total de vagens
CV	Coeficiente de Variação
DP	Desvio Padrão
N	Número de observação
NTV	Número total de vagens de amendoim
NVD	Número total de vagens contendo dois grãos de amendoim
Sapeca	S istema de A valiação de P erdas na C olheita de A mendoim
CNN	Redes Neurais Convolucionais
YOLO	You Only Look Once
IDW	Inverso Do Quadrado Da Distância
RGB	vermelho, verde e azul
FPN	Feature Pyramid Networks

Google Colab	Google Colaboratory
GFLOPs	ponto flutuante giga por segundo
TP	Verdadeiros Positivos
FN	Falsos Negativos
FP	Falsos Positivos
AP	Precisão média
IoU	Intersecção sobre União
P(r)	Curva de precisão-recall suavizada
C	Número de categorias
APi	Taxa de precisão média da categoria
MAPE	Erro Percentual Absoluto Médio
n	número total de imagens
$C_{Automatic}$	número de perdas contadas automaticamente
C_{manual}	número real de perdas contadas manualmente na imagem
P-R	Precisão-Recall
mAP@50	Precisão média na intersecção acima do limite de união de 50%

LISTA DE TABELAS

Página

Capítulo 3

Tabela 1. Informações gerais sobre as nove áreas comerciais explorados no desenvolvimento desta pesquisa.....	43
Tabela 2. Valores médios da caracterização das perdas de amendoim para as cultivares trabalhadas.....	48
Tabela 3. Coeficiente de determinação das equações de modelagem para estimativa de perdas de amendoim em solos arenosos e argilosos, com base no número de vagens.....	52
Tabela 4. Análise descritiva dos valores de perdas encontrados em campo para as cultivares de amendoim Granoleico, IAC 503 e IAC 677.....	57

Capítulo 4

Tabela 1. Exemplos de notas de caixa delimitadora e o número de imagens nos conjuntos de treinamento e validação são categorizados de acordo com as condições ambientais.....	79
Tabela 2. Configurações de hiperparâmetros para treinamento de rede.	81
Tabela 3. Valores médios dos dados de perda de vagens de amendoim coletados durante a fase de testes de campo.....	81
Tabela 4. Comparações entre as versões do algoritmo YOLO.....	85

LISTA DE FIGURAS

Página

Capítulo 1

Figura 1. Resumo gráfico da tese “Colheita mecanizada de amendoim: desafios e oportunidades no desenvolvimento de tecnologias para avaliação de perdas”	2
--	---

Capítulo 2

Figura 1. Fluxograma do processo de meta-revisão sistemática. As caixas cinzas destacam as principais etapas do nosso processo de revisão, enquanto as caixas laranja indicam as fontes de dados e o fluxo do processo, incluindo estudos adicionais identificados por meio de busca de citações....	8
Figura 2. Variáveis extraídas na revisão sistemática de perdas na colheita mecanizada de amendoim.....	9
Figura 3. Literatura sobre monitoramento de perdas na colheita mecanizada de amendoim: A - Evolução histórica da literatura; B - Instituições responsáveis pelo maior número de publicações sobre perdas na colheita mecanizada de amendoim; C - Autores responsáveis pelo maior número de publicações sobre perdas na colheita mecanizada de amendoim	10
Figura 4. O diagrama de Sankey ilustra a distribuição de estudos sobre perdas na colheita mecanizada de amendoim na literatura acadêmica.	13
Figura 5. Distribuição de perdas totais em operações mecanizadas de arranquio e recolhimento de amendoim. Os valores de perdas são expressos como uma porcentagem e calculados com base em dados de produtividade e valores de perdas fornecidos pelos autores dos estudos.....	14
Figura 6. Distribuição percentual de perdas visíveis e invisíveis em relação às perdas totais na arranquio mecanizada de amendoim. O percentual foi calculado a partir da soma das categorias de perdas observadas nos estudos aceitos para análise.....	16

Figura 7. Porcentagem de perdas na plataforma e mecanismos internos durante a operação mecanizada de recolhimento de amendoim, com base nas perdas totais encontradas em campo..... 17

Figura 8. Porcentagens de perdas qualitativas na colheita mecanizada de amendoim, categorizadas em vagens inteiras, vagens quebradas, grãos soltos e impurezas. O gráfico mostra a influência de diferentes sistemas de preparo do solo (Convencional, Reduzido, Rip Strip, Convencional + canteiros), teor de água das vagens e sistema de trilha do tipo axial e tangencial, destacando os impactos de cada fator na qualidade do material colhido. *Canteiros feitos com rotocanteirador; **Canteiros feitos com enxada rotativa..... 19

Figura 9. Confiabilidade da Pesquisa sobre Perdas na Colheita Mecanizada de Amendoim. (a) Qualidade geral de todos os artigos de texto completo. (b) Qualidade dos artigos que abordam a operação de arranquio de acordo com critérios qualitativos. (c) Qualidade dos artigos que abordam a operação de coleta de acordo com critérios qualitativos..... 21

Capítulo 3

Figura 1. Correlação de Spearman entre as perdas visíveis (PV) e invisíveis (PIA) e a quantidade de vagens, classificadas por número de grãos: 1, 2, 3 e totais. A abordagem geral representa a condição da união dos conjuntos de dados das duas classes de solo..... 50

Figure 2. Análise de regressão linear e diagrama de caixas entre as perdas visíveis e invisíveis sob diferentes classes de solo. A – Modelo para Argissolos Vermelho-Amarelo; B – Modelo para Latossolos Vermelhos; C – Modelo geral; D – Variabilidade das perdas em cada área trabalhada..... 55

Figura 3. Regressão linear entre as perdas observadas e estimadas para as cultivares de amendoim Granoleico, IAC 503 e IAC 677. As perdas estimadas foram baseadas no número total de vagens e na contagem de vagens de dois grãos. Os valores de perdas incluem tanto as perdas visíveis quanto as invisíveis..... 60

Figura 4. Regressão linear entre as perdas invisíveis observadas e estimadas para as cultivares Granoleico, IAC 503 e IAC 677. As perdas invisíveis foram estimadas utilizando uma equação que tem as perdas visíveis como indicador principal.....	61
Figura 5. Interface da plataforma construída com base no pacote Streamlit.....	63
Figura S1. Modelos de estimativa de perdas visíveis em função do número de vagens em solos arenosos e argilosos.....	69
Figura S2. Modelos de estimativa de perdas invisíveis em função do número de vagens em solos arenosos e argilosos.....	70
Figura S3. Modelos geral para estimativa de perdas no arranquio de amendoim em função do número de vagens em classes de solo: Argissolos Vermelho-Amarelos (PVA) e Latossolos Vermelhos (LV). O desenvolvimento desses modelos foi por meio da união dos dados de perdas visíveis e invisíveis.....	71
Capítulo 4	
Figura 1. Mapa de localização das áreas experimentais dos campos #1 (Município de Ibitinga) e #2 (Município de Sertãozinho) estavam no Estado de São Paulo, Brasil. Campo 1 de treinamento e campo 2 de teste. Os pontos marcados no campo 2 indicam os locais georreferenciados onde as imagens foram capturadas para o conjunto de dados de teste.....	76
Figura 2. Resumo gráfico com as etapas de construção do banco de dados. (a) aquisição de imagem; (b) filmagem da área de interesse; (c) exemplo de classificação de perdas.....	78
Figura 3. Diagrama da estrutura do modelo de YOLOv8n.....	80
Figura 4. Curvas de precisão-recall para cada condição de captura fotográfica de perda de amendoim da câmera de smartphone móvel. A - Vagens de um grão identificadas; B - Vagens de dois grãos identificadas.....	87
Figura 5. Resultados de validação do YOLOv8n em cada classe treinada como uma função do tempo de aquisição de imagem. A – taxa de precisão; B – taxa de recall; e C – mAP ₅₀	88

Figura 6. Comparação entre contagem manual e automática de perdas de amendoim por imagem. A - vagens de um grão; B - vagens de dois grãos; C - número total de vagens encontradas na imagem; e D - Erro Percentual Absoluto Médio (MAPE) de contagens de perdas de amendoim para diferentes classes de vagens.....	89
Figura 7. Regressão linear entre perdas observadas e estimadas de amendoim por YOLOv8n. A - Estimativa de perdas pela contagem de vagens de dois grãos; B – Estimativa de perdas pela contagem de vagens totais.....	90
Figura 8. Mapas de interpolação conforme coleta de perdas de amendoim em teste de campo, em que: A - valores reais de perdas de amendoim encontrados em campo; B - mapas estimados de perdas por contagem visual nas imagens; C - mapas estimados de perdas obtidos pela contagem automática realizada pelo algoritmo YOLOv8n.....	91
Figura 9. Comparação da variabilidade entre perdas reais de amendoim estimadas no campo e estimativas de perdas de amendoim usando contagem manual e automática com YOLOv8n em imagens. A - Boxplots ilustrando a variabilidade entre diferentes abordagens de estimativa de perdas de amendoim; B - Erro Absoluto Médio das estimativas de perdas da contagem manual e automática de vagens em comparação com os valores reais de campo.....	92
Figura 10. Desafios potenciais durante a detecção de vagens em ambiente pós-colheita.....	94
Figura S1. Exemplo de como as imagens para a fase de testes foram geradas a partir de vídeos gravados em cada unidade de amostragem.....	103

COLHEITA MECANIZADA DE AMENDOIM: DESAFIOS E OPORTUNIDADES NO DESENVOLVIMENTO DE TECNOLOGIAS PARA AVALIAÇÃO DE PERDAS

RESUMO – A colheita mecanizada de amendoim desempenha um papel fundamental na agricultura, sendo a estimativa de perdas uma etapa crucial para o monitoramento da qualidade operacional desse processo. No entanto, os métodos tradicionais de estimativa manual apresentam limitações significativas no campo, pois são exaustivos, demorados e suscetíveis a erros, especialmente após longos períodos de trabalho, o que dificulta a obtenção de dados precisos e em tempo hábil para a tomada de decisões. Como resultado, muitos produtores optam por não mensurar as perdas devido à inviabilidade desses métodos. Para enfrentar esse desafio, esta tese propõe um modelo prático para estimativa de perdas baseado na contagem de vagens, que pode ser facilmente aplicado em campo por meio de uma plataforma web, tornando o processo mais rápido e acessível. Além disso, introduzimos uma solução automatizada, utilizando técnicas de visão computacional, para estimar perdas a partir de imagens capturadas no ambiente pós-colheita, permitindo uma coleta de dados ágil e precisa. Essas contribuições não apenas facilitam o controle de perdas, mas também incentivam a adoção de práticas agrícolas mais responsáveis e tecnológicas. Esta tese representa um marco na agricultura digital voltada ao gerenciamento de perdas na colheita mecanizada de amendoim, oferecendo aos produtores ferramentas práticas e avançadas para mensuração de perdas.

Palavras-chave: 1. Agricultura digital. 2. *Arachis hypogaea*. 3. Colheita mecanizada. 4. Inteligência artificial. 5. Perdas na colheita

MECHANIZED PEANUT HARVESTING: CHALLENGES AND OPPORTUNITIES IN THE DEVELOPMENT OF TECHNOLOGIES FOR LOSS ASSESSMENT

ABSTRACT – Mechanized peanut harvesting plays a fundamental role in agriculture, and losses estimation is a crucial step for monitoring the operational quality of this process. However, traditional manual estimation methods have significant limitations in the field, as they are exhaustive, time-consuming, and susceptible to errors, especially after long work periods. Due to the hardness of this operation, it becomes challenging to obtain accurate and timely data for decision-making. As a result, many producers choose to refuse themselves from measuring losses due to the unfeasibility of these methods. To address this challenge, this dissertation proposes a practical model for losses estimation based on pod counting, which can be easily applied in the field through a web platform, making the process faster, accurate, and more accessible. In addition, we introduce an automated solution, using computer vision techniques, to estimate losses from images captured in the post-harvest environment, allowing for faster and accurate data collection. These contributions facilitate loss control and encourage adopting more responsible and technological agricultural practices. This dissertation represents a milestone in digital agriculture focused on managing losses in mechanized peanut harvesting, offering producers practical and advanced tools for measuring losses.

Keywords: 1. Digital agriculture, 2. *Arachis hypogaea*, 3. Mechanical harvesting, 4. Artificial intelligence, 5. Harvest losses

CAPÍTULO 1 - Considerações gerais

No ciclo de produção agrícola, dentro das propriedades, as perdas representam um dos maiores desafios enfrentados pelos produtores, pois refletem ineficiências no trabalho realizado em campo e impactam diretamente o retorno econômico da propriedade. No entanto, essas perdas vão além de simples indicadores de falhas operacionais; elas podem ser fundamentais para o desenvolvimento de práticas de colheita mais sustentáveis. A partir da análise das perdas, é possível obter informações valiosas sobre as influências de fatores externos e intrínsecos a cada sistema mecanizado. Dessa forma, o monitoramento rigoroso das perdas oferece uma base sólida para o desenvolvimento de estratégias que aumentem a eficiência operacional e possibilitem uma tomada de decisões mais assertiva. Assim, o avanço do conhecimento neste campo é crucial para promover pesquisas que contribuam para a conscientização sobre o desperdício de alimentos e a importância de práticas agrícolas mais responsáveis.

Dentre as principais commodities agrícolas, o amendoim destaca-se devido a seus benefícios nutricionais e seu valor econômico. No entanto, esta cultura também enfrenta desafios significativos durante o seu processo de colheita, sobretudo pelos altos índices de perdas. Na colheita mecanizada do amendoim, dois tipos principais de perdas são encontrados: perdas visíveis, compostas por vagens e grãos deixados na superfície do solo após a operação, e perdas invisíveis, que permanecem retidas abaixo da superfície do solo.

Assim, os métodos atuais de quantificação dessas perdas, especialmente das perdas invisíveis, são frequentemente ineficientes, exigindo processos manuais exaustivos, que consomem tempo e recursos, dificultando a obtenção de dados precisos em tempo hábil para tomada de decisões no campo. Como consequência, muitos produtores deixam de mensurar essas perdas por conta da inviabilidade dos métodos disponíveis.

Diante disso, torna-se urgente a necessidade de alternativas mais práticas, variáveis e eficazes para o monitoramento de perdas. O desenvolvimento de novas metodologias para quantificar e analisar as perdas no processo de colheita do amendoim

surge, portanto, como uma estratégia promissora para aprimorar significativamente o monitoramento das operações mecanizadas. Esses avanços podem facilitar o controle das variabilidades indesejadas no processo, permitindo que os produtores ajustem suas operações de forma mais rápida e eficiente.

Nesta perspectiva, esta Tese de Doutorado explora os desafios e as oportunidades para o desenvolvimento de tecnologias voltadas à avaliação de perdas na colheita mecanizada de amendoim, propondo soluções inovadoras que aumentem a eficiência e promovam a sustentabilidade no campo. Organizada em cinco capítulos interligados, a pesquisa aborda etapas essenciais para o monitoramento e quantificação de perdas, estabelecendo uma base sólida para o avanço de práticas agrícolas mais responsáveis e tecnológicas. A Figura 1 resume graficamente nossa abordagem, que apresenta os métodos utilizados e de forma simplificada os principais resultados obtidos.




Figura 1. Resumo gráfico da tese “Colheita mecanizada de amendoim: desafios e oportunidades no desenvolvimento de tecnologias para avaliação de perdas”. Fonte: Figura parcialmente gerada por IA. Gemini.

No presente capítulo tecemos as considerações gerais da tese. No Capítulo 2, realizamos uma meta-revisão sistemática sobre perdas na colheita mecanizada de

amendoim. Este estudo abrange a literatura recente e destaca as metodologias usadas para quantificar perdas, identificando os fatores que influenciam as perdas nas fases de arranquio e recolhimento. Além disso, delineamos as principais lacunas de conhecimento e propomos diretrizes para orientar pesquisas futuras, com foco na sustentabilidade e na eficiência da colheita.

O Capítulo 3 explora uma abordagem inovadora baseada na contagem de vagens para otimizar a estimativa de perdas durante a colheita mecanizada. Adicionalmente, buscamos compreender a relação entre dois tipos de perdas, avaliando a possibilidade de estimar perdas invisíveis a partir das visíveis. Ao analisar a relação entre o número de vagens e esses dois tipos de perdas, propomos um modelo eficiente que permite estimativas rápidas e precisas, proporcionando maior agilidade e precisão ao processo de monitoramento. Como complemento a essa abordagem, desenvolvemos uma plataforma digital intuitiva que possibilita a aplicação dos modelos diretamente no campo. Esta plataforma permite transformar a estimativa de perdas em uma atividade acessível aos produtores, permitindo que realizem avaliações precisas e rápidas no próprio local de colheita.

No Capítulo 4, em continuidade à abordagem prática apresentada no Capítulo 3, que utiliza a contagem de vagens para estimar perdas na colheita mecanizada de amendoim, introduzimos uma solução automatizada baseada em redes convolucionais profundas (YOLOv8) para aprimorar ainda mais essa prática. Essa tecnologia inovadora permite que, com uma simples fotografia da área colhida, obtida por uma câmera de celular, seja possível realizar a contagem automática das vagens e estimar as perdas de forma rápida e precisa. Essa automatização não apenas facilita o processo, mas também possibilita a coleta de mais amostras, permitindo a geração de mapas detalhados de distribuição de perdas. Com esses mapas, os produtores podem identificar áreas de maior desperdício e direcionar intervenções de forma mais eficiente, promovendo uma agricultura mais sustentável e orientada por dados.

Finalmente, no Capítulo 5, apresentamos as considerações finais, destacando as principais contribuições da pesquisa e propondo direções para o desenvolvimento futuro de tecnologias de monitoramento de perdas na colheita mecanizada de amendoim.

Desta forma, esta Tese contribui para a otimização da colheita mecanizada de amendoim, oferecendo soluções práticas e tecnológicas que apoiam a sustentabilidade e a eficiência na produção agrícola.

CAPÍTULO 2 - Perdas na colheita mecanizada de amendoim: uma meta-revisão sistemática e diretrizes para pesquisas futuras

RESUMO - A estimativa de perdas é essencial para aumentar a eficiência da colheita mecanizada de amendoim. Assim, o monitoramento contínuo dessas perdas podem contribuir para o gerenciamento mais eficaz das operações mecanizadas. Com o objetivo de promover uma colheita mais sustentável, esta meta-revisão fornece uma análise detalhada de estudos que utilizam a quantificação de perdas para avaliar a eficiência e qualidade das operações mecanizadas na colheita de amendoim. Foram examinadas as principais perdas nas fases de arranquio e recolhimento, bem como as metodologias aplicadas para quantificação, considerando os fatores que influenciam essas perdas. A busca inicial localizou 322 artigos, dos quais 20 atenderam aos critérios de inclusão. A análise revelou uma lacuna significativa de conhecimento, especialmente relacionada ao impacto de fatores como as condições climáticas e a adaptação de práticas de colheita a diferentes campos. Identificamos que a aplicação de soluções tecnológicas emergentes, como inteligência artificial e aprendizado de máquina, possui grande potencial para automatizar e otimizar o monitoramento de perdas em tempo real, oferecendo novas perspectivas para o avanço do setor. Com base nas lacunas encontradas, desenvolvemos um protocolo padronizado para quantificar perdas e avaliar as condições de colheita, que poderá orientar pesquisas futuras e implementação de práticas mais eficazes. Adoção de tecnologias inovadoras, juntamente com a personalização das operações de colheita, pode reduzir significativamente as perdas e aumentar a produtividade, promovendo uma colheita mais eficiente e ambientalmente responsável. Este estudo representa um avanço na compreensão das práticas de colheita mecanizada de amendoim e oferece direções para a adoção de práticas agrícolas sustentáveis. A colaboração contínua entre pesquisadores, formuladores de políticas e produtores será essencial para que essas inovações sejam efetivamente aplicadas em campo, beneficiando tanto os agricultores quanto o meio ambiente.

Palavras-chave: Agricultura mecanizada, Agricultura sustentável, Arranquio, Monitoramento da colheita, Recolhimento, Segurança alimentar.

1. Introdução

O amendoim é uma das principais oleaginosas cultivadas no mundo. É economicamente importante devido ao alto teor de óleo de suas sementes e ao sabor agradável que oferece aos consumidores. Além disso, desempenha um papel significativo na indústria alimentícia, sendo uma fonte essencial de proteína vegetal e

óleos (Cruz et al., 2021). Seu papel na indústria alimentícia é crucial, pois fornece uma fonte fundamental de nutrição e sabor para uma ampla gama de produtos. Globalmente, o amendoim é de grande relevância para as economias de vários países, com a China ocupando a posição de maior produtor mundial, respondendo por 37% da produção global (USDA, 2024).

Assim como outras culturas, o amendoim pode ser colhido manualmente, semimecanizado ou mecanizado. No entanto, a colheita mecanizada se tornou mais do que apenas uma opção, mas uma necessidade para otimizar o cultivo em larga escala, substituindo práticas manuais, que poderiam ser mais eficientes. Nesse sentido, Wessler et al. (2007) afirmam que a mecanização nas etapas de arranquio e recolhimento do amendoim aumenta a capacidade operacional, promovendo a expansão das áreas cultivadas. Além disso, Dawelbeit (1991) também destacou esse aumento na eficiência ao comparar quatro sistemas de colheita de amendoim, observando que o arranquio realizado por um conjunto mecanizado substitui o trabalho manual com a capacidade de executar o equivalente a aproximadamente 100 horas-homem por hectare.

Embora a mecanização tenha contribuído significativamente para o aumento da produtividade agrícola, a colheita do amendoim ainda enfrenta desafios significativos. Esses desafios, que podem influenciar a eficiência dessa operação, não devem ser subestimados. Eles variam desde as condições ambientais (Ormond et al., 2018; Zerbato et al., 2017), as características do maquinário utilizado (Santos et al., 2019), a qualidade da matéria-prima (Santos et al., 2021) até o nível de qualificação dos trabalhadores (Brito Filho et al., 2023). Assim, o gerenciamento eficaz da colheita mecanizada não é apenas importante, mas essencial para conhecer e controlar os níveis de perdas.

Quantificar essas perdas é crucial para melhorar a eficiência da colheita mecanizada de amendoim. Estimativas precisas permitem que os agricultores ajustem suas práticas de manejo e configurações de máquinas, minimizando perdas e maximizando a produtividade (Mirzazadeh et al., 2023). Além disso, estratégias práticas para reduzir perdas podem gerar ganhos socioeconômicos significativos ao melhorar a qualidade da colheita, ao mesmo tempo em que se alinham com os Objetivos de Desenvolvimento Sustentável (ODS), particularmente o ODS 12, que incentiva padrões de produção e consumo mais sustentáveis (Nações Unidas, 2023).

Portanto, considerando a importância de quantificar as perdas de amendoim para o desenvolvimento de uma colheita mais sustentável, nossa meta-análise fornece uma análise aprofundada de estudos que usam perdas para indicar a eficiência e a qualidade das operações mecanizadas na colheita de amendoim. Em nossa meta-análise, realizamos uma avaliação descritiva e quantitativa das principais perdas nas fases de arranquio e recolhimento. Além disso, investigamos as metodologias aplicadas para quantificar essas perdas e discutimos os fatores que influenciam as perdas nas fases de colheita. Por meio deste estudo sistemático, nosso objetivo foi identificar lacunas de conhecimento e oferecer orientações para pesquisas futuras para melhorar a eficiência e a sustentabilidade da colheita mecanizada de amendoim.

2. Protocolo de revisão sistemática

2.1. Fonte de dados e estratégia de busca

Os Itens de relatórios preferenciais para revisões sistemáticas e meta-análises (protocolo PRISMA) foi usado para orientar esta revisão sistemática e meta-análise (Figura 1). Iniciamos nosso processo concentrando nossos esforços de busca em artigos revisados por pares de bancos de dados estabelecidos e confiáveis, especificamente Scopus® e Web of Science™. Para garantir a precisão e eficácia de nossa busca, criamos uma sequência especial de caracteres específicas para pesquisa. Essas sequências integraram palavras-chave relevantes aos principais temas envolvendo perdas na colheita mecanizada de amendoim, combinadas com operadores booleanos de busca: "Loss*" AND "Harvest*" OR "Machine" OR "Mechanization" OR "Mechanized Harvest" OR "Digging" AND "Peanut" OR "Arachis hypogaea L." NOT "review" OR "meta-analysis", optando por excluir revisões e meta-análises. Além disso, uma técnica de "bola de neve", juntamente com o rastreamento de citações, foi incorporada para abranger todos os estudos pertinentes ao escopo de nossa busca.




Figura 1. Fluxograma do processo de meta-revisão sistemática. As caixas em cor cinza destacam as principais etapas do processo de revisão, enquanto as caixas em cor laranja indicam as fontes de dados e o fluxo do processo, incluindo estudos adicionais identificados por meio de busca de citações.

2.2. Critérios de elegibilidade

O escopo do nosso estudo se concentrou no monitoramento de perdas na colheita mecanizada de amendoim. Nesse contexto, nossa equipe de revisão conduziu uma avaliação metódica dos artigos para consistência e elegibilidade. Essa avaliação examinou minuciosamente títulos, resumos, palavras-chave, destaques, materiais e métodos e conclusões. Artigos estreitamente alinhados com nosso escopo de pesquisa foram incluídos. Por outro lado, para garantir a solidez da nossa meta-análise, excluímos intencionalmente materiais acadêmicos não revisados por pares, como capítulos de livros, anais de conferências, relatórios técnicos e tópicos relacionados ao desenvolvimento de projetos e otimização de máquinas de colheita. Também desconsideramos artigos que não apresentavam a metodologia usada para quantificar as perdas na colheita de amendoim.

2.3. Extração e análise de dados

Realizamos um rigoroso processo de avaliação para garantir a inclusão de informações pertinentes relacionadas a perdas na colheita mecanizada de amendoim. A extração de dados envolveu a exportação de informações para o Microsoft Excel e a organização das planilhas por tópicos, a saber, as características dos locais experimentais (Meio Ambiente), características específicas das máquinas (Máquina), características gerais das culturas (Matéria-prima), tipos de perdas quantificadas (Medição) e métodos de quantificação de perdas (Métodos). A Figura 2 mostra as principais variáveis caracterizadas pelos trabalhos selecionados em nossa pesquisa sistemática.




Figura 2. Variáveis extraídas na revisão sistemática de perdas na colheita mecanizada de amendoim.

Posteriormente, sintetizamos e assimilamos todas essas informações para transmitir resultados descritivos e analíticos da meta-análise. Aplicamos estatísticas descritivas para determinar medidas de posição e dispersão, proporcionando assim uma visualização clara das perdas nas principais etapas da colheita do amendoim. Essa análise nos permitiu identificar quais operações apresentam as maiores perdas e determinar a magnitude de cada tipo de perda dentro dessas operações.

3. Evolução das publicações sobre perdas na colheita mecanizada de amendoim

Nossa meta-análise sistemática abrangente identificou 322 artigos potenciais sobre o assunto crítico de perdas na colheita mecanizada de amendoim. No entanto, para garantir o máximo de rigor e confiabilidade em nossa síntese de evidências, apenas 20 estudos atenderam aos critérios de inclusão e foram considerados relevantes para o escopo desta pesquisa. Assim, a Figura 3 apresenta informações bibliométricas importantes sobre o desenvolvimento do tema, permitindo uma visão abrangente da evolução das publicações científicas sobre perdas na colheita mecanizada de amendoim. Além disso, destaca as principais instituições de ensino e autores que contribuíram para o avanço do conhecimento neste campo.




Figura 3. Literatura sobre monitoramento de perdas na colheita mecanizada de amendoim: A - Evolução histórica da literatura; B - Instituições responsáveis pelo maior número de publicações sobre perdas na colheita mecanizada de amendoim; C - Autores responsáveis pelo maior número de publicações sobre perdas na colheita mecanizada de amendoim.

Analisando o gráfico da evolução histórica da literatura (Figura 3A) sobre monitoramento de perdas na colheita mecanizada de amendoim, observamos um desenvolvimento lento entre 1991 e 2011, com a publicação de apenas quatro estudos na área. No entanto, desde 2013, houve uma contribuição contínua para o estado da

arte, com a publicação de pelo menos um artigo por ano. Embora o volume acumulado de publicações ainda seja baixo, o avanço do conhecimento neste campo é vital para promover pesquisas que aumentem a conscientização da sociedade sobre o controle do desperdício de alimentos. Além disso, os achados desses estudos podem fornecer informações valiosas para pesquisadores, formuladores de políticas e partes interessadas comprometidas com práticas agrícolas sustentáveis.

O Brasil e os Estados Unidos são líderes em contribuições científicas na área de perdas na colheita mecanizada de amendoim. No Brasil, a Universidade Estadual Paulista "Júlio de Mesquita Filho" (UNESP) se destaca como a principal instituição, participando com 13 das 20 publicações relevantes (Figura 3B). Nesse campo de pesquisa, a UNESP colaborou estreitamente com outras cinco instituições brasileiras, com destaque para a Universidade Federal de Lavras (UFLA) e a Universidade Estadual de Minas Gerais (UEMG), que ocupam o segundo lugar em número de publicações relacionadas às perdas de amendoim.

Devido a essa colaboração, mais de 65% dos principais autores responsáveis pela disseminação do conhecimento nesta área são brasileiros (Figura 3C). Destacam-se Silva RP, Santos AF e Zerbato C, com 11, 7 e 7 publicações, respectivamente. Esses pesquisadores são protagonistas no campo de pesquisa sobre colheita mecanizada de amendoim, contribuindo significativamente para o avanço do conhecimento. A predominância de publicações da UNESP e de outras instituições brasileiras reflete a importância do cultivo do amendoim para o país. O Estado de São Paulo, maior produtor de amendoim do Brasil (CONAB, 2024), concentra a maior parte das pesquisas devido à sua relevância na produção. O cultivo do amendoim influencia diretamente no desenvolvimento econômico do Estado, contribuindo substancialmente para a economia local, gerando empregos e promovendo o avanço tecnológico na cadeia produtiva. Além disso, essa cultura é utilizada para rotacionar áreas de renovação de cana-de-açúcar, proporcionando benefícios agrônômicos e econômicos que complementam a produção de cana-de-açúcar (Bertino et al., 2023).

Nos Estados Unidos, as pesquisas nesse campo são predominantemente conduzidas por instituições do Estado da Geórgia. Destacam-se o Laboratório Nacional de Pesquisa de Amendoim (NPRL), parte do Serviço de Pesquisa Agrícola do

Departamento de Agricultura dos Estados Unidos (USDA-ARS), e a Universidade da Geórgia (UGA). Essas instituições frequentemente colaboram com parceiros de pesquisa de outras universidades, empresas e organizações, como a Universidade de Auburn (Alabama) e a Universidade da Flórida.

3.1. Mecanização da Colheita do Amendoim

A colheita mecanizada do amendoim é um processo indireto que consiste em duas etapas principais: arranquio e recolhimento. Durante o arranquio, quando a cultura atinge mais de 70% de maturação de vagens, as plantas de amendoim são arrancadas do solo e invertidas com as vagens expostas e a parte aérea voltada para baixo (Silva, 2019). Devido ao alto teor de água das vagens (35 a 45%), elas permanecem expostas até atingirem o teor de água ideal de 18 a 24% para a próxima fase denominada recolhimento (Silva, 2019). Nesta etapa, as vagens são separadas do restante das plantas e transportadas para o tanque graneleiro para serem armazenadas e enviadas para a unidade de processamento (Tasso Júnior et al., 2004).

Portanto, a literatura acadêmica sobre perdas na colheita do amendoim reflete essa divisão, focando predominantemente nas operações de arranquio e recolhimento (Figura 4). A literatura sobre a etapa de arranquio do amendoim foi composta por 17 estudos que quantificaram as perdas associadas a essa fase. Destes, uma parcela significativa (N=10) aprofundou-se na discriminação de perdas quantitativas, diferenciando entre perdas visíveis, que ocorrem acima do solo, e perdas invisíveis, encontradas abaixo do solo após a passagem da máquina. Em relação à etapa de recolhimento, foram identificados cinco estudos. Destes, quatro quantificaram as perdas totais, com dois classificando essas perdas em duas categorias principais: perdas originadas da plataforma e perdas originadas dos mecanismos internos da máquina. Além disso, dois estudos avaliaram a qualidade da matéria-prima, classificando as perdas em quatro tipos: vagens inteiras, vagens quebradas, grãos soltos e impurezas.




Figura 4. O diagrama de Sankey ilustra a distribuição de estudos sobre perdas na colheita mecanizada de amendoim na literatura acadêmica.

A Figura 5 mostra a distribuição das perdas nas operações de arranquio e recolhimento durante a colheita mecanizada de amendoim. A etapa de arranquio apresenta maior variabilidade nas perdas, com valores percentuais variando de 3,06% a 47,09% e mediana de 13,02%. Essa elevada variabilidade está associada à presença de dois tipos principais de perdas nessa operação: as perdas visíveis, compostas por vagens e grãos deixados na superfície do solo, e as perdas invisíveis, que permanecem retidas abaixo da superfície do solo.

Em contrapartida, a etapa de recolhimento apresenta perdas mais concentradas, com mediana de 5,78% e menor amplitude, variando de 1,00% a 16,10%. Isso ocorre, porque as perdas no recolhimento são resultado apenas das perdas visíveis totais, que incluem as perdas acumuladas durante as operações de arranquio e recolhimento.

Esses resultados evidenciam que a operação de arranquio é a mais desafiadora no controle de perdas, principalmente devido à influência das perdas invisíveis, que contribuem significativamente para a variabilidade observada nessa etapa. De fato, as perdas invisíveis, por estarem diretamente relacionadas às condições do solo e ao manejo operacional, são um fator crítico que exige maior atenção. Portanto, tais evidências demonstram por que mais de 80% dos estudos na literatura acadêmica (Figura 4) são focados na operação de arranquio, refletindo sua importância no processo

de colheita mecanizada de amendoim e a necessidade de estratégias eficazes para mitigar as perdas nessa etapa.




Figura 5. Distribuição de perdas totais em operações mecanizadas de arranquio e recolhimento de amendoim. Os valores de perdas são expressos como uma porcentagem e calculados com base em dados de produtividade e valores de perdas fornecidos pelos autores dos estudos.

Atualmente, não há porcentagens médias bem estabelecidas para perdas na colheita mecanizada de amendoim, o que dificulta a criação de parâmetros claros para a indústria. Conforme ilustrado na Figura 5, observamos uma variação significativa de perdas entre as diferentes operações, destacando a necessidade de estudos mais aprofundados. Definir valores médios para perdas seria extremamente útil para os agricultores e a indústria, pois forneceria uma referência sólida para identificar e corrigir ineficiências.

As perdas de amendoim são significativamente maiores do que as de outras *commodities*, como soja, milho e algodão. Logo, buscar novas alternativas de monitoramento e controle dessas perdas podem ser cruciais para reduzi-las. Assim, adotar o uso de tecnologias mais avançadas as máquinas de colheita de amendoim podem ser alternativas eficientes para melhor compreensão dos fatores que contribuem

para o aumento das perdas. Uma vez considerando, que a obtenção de informações detalhadas sobre os parâmetros das operações ajudaria os operadores a ajustar as máquinas com mais precisão.

Por outro lado, outro fator que contribui para as altas perdas na colheita do amendoim é a falta de pesquisas focadas no controle efetivo dessas perdas. Há escassez de estudos explorando as combinações ideais de ajustes de máquinas em diferentes condições de cultivo para aumentar a eficiência operacional. A ausência de parâmetros bem definidos e recomendações adaptadas às diversas condições de campo dificulta a otimização do processo, resultando nas altas perdas observadas. Portanto, investir em pesquisas que abordem esses aspectos é essencial para melhorar o desempenho operacional e reduzir as perdas durante a colheita.

3.2. Arranquio de amendoim

As perdas nas operações de arranquio mecanizado são geralmente classificadas em três categorias: visíveis, invisíveis e totais. As perdas visíveis, que se encontram acima do solo, resultam do levantamento e da agitação das plantas pela correia vibratória durante a remoção do solo e o enleiramento das plantas. As perdas invisíveis se encontram abaixo da superfície do solo, ocorrendo devido à retenção das vagens no solo ou à ação das lâminas do arrancador. Essas lâminas realizam cortes superficiais, deixando algumas vagens enterradas, que são perdidas quando o solo é deslocado em direção à esteira vibratória. Já as perdas totais correspondem à soma das perdas visíveis e invisíveis, representando a totalidade das perdas geradas durante o processo de arranquio.

A análise do percentual de perdas na operação de arranquio (Figura 5) constamos que as perdas visíveis correspondem a 33,39% a 52,55% desse percentual total de perdas referente a essa operação. Enquanto as perdas invisíveis variam de 47,45% a 66,61%. Esses dados indicam uma maior concentração de perdas invisíveis do que de perdas visíveis. Além disso, há uma variabilidade considerável em ambos os tipos de perdas, como evidenciado pela ampla faixa entre valores máximos e mínimos. Essa alta

variabilidade sugere que a operação de arranquio mecanizada é influenciada por diversos fatores e não por um único aspecto isolado.




Figura 6. Distribuição percentual de perdas visíveis e invisíveis em relação às perdas totais no arranquio mecanizado de amendoim. O percentual foi calculado a partir da soma das categorias de perdas observadas nos estudos aceitos para análise.

Portanto, nossas descobertas ressaltam a necessidade de concentrar esforços na redução de perdas invisíveis, que representam a maioria das perdas totais e são as mais desafiadoras devido à sua ocorrência subterrânea. Assim, adotar tecnologias avançadas e ajustes operacionais específicos durante o arranquio pode ser essencial para mitigar perdas visíveis e invisíveis.

3.3. *Recolhimento do amendoim*

O recolhimento é a segunda etapa da colheita mecanizada do amendoim, na qual as vagens são separadas da planta, preparando-as para o processamento. No entanto, a literatura carece de estudos específicos focados nesta etapa do recolhimento do amendoim. Em geral, ao avaliar a operação de colheita, o percentual de perdas visíveis totais é considerado um dos principais indicadores da qualidade do processo. Essas

perdas resultam da soma de perdas nos mecanismos internos, perdas naturais no processo e na plataforma, geralmente devido a ajustes inadequados ou má manutenção do equipamento (Pereira et al., 2020).

Nossa revisão revelou cinco estudos que se aprofundaram na etapa de recolhimento do amendoim. Os resultados desses estudos, descritos na Figura 7, mostram que a plataforma é a principal fonte de perdas, com valores percentuais variando de 48,02% a 87,35%, das perdas totais da operação de recolhimento encontradas em campo. Esses dados ressaltam o papel da plataforma como a principal fonte de perdas, muitas vezes devido a ajustes incorretos e acúmulo de material vegetal. Esse acúmulo ocorre frequentemente em consequência da qualidade das leiras formadas na operação de arranquio anterior. Leiras malformadas, com muito ou pouco material vegetal ou dimensões irregulares, podem afetar diretamente o fluxo de material para a máquina de colheita, comprometendo a eficiência da coleta.




Figura 7. Porcentagem de perdas na plataforma e mecanismos internos durante a operação mecanizada de recolhimento de amendoim, com base nas perdas totais encontradas em campo.

As perdas associadas aos mecanismos internos das máquinas variam de 12,65% a 51,98%. Embora essas perdas sejam, em média, menores que as da plataforma, a

ampla variação nos dados sugere que, sob certas condições operacionais, os mecanismos internos também podem contribuir significativamente para as perdas totais. Assim, a escolha da máquina de colheita se torna crucial, pois elas usam dois tipos principais de sistemas de debulha e separação: fluxo tangencial ou radial e fluxo axial (Camolese et al., 2015). As colhedoras de fluxo tangencial debulham por impacto das barras do cilindro, enquanto as colhedoras de fluxo axial debulham por atrito conforme o material se move ao longo do eixo do cilindro. Essas diferenças nos mecanismos internos explicam por que as respostas operacionais podem variar significativamente entre as máquinas, dependendo das condições de trabalho e do ambiente em que operam. Isso destaca a necessidade urgente de mais estudos para identificar as melhores práticas e tecnologias para reduzir perdas e melhorar a eficiência do processo.

Além disso, assim como na operação de arranquio, a etapa de recolhimento também apresenta alta variabilidade nas perdas, evidenciada pela ampla faixa de valores registrados. Essa variabilidade sugere a influência de diversos fatores, como as configurações da máquina, o tipo de colhedora utilizada, as condições do solo e do material vegetal e a qualidade das leiras formadas. No entanto, esses achados também ressaltam o potencial de melhoria no processo de colheita.

Dentro desse contexto, outro importante indicador da eficiência da operação de recolhimento de amendoim são as perdas qualitativas diretamente relacionadas à qualidade do material colhido. No entanto, a avaliação dessas perdas ainda é pouco explorada na literatura, com apenas dois estudos recentes abordando essa variável para avaliar a qualidade da operação no campo (Brito Filho et al., 2023; Dos Reis et al., 2022). As perdas qualitativas são relevantes para o setor, pois influenciam diretamente nos descontos financeiros aplicados ao material colhido, afetando o retorno econômico do produtor rural.

Na literatura, as classes de materiais que mais se destacaram como indicadores qualitativos foram vagens inteiras, vagens quebradas, grãos soltos e impurezas. Nossa análise quantitativa encontrou valores percentuais médios de 79,10%, 6,20%, 4,40% e 10,30% para cada classe, respectivamente (Figura 8). No entanto, esses níveis são desconhecidos na literatura, o que impossibilita comparações mais abrangentes. Além disso, outra categoria mencionada nos estudos revisados inclui vagens com sementes

deformadas ou sem sementes (Brito Filho et al., 2023; Dos Reis et al., 2022). No entanto, essa categoria está mais relacionada às características específicas de desenvolvimento da cultura do amendoim do que diretamente à operação mecanizada. No entanto, essa classe pode ser considerada uma impureza, pois, durante o processo de beneficiamento, não tem utilidade para a indústria.




Figura 8. Porcentagens de perdas qualitativas na colheita mecanizada de amendoim, categorizadas em vagens inteiras, vagens quebradas, grãos soltos e impurezas. O gráfico mostra a influência de diferentes sistemas de preparo do solo (Convencional, Reduzido, Rip Strip, Convencional + canteiros), teor de água das vagens e sistema de trilha do tipo axial e tangencial, destacando os impactos de cada fator na qualidade do material colhido. *Canteiros feitos com rotocanteirador; **Canteiros feitos com enxada rotativa

Nossa meta-análise revela que o método de preparo do solo pode influenciar na qualidade do material colhido. Ao comparar os efeitos de diferentes sistemas de preparo do solo, observamos que esses sistemas afetam diretamente as classes de qualidade do material colhido. O sistema de preparo do solo convencional é a principal escolha dos agricultores e apresenta valores semelhantes aos valores da média geral. No entanto, Dos Reis et al. (2022) constataram que o sistema de preparo reduzido pode ser uma alternativa viável ao convencional, pois resultou em perdas qualitativas semelhantes.

Além disso, Brito Filho et al. (2023) destacaram que o uso do sistema convencional mais enxadas rotativas ajudou a preservar melhor a qualidade do material, resultando em maiores porcentagens de vagens inteiras.

Por outro lado, o tipo de sistema de debulha utilizado pelas colhedoras também desempenha um papel fundamental na preservação da integridade das vagens. Observamos que os sistemas de debulha axial e tangencial têm impactos diferentes na qualidade do material. O sistema de debulha axial, que realiza a debulha por atrito, mostrou-se mais eficiente na preservação da integridade das vagens, resultando em maior proporção de vagens inteiras em comparação ao sistema tangencial, que utiliza impacto para separar o material (Dos Reis et al., 2022). O impacto gerado no sistema tangencial facilita uma fragmentação mais significativa das vagens e aumenta a quantidade de grãos soltos.

Portanto, a análise desses dados reforça a necessidade de focar não apenas nas perdas quantitativas, mas também nas perdas qualitativas, fundamentais para a valorização do amendoim. Embora os dados demonstrem diferenças entre os sistemas de preparo do solo e os sistemas de debulha, é importante destacar que as pesquisas nessa área ainda precisam ser mais exploradas. A flutuação dos resultados entre os diferentes sistemas destaca a necessidade de mais estudos para validar e ampliar esses achados. Pesquisas adicionais são essenciais para estabelecer uma base sólida sobre o impacto dos sistemas de preparo do solo e debulha na eficiência da colheita e na qualidade do material colhido, garantindo as melhores práticas.

3.3. Fatores identificados na colheita mecanizada de amendoim

A medição precisa das perdas, incluindo perdas totais, visíveis, invisíveis, da plataforma, dos mecanismos internos da máquina e de qualidade, são essenciais para avaliar a eficácia do processo de colheita e identificar áreas de melhoria (Ormond et al., 2018; Dos Reis et al., 2022). Implementar métodos sistemáticos para medir e monitorar essas perdas pode ajudar a desenvolver soluções eficazes. Por fim, considerando os seis principais fatores (meio ambiente, máquina, medição, material e método), é possível listar os principais indicadores que influenciam as operações que envolvem a colheita da

cultura. A análise detalhada desses fatores permite desenvolver estratégias para melhorar o processo de colheita mecanizada de amendoim para melhorar o desempenho e minimizar as perdas.

Encontramos apenas um estudo sobre consistência metodológica (Figura 9A). Em outras palavras, todos os artigos completos careciam de informações em algum nível crítico, desde dados de compactação do solo até informações de orientação. As porcentagens em nosso banco de dados de meta-análise variam amplamente, de aproximadamente 38,46% a 92,31%. Portanto, a literatura típica pode fornecer, em média, cerca de 67,33% do total de dados que esperamos em uma metodologia consistente. O conjunto de informações para arranjo e coleta é o mesmo, com um total de 15 filtros. No entanto, em relação à operação de coleta, um conjunto mais extenso de tópicos é atendido, representando 65,88% do total de cinco estudos avaliados, atendendo a 68,57% dos filtros (Figura 9C). Em contraste, o arranjo representa 60,55% dos 17 estudos avaliados e atende a cerca de 66,97% do total de filtros usados (Figura 9B).




Figura 9. Confiabilidade da pesquisa sobre perdas na colheita mecanizada de Amendoim. (a) Qualidade geral de todos os artigos de texto completo. (b) Qualidade dos artigos que abordam a operação de arranquio de acordo com critérios qualitativos. (c) Qualidade dos artigos que abordam a operação de coleta de acordo com critérios qualitativos.

Particularmente na disposição, cinco (29,41%) dos 17 artigos conseguem fornecer informações acima de 80% sobre textura do solo, preparo do solo, cultivar, produtividade e perdas totais. Os outros 12 estudos referem-se a dados ausentes sobre compactação, teor de água do solo, maturação, teor de água da vagem, força de desprendimento das vagens, perdas visíveis e invisíveis e informações sobre sistema de navegação automático, popularmente conhecido como piloto automático, velocidade de deslocamento da máquina, tipo de arrancador e metodologia utilizada. Por outro lado, ao avaliar o fator solo e lidar com a coleção, dois estudos descrevem 100% das informações sobre a textura e o preparo do solo utilizados. Outros sete documentos focados na coleção podem pontuar acima da média da qualidade da pesquisa. Eles descrevem itens relacionados à cultivar, produtividade, perdas totais, velocidade, sistema de debulha e tipo de metodologia utilizada para quantificar as perdas. Assim, verifica-se que as principais inconsistências dentro da coleção se concentram na ausência de informações sobre maturação, teor de água da vagem, quantificação das perdas na plataforma e na máquina, perdas qualitativas, uso do piloto automático e orientação.

Os artigos sobre arranquio sempre descrevem produtividade e perdas totais. Entretanto, os autores raramente fornecem informações completas e confiáveis sobre compactação do solo, força de desprendimento do ginóforo e orientação, aspectos mencionados em apenas 20% dos artigos, tornando-os as principais limitações. Além disso, acadêmicos que moldam a literatura sobre aspectos orientados às plantas fornecem aproximadamente 60% das informações sobre perdas visíveis e invisíveis. Quanto ao pagamento, nenhum dos documentos consultados sugere detalhes sobre a orientação no momento da colheita, e informações sobre maturação nesta fase estão presentes em apenas 20% dos materiais que mencionam a coleta. Fica claro, portanto, que os pesquisadores precisam complementar as informações sobre as etapas da colheita mecanizada para melhor estruturar os dados que refletem as perdas na colheita.

4. Fatores associados às perdas na colheita mecanizada de amendoim

4.1. Fatores ambientais

A operação de arranjo na colheita mecanizada de amendoim é uma etapa crucial que influencia diretamente nas perdas durante a colheita. O tipo de solo, preparo e textura têm impacto significativo na eficácia desta operação. Por exemplo, o aumento da umidade em solos argilosos pode reduzir a resistência do solo, facilitando o arranquio e reduzindo perdas visíveis e invisíveis. Solos com maior umidade apresentaram menor dureza e ruptura mais fácil, sugerindo maior facilidade no arranjo e resultando em menores perdas visíveis e totais. Zerbato et al. (2014) mostraram que a umidade no solo de 24,8%, as perdas visíveis e invisíveis foram menores em condições de umidade de 19,3%, destacando a importância da umidade do solo na redução das perdas durante o arranjo. Além disso, o preparo do solo também é um fator determinante na eficácia do arranjo. Utilizar sistemas de preparo que promovam uma estrutura de solo mais friável e menos compactada pode melhorar o desempenho do arranjo mecanizado. Por exemplo, sistemas de plantio direto ou mínimo que mantêm a cobertura vegetal no solo podem ajudar a preservar a umidade e a estrutura do solo, reduzindo a resistência durante o arranjo e, conseqüentemente, as perdas (Dos Reis et al., 2022).

A textura do solo, definida pela proporção de areia, silte e argila, também influencia significativamente o arranjo. Solos argilosos, por exemplo, tendem a ter menos coesão, o que pode resultar em maiores perdas durante o arranjo devido à menor aderência do solo nas raízes das plantas. Por outro lado, solos argilosos, embora mais desafiadores de manusear em condições secas, quando bem irrigados, fornecem um ambiente que facilita o arranjo, com menor risco de quebra de vagens e menores perdas. Estudos sugerem que a maior quantidade de perdas visíveis e totais pode ser encontrada em populações de plantas mais altas em condições de solo com menor umidade, indicando a complexa interação entre textura do solo e densidade de semeadura (Zerbato et al., 2019). Além disso, Jackson et al. (2011) destacam a prática de canteiros e seu impacto na redução de perdas durante a operação de arranquio e no aumento da produtividade do amendoim. Essa técnica, que envolve a criação de canteiros antes da semeadura, ajuda a manter a estrutura do solo, permitindo melhor penetração e extração

das raízes das plantas de amendoim. Isso resulta em menores perdas durante a colheita, melhor drenagem do solo e redução da compactação.

Durante a operação de recolhimento na colheita mecanizada de amendoim, o solo desempenha um papel crucial na determinação das perdas. O preparo convencional do solo resulta em menor variabilidade de perdas e melhor qualidade de operação, independentemente da velocidade deslocamento da máquina de colheita. Em contraste, o preparo conservacionista apresentou maior variabilidade de perdas devido ao aumento do fluxo de material na plataforma de coleta, o que pode gerar perdas antes do processamento completo pelo sistema de separação e trilha da máquina (Ormond et al., 2018).

Em relação à umidade do solo durante o recolhimento, fatores como produtividade e perdas são influenciados. Solos com 24,8% de umidade proporcionam maiores ganhos de produtividade e menores perdas, especialmente em populações de plantas mais densas, sugerindo que o manejo adequado da umidade do solo pode otimizar a eficiência da coleta e minimizar as perdas (Zerbato et al., 2017). A umidade do solo impacta significativamente em menores perdas durante a operação de recolhimento, pois a umidade melhora a coesão do solo e facilita a extração de plantas sem danos significativos às vagens (Brito Filho et al., 2023).

A preparação do solo também desempenha um papel crucial na influência das perdas durante o recolhimento. Sistemas de preparo reduzidos do solo e métodos strip-full demonstraram ter menos perdas em comparação com a preparação convencional. Esses métodos preservam melhor a estrutura do solo e reduzem a resistência ao movimento da máquina, melhorando assim a eficiência do recolhimento (Dos Reis et al., 2022). A influência do preparo do solo nas perdas de recolhimento ressalta a importância do manejo do solo no processo de colheita mecanizada de amendoim.

4.2. Fatores relacionados a matéria-prima

A medição da produtividade é essencial para entender, quantificar e interpretar corretamente a magnitude das perdas e identificar oportunidades de melhoria na colheita

mecanizada de amendoim. Avaliar apenas a porcentagem de perdas sem relação com a produtividade total pode fornecer uma visão incompleta do impacto real dessas perdas.

A medição da produtividade ajuda a contextualizar as perdas ajustando as práticas de gestão para otimizar o desempenho e minimizar as perdas. Estudos mostram que relacionar as perdas totais de produtividade fornece uma visão mais completa e eficiente (Colvin et al., 2018; Santos et al., 2016; Santos et al., 2013; Lamb et al., 2004; Beam et al., 2002). Assim, a avaliação integrada da produtividade e das perdas é essencial para decisões informadas e o sucesso econômico dos produtores.

A escolha de cultivares de amendoim não é apenas uma questão de preferência, mas uma decisão crucial que pode impactar significativamente seus resultados financeiros. Estudos mostraram que diferentes cultivares exibem variações significativas na resistência dos ginóforos, influenciando diretamente as perdas de vagens. Por exemplo, a pesquisa de Sorensen et al. (2017) descobriu que cultivares como 'Georgia-06G' e 'Florida-07' com maior resistência dos ginóforos experimentaram perdas menores e renda maior do que outras cultivares. Isso ressalta os benefícios financeiros de selecionar cultivares com características favoráveis para reduzir perdas e maximizar a lucratividade.

Além disso, Colvin et al. (2018) encontraram resultados semelhantes ao comparar as cultivares "Georgia-06G" e "Lifeguard", concluindo que a Georgia-06G apresentou menor perda de vagens devido à sua robustez. A pesquisa de Sorensen et al. (2015) reforça essa conclusão, mostrando que a força do ginóforo é um fator determinante na seleção de cultivares para minimizar perdas e maximizar a produtividade (Colvin et al., 2018; Sorensen et al., 2015). A escolha adequada das cultivares pode otimizar a colheita e reduzir significativamente as perdas, resultando em uma produção mais eficiente e rentável.

A maturação das vagens de amendoim é um fator determinante para minimizar as perdas durante a colheita. Estudos mostram que a escolha do momento ideal para a colheita, com base na maturação das vagens, pode reduzir significativamente as perdas. Santos et al. (2021) determinaram que o melhor momento para a colheita é influenciado por variáveis como maturação e umidade do solo, enfatizando a importância do monitoramento dessas variáveis para otimizar a colheita. Da mesma forma, Sorensen et

al. (2017) avaliaram a resistência do ginóforo do amendoim e descobriram que o amadurecimento dos frutos afeta diretamente a produtividade e as perdas, sugerindo que a escolha do momento certo para a colheita é crucial para minimizar as perdas e maximizar o desempenho.

Colvin et al. (2018) também enfatizaram o papel da maturação na determinação do momento ideal para a colheita, observando que a sanidade da cultura e a maturação influenciam diretamente no desempenho e nas perdas. Este estudo demonstrou que as colheitas conduzidas no momento certo de maturação resultam em menores perdas e maior qualidade das vagens. Além disso, Santos et al. (2016) examinaram a relação entre a maturação das vagens e as perdas durante a colheita, sugerindo que a alta maturação pode aumentar as perdas devido a menor força de desprendimento das vagens. Complementando esses achados, dos Santos et al. (2013) concluíram que a colheita aos 120 dias após a semeadura é ideal para minimizar as perdas e maximizar a produtividade, reforçando a importância de considerar a maturação na programação da colheita e o papel crucial do público na implementação desses achados.

O teor de água das vagens de amendoim é um fator crítico na colheita mecanizada, pois influencia diretamente nas perdas durante o processo. Bertonha et al., (2014) analisaram as perdas no arranquio mecanizado do amendoim em função dos teores de água nas vagens usando o teste de Chauvenet. O estudo foi conduzido no município de Olímpia, Estado de São Paulo, Brasil, em solo de textura argilosa com um arrancador-invertedor de amendoim 4x2, e foram avaliados quatro teores de água nas vagens: 23,6%, 29,5%, 33,9% e 36,0%. Os resultados mostraram que as perdas visíveis e totais são maiores quando o arranquio é realizado com maiores teores de água, identificando 23,6% como o teor de água adequado para a operação de arranquio, minimizando assim as perdas durante a colheita.

Complementando esses achados, Cavichioli et al. (2014) quantificaram as perdas de amendoim durante a colheita mecanizada em função dos períodos do dia e observaram que parte das perdas se deve ao teor de água da vagem estar fora do intervalo recomendado na bibliografia (acima de 18% e abaixo de 24%). Cavichioli et al. (2014) mencionaram que após o arranquio, as vagens de amendoim e seus ramos apresentam alto teor de água (entre 35% e 45%). Após um período médio de secagem

de quatro dias, o teor de água foi reduzido para valores médios entre 18% e 24%. Quando o teor de água da matéria vegetal é baixo, as vagens se destacam do ramo durante a etapa de recolhimento, resultando em perdas mais significativas. Por outro lado, maiores teores de água dificultam o desprendimento da matéria vegetal das vagens.

A ocorrência de chuvas durante a colheita aumenta o teor de água das vagens e da matéria vegetal, estendendo o tempo necessário para atingir o teor ideal para o recolhimento, o que resulta em maiores perdas e comprometimento da qualidade do amendoim. Santos et al. (2021) investigaram em função dos teores de água das vagens (15% e 20%) na colheita mecanizada e descobriram que as perdas foram maiores na plataforma do que nos mecanismos internos da máquina. A qualidade da colheita não foi afetada pelo teor de água nas vagens, mas a regulação correta das máquinas agrícolas pode restringir as perdas a aproximadamente 1% da produtividade. Vagens com 15% de teor de água reduziram impurezas minerais e vegetais, enquanto vagens com 20% de teor de água forneceram mais vagens inteiras.

Esses estudos ressaltam a complexidade do problema. Eles sugerem que manter o teor de água das vagens dentro do intervalo ideal é essencial para minimizar as perdas durante a colheita mecanizada de amendoim. No entanto, não se trata apenas de controlar o teor de água das vagens. É crucial otimizar a eficiência da colheita considerando fatores como condições climáticas e a operação adequada do equipamento de colheita.

4.3. Fatores da máquina

As características das máquinas são cruciais para a eficiência da colheita de amendoim. Regulagens inadequadas, falta de manutenção e baixos níveis tecnológicos podem impactar diretamente nas perdas durante o processo e degradar a qualidade da matéria-prima. Por exemplo, a manutenção regular das lâminas do arrancador-invertedor de amendoim pode reduzir significativamente as perdas durante o processo de arranquio mecanizado (Dos Santos et al., 2021).

As geotecnologias de sistema de navegação automática desempenham um papel fundamental na redução da variabilidade das operações mecanizadas e na minimização de perdas (Santos et al., 2016). Além disso, quando essa geotecnologia é estendida a outras operações, como a semeadura, ela ajuda a manter a precisão do alinhamento entre as passadas do trator durante a semeadura quanto no arranquio, mostrando que o sistema de navegação automática reduz erros de paralelismo e perdas associadas à colheita (Zerbato et al., 2019; Dos Santos et al., 2018).

Apesar do nível tecnológico relativamente baixo das máquinas de colheita de amendoim em comparação com as usadas em outras culturas, a velocidade de deslocamento é outro fator-chave que influencia diretamente a eficiência das operações mecanizadas. Ajustar a velocidade com base nas condições de campo é essencial para otimizar a eficiência e minimizar perdas. Zerbato et al. (2018) compararam diferentes velocidades de deslocamento durante a fase de arranquio e descobriram que operar a 6 km h⁻¹ não resultou em uma diferença significativa em comparação a 4,5 km h⁻¹. Portanto, a velocidade mais alta pode ser usada para otimizar o tempo de operação e cobrir uma área maior sem comprometer a qualidade da colheita. Na fase de recolhimento, Ormond et al. (2018) observaram que operar a 8 km h⁻¹ resultou em maior eficiência e menos variabilidade nas perdas em comparação com velocidades mais baixas (4 km h⁻¹ e 6 km h⁻¹), onde a operação apresentou mais instabilidade.

Além do impacto da velocidade, o tipo de sistema de debulha usado nas colhedoras também afeta o desempenho da colheita (Dos Reis et al., 2022). Ajustes nos pinos batedores, com base no nível do teor de água das vagens no campo, são cruciais. Esses ajustes determinam se o processo de debulha será mais ou menos agressivo, o que impacta diretamente na integridade das vagens durante a colheita.

5. Monitoramento de perdas na colheita mecanizada de amendoim

O monitoramento de perdas na colheita mecanizada de amendoim é um grande desafio para garantir a eficiência operacional e minimizar os impactos econômicos. A maioria dos estudos revisados nesta meta-análise utilizou métodos tradicionais de quantificação que dependem da geometria da estrutura e da experiência dos analistas.

Embora amplamente utilizados, esses métodos apresentam desafios porque são demorados, trabalhosos e, em alguns casos, destrutivos.

Dentre as metodologias de quantificação de perdas, a mais comum é o uso de armações retangulares ou circulares. Este método permite uma estimativa direta das perdas por meio da contagem ou mensuração da massa das amostras. Todos os estudos analisados nesta pesquisa se concentraram na quantificação das perdas totais de amendoim (Figura 4). No entanto, apenas uma parte dos estudos se preocupou em diferenciar perdas visíveis das invisíveis na operação de arranquio, bem como separar perdas ocorridas na plataforma e nos mecanismos internos durante a operação de recolhimento. Essa diferenciação é crucial para uma compreensão abrangente das perdas e para o desenvolvimento de soluções direcionadas.

Na etapa de arranquio, a principal metodologia para quantificar perdas é o uso de armações retangulares. Esta abordagem é amplamente utilizada devido à sua simplicidade e rápida implementação, cobrindo uma área fixa de 1 a 2 m². Ela permite estimar diretamente as perdas visíveis por meio da contagem e mensuração da massa das vagens após a passagem da máquina. No entanto, a medição de perdas invisíveis requer mais tempo e esforço, pois tais perdas ocorrem abaixo da superfície do solo, exigindo arranquio manual de 15 a 20 cm.

Na etapa de recolhimento, a armação retangular continua sendo o método mais utilizado para quantificar as perdas. No entanto, para distinguir as perdas ocorridas na plataforma daquelas associadas aos mecanismos internos da colhedora, a operação deve ser interrompida para realizar a medição, o que compromete a eficiência operacional. Alternativamente, alguns estudos adotaram a armação circular, que representa melhor as perdas. Normalmente, utilizando quatro armações circulares de 0,25 m² distribuídos ao longo da operação, este método permite coletar amostras sem interromper a colheita, preservando o desempenho operacional da colhedora.

Neste contexto, ambas as metodologias apresentam vantagens e desvantagens. A armação retangular é rápida e fácil de montar e é amplamente utilizada para quantificar as perdas totais durante as operações de colheita. Entretanto, sua precisão é limitada, com tendência a subestimar as perdas, além de interferir no fluxo de trabalho da colhedora quando é necessário identificar as fontes exatas das perdas, sejam elas da

plataforma ou dos mecanismos internos (como debulha, separação e limpeza). Em contrapartida, a armação circular oferece maior acurácia e confiabilidade, representando melhor a variabilidade das perdas ao cobrir múltiplos pontos de amostragem, o que reduz o erro amostral. Entretanto, essa abordagem demanda tempo adicional para análise devido ao maior número de amostras, embora não interfira na operação da colhedora. Portanto, a escolha entre essas metodologias dependerá das necessidades e objetivos da fazenda.

Entretanto, a maioria dos estudos foca na mensuração de perdas quantitativas, deixando as perdas qualitativas como uma área menos explorada. A mensuração de perdas qualitativas envolve a coleta de amostras do material colhido durante a operação, o que pode ser feito na saída do elevador de grãos (Dos Reis et al., 2022) das colhedoras, no tanque graneleiro (Brito Filho et al., 2023) ou nos pontos de transbordo. Essa análise permite avaliar a integridade do material colhido, como a porcentagem de grãos danificados. Entretanto, pesquisas sobre métodos padronizados para coleta e identificação de qualidade ainda estão em estágios iniciais. Portanto, estudos futuros devem focar no desenvolvimento de protocolos mais robustos e no estabelecimento de parâmetros que possam ser considerados indicadores confiáveis da eficiência da colheita de amendoim.

Finalmente, a maioria dos estudos revisados foi conduzida em campos comerciais, reforçando a confiabilidade dos dados obtidos por meio de medições manuais detalhadas em comparação com estudos baseados apenas em informações do(a) agricultor(a). Entretanto, uma limitação padrão desses estudos é a falta de tecnologias automatizadas que substituam métodos manuais de quantificação de perdas para medição quantitativa e qualitativa. Essa lacuna destaca a necessidade de inovação e ferramentas mais eficientes para monitorar perdas na colheita mecanizada.

6. Principais lacunas identificadas

6.1. Colheita mecanizada

As perdas na colheita mecanizada de amendoim continuam sendo um problema significativo, principalmente durante as fases de arranquio e recolhimento. Diversas lacunas de pesquisa emergem dessas operações, oferecendo oportunidades para estudos futuros que busquem otimizar o processo de colheita e reduzir perdas. Durante a etapa de arranquio, as lacunas mais evidentes estão relacionadas aos ajustes finos, como a regulação da intensidade de vibração das esteiras dos arrancadores e sua relação com diferentes condições do solo. Além disso, o estudo de Dos Santos et al. (2021) revelou que lâminas desgastadas do arrancador podem aumentar as perdas em até 22%. No entanto, ainda há pouca clareza sobre o momento ideal para a substituição dessas lâminas. Portanto, tais atividades ainda precisam ser mais bem compreendidas.

Na fase de recolhimento, o desempenho dos sistemas de debulha e separação nas colhedoras também se destaca como uma lacuna. Dos Reis (2022) indicam que sistemas de fluxo axial, mais suaves, tendem a ser mais eficazes em condições de menor teor de água das vagens, enquanto sistemas de fluxo tangencial, mais agressivos, causam maiores danos ao material colhido. No entanto, otimizar os ajustes dessas máquinas ao longo do dia, com base nas variações climáticas e nas condições do material colhido, ainda é pouco explorado. Ajustes como o ângulo dos pinos batedores e a velocidade de operação em diferentes tipos de solo e regiões do país são outros fatores que requerem maior investigação.

6.2. Influências ambientais

O preparo do solo apresenta desafios que influenciam diretamente a eficiência da colheita mecanizada de amendoim. Pesquisas preliminares sugerem que o tipo de preparo do solo pode impactar as perdas (Brito Filho et al., 2023; Dos Reis et al., 2022). No entanto, uma investigação mais abrangente é necessária para entender como diferentes métodos de preparo do solo afetam o desempenho da colhedora. A adoção de práticas como o uso de canteiros, comumente aplicadas nos Estados Unidos (Truman et al., 2012; Jackson et al., 2011) e no cultivo de culturas subterrâneas como a batata, deve ser mais explorada no Brasil para o cultivo de amendoim (Brito Filho et al., 2023). Também é crucial integrar análises econômicas a esta pesquisa para avaliar os

potenciais benefícios econômicos da adoção de novos sistemas de preparo do solo, considerando a produtividade e a redução de perdas.

As condições climáticas, particularmente a umidade do solo e o teor de água da vagem, são fatores críticos que impactam diretamente o processo de colheita. Santos et al. (2021) realizaram estudos com vagens com teor de água da vagem entre 15% e 20%, mas não necessariamente como a faixa ideal, mas sim como referência para investigar sua influência nas perdas durante a colheita. Portanto, outras faixas de teor de água da vagem ainda precisam ser exploradas para entender melhor como esse fator afeta o desempenho das máquinas e a eficiência do processo. A interação entre o teor de água das vagens e condições do solo, bem como os ajustes necessários nas máquinas, ainda não foram suficientemente estudados. Pesquisas futuras devem se concentrar no desenvolvimento de estratégias de ajuste dinâmico das máquinas, considerando variações climáticas e do solo ao longo do dia, para otimizar o processo de colheita e reduzir perdas.

6.3. Colheita de amendoim

A força de desprendimento da vagem ainda precisa de mais investigação. Devido ao hábito de crescimento indeterminado do amendoim, é crucial identificar os fatores que influenciam a queda da vagem durante a colheita. Questões importantes incluem se vagens mais maduras têm menor resistência à queda do que vagens imaturas e como o teor de água da vagem afeta essa resistência. Estabelecer parâmetros claros para a força de queda com base em diferentes estádios de maturação pode fornecer percepções valiosas, permitindo regulagens mais precisas nas operações de colheita e, assim, reduzindo perdas associadas ao desprendimento inadequada da vagem.

6.4. Quantificações de perdas

Em relação às metodologias de quantificação de perdas, uma lacuna significativa está na padronização das dimensões das armações retangulares utilizadas para medir perdas. A questão da dimensão ideal permanece em aberto: seria mais eficiente utilizar

armações retangulares de 1 m², 2 m² ou até maiores, como 5 m²? A falta de estudos comparativos sistemáticos entre diferentes tamanhos de armações dificulta determinar qual dimensão oferece a melhor acurácia de medição e praticidade operacional em campo. Definir um padrão otimizado é essencial para garantir medições mais confiáveis e consistentes.

Além disso, estudos comparativos entre armações retangulares e circulares são necessários, especialmente na fase de recolhimento. Qual das duas seria mais eficaz em capturar com precisão as perdas e representar a variabilidade de campo? Embora a armação circular ofereça maior representatividade, a questão de qual método é mais adequado para cada fase de colheita e sob diferentes condições de campo ainda é um ponto em aberto para futuras investigações.

7. Direção e orientação para pesquisas futuras

Dadas as lacunas identificadas na colheita mecanizada de amendoim, é crucial direcionar pesquisas futuras para otimizar o processo, minimizar perdas e melhorar a qualidade da colheita. Uma área promissora é o desenvolvimento de novas maneiras de quantificar perdas, especialmente com inteligência artificial (IA). Os modelos de IA podem ser treinados para identificar e classificar objetos relacionados a perdas na colheita, abrindo caminho para o desenvolvimento de sensores em tempo real capazes de monitorar continuamente as perdas durante a colheita. Esse avanço reduziria a dependência de medições manuais e aumentaria a precisão da estimativa de perdas durante todo o processo.

Além disso, os métodos de aprendizado de máquina e profundo podem melhorar as práticas de colheita aprendendo com dados coletados ao longo do tempo. A integração de variáveis como condições climáticas, características da cultura e informações do solo, combinadas com técnicas de sensoriamento remoto, representa uma oportunidade significativa para prever as melhores condições de colheita e evitar perdas causadas por adversidades como alta teor de água (vagens e solos), doenças, pragas ou maturação inadequada das vagens. Ao combinar todos esses dados, os

algoritmos de IA podem otimizar as operações e fornecer recomendações automatizadas em tempo real para as regulagens da máquina.

Outra área de interesse para pesquisas futuras é a identificação de zonas de manejo, ou também conhecidas como Unidades de Gestão Diferenciada (UGDs), com diferentes níveis de perdas, como alto, médio e baixo. Isso permitiria regulagens personalizadas da máquina para atender às condições específicas de cada área, criando uma colheita de precisão e específica. Regular a velocidade de deslocamento da máquina, o ângulo dos pinos batedores ou mesmo a intensidade da debulha para cada zona de manejo poderia reduzir potencialmente o nível de perdas e aumentar a eficiência operacional.

8. Conclusões

Desenvolvemos uma revisão abrangente da literatura sobre monitoramento de perdas na colheita mecanizada de amendoim. Identificamos as principais metodologias de quantificação e discutimos os fatores que influenciam essas perdas. Além disso, destacamos lacunas importantes que abrem espaço para pesquisas futuras. Nossa meta-análise avaliou métodos de quantificação de perdas e as principais fases operacionais na colheita mecanizada de amendoim.

A aplicação de soluções tecnológicas foi um dos pontos-chave identificados como uma forma promissora de melhorar a eficiência da colheita. Métodos inovadores, como inteligência artificial e métodos de aprendizado de máquina e profundo, mostram grande potencial para automatizar e otimizar o monitoramento de perdas em tempo real. Além disso, personalizar as práticas de colheita e adaptar as configurações da máquina a diferentes campos e condições climáticas surgem como abordagens que podem reduzir significativamente as perdas e aumentar a produtividade.

Espera-se que este trabalho não apenas contribua para o avanço do conhecimento científico na área de colheita mecanizada de amendoim, mas também forneça um caminho concreto para a adoção de práticas agrícolas mais sustentáveis. A padronização dos métodos de quantificação e a incorporação de tecnologias emergentes devem permitir uma redução significativa nas perdas, promovendo uma produção

agrícola mais eficiente e ambientalmente responsável. O sucesso dessas iniciativas dependerá da colaboração contínua entre cientistas, formuladores de políticas e produtores, garantindo que as inovações sejam aplicadas efetivamente no campo e beneficiando tanto os agricultores quanto o meio ambiente.

9. Referências

Beam JB, Jordan DL, York AC, Isleib TG, Bailey JE, McKemie TE, Spears JF, Johnson PD (2002) Influence of prohexadione calcium on pod yield and pod loss of peanut. **Agronomy Journal** 94(2): 331-6. <https://doi.org/10.2134/agronj2002.3310>

Bertonha RS, Silva RP, Furlani CE, Nascimento JM, Cavichioli FA (2014) Perdas e teor de água das vagens no arranquio mecanizado de amendoim. **Energia na Agricultura** 29(3): 167-73.

Brito Filho AL, Carneiro FM, Souza JBC, Almeida SLH, Lena BP, Silva RP (2023) Does the Soil Tillage Affect the Quality of the Peanut Picker? **Agronomy** 13(4): 1024-16. <https://doi.org/10.3390/agronomy13041024>

Cavichioli FA, Zerbato C, Bertonha RS, da Silva RP (2014) Perdas quantitativas de amendoim nos períodos do dia em sistemas mecanizados de colheita. **Científica** 42(3): 211-5. <https://doi.org/10.15361/1984-5529.2014v42n3p211-215>

Colvin BC, Tseng YC, Tillman BL, Rowland DL, Erickson JE, Culbreath AK, Ferrell JA (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>

Dawelbeit MI (1991) Comparison of four peanut harvesting systems in irrigated clays of Sudan. **Applied Engineering in Agriculture** 7(1): 10-13. <https://doi.org/10.13031/2013.26205>

Dos Reis MA, Corrêa LN, Dos Santos AF, da Silva RP (2022) Peanut harvest quality: Relationship between soil tillage management and threshing systems. **Spanish Journal of Agricultural Research** 20(3): e0206. <https://doi.org/10.5424/sjar/2022203-18704>

Dos Santos AF, da Silva RP, Zerbato C, de Menezes PC, Kazama EH, Paixão CS, Voltarelli MA (2019) Use of real-time extend GNSS for planting and inverting peanuts. **Precision Agriculture** 20: 840-56. <https://doi.org/10.1007/s11119-018-9616-z>

Dos Santos AF, de Oliveira LP, de Oliveira BR, Ormond AT, da Silva RP (2021) Can Digger Blades Wear Affect the Quality of Peanut Digging? **Revista Engenharia na Agricultura-REVENG** 29:49-57. <https://doi.org/10.13083/reveng.v29i1.10444>

Jackson JL, Beasley Júnior JP, Tubbs RS, Lee RD, Grey TL (2011) Fall-Bedding for Reduced Digging Losses and Improved Yield in StripTill Peanut. **Peanut Science** 38, 31–40. <https://doi.org/10.3390/agronomy13041024>

Lamb MC, Masters MH, Rowland D, Sorensen RB, Zhu H, Blankenship RD, Butts CL (2004) Impact of sprinkler irrigation amount and rotation on peanut yield. **Peanut Science** 31(2):108-13. <https://doi.org/10.3146/pnut.31.2.0009>

Ormond AT, Dos Santos AF, Alcantara AS, Zerbato C, Furlani CE (2018) Tillage interference in the quality of peanut mechanized harvest. **Engenharia Agrícola** 38(2): 251-9. <http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v38n2p251-259/2018>

Santos EP, Silva RP, Bertonha RS, Noronha RH, Zerbato C (2013) Produtividade e perdas de amendoim em cinco diferentes datas de arranquio. **Revista Ciência Agronômica** 44: 695-702. <https://doi.org/10.1590/S1806-66902013000400005>

Santos AF, Kazama EH, Ormond AT, Tavares TO, Silva RP (2016) Quality of mechanized peanut digging in function of the auto guidance. **African Journal of Agricultural Research** 11(48): 4894-901. <https://doi.org/10.5897/AJAR2016.11442>

Santos AF, Alcântara AS, Corrêa LN, Queiroz RF, Silva RP (2021) Does moisture in pods interfere with mechanized harvesting of peanuts? **Engenharia Agrícola** 41: 98-106. <https://doi.org/10.1590/1809-4430-Eng.Agric.v41n1p98-106/2021>

Sorensen RB, Lamb MC, Butts CL (2015) Can peg strength be used as a predictor for pod maturity and peanut yield? **Peanut Science** 42(2): 92–99. <https://doi.org/10.3146/0095-3679-42.2.92>

Sorensen RB, Nuti RC, Holbrook CC, Chen CY (2017) Peanut peg strength and associated pod yield and loss by cultivar. **Peanut Science** 44(2): 77-82. <https://doi.org/10.3146/PS17-1.1>

Truman CC, Potter TL, Nuti RC (2012) Quantifying variable rainfall intensity events on seasonal runoff and sediment losses from strip and conventionally tilled peanuts. **Peanut Science** 39(1): 62–68. <https://doi.org/10.3146/PS11-15.1>

Zerbato C, Silva VF, Torres LS, Silva RP, Furlani CE (2014) Peanut mechanized digging regarding to plant population and soil water level. **Revista Brasileira de Engenharia Agrícola e Ambiental** 18(4): 459-65. <https://doi.org/10.1590/S1415-43662014000400015>

Zerbato C, Furlani CE, Silva RP, Voltarelli MA, Santos AF (2017) Statistical control of processes applied for peanut mechanical digging in soil textural classes. **Engenharia Agrícola** 37(2): 315-322. <https://doi.org/10.1590/1809-4430-Eng.Agric.v37n2p315-322/2017>

Zerbato C, Furlani CE, Oliveira MF, Voltarelli MA, Tavares TD, Carneiro FM (2019) Quality of mechanical peanut sowing and digging using autopilot. **Revista Brasileira de Engenharia Agrícola e Ambiental** 23(8): 630-637. <https://doi.org/10.1590/1807-1929/agriambi.v23n8p630-637>

CAPÍTULO 3 – Otimização da estimativa de perdas na colheita mecanizada de amendoim por meio da contagem de vagens

RESUMO – As perdas são importantes indicadores da eficiência da operação de colheita. A estimativa de perdas na colheita mecanizada de amendoim é essencial para otimizar a produtividade e reduzir o desperdício. Entretanto, métodos convencionais de quantificação, especialmente das perdas invisíveis, são demorados e demandam alta mão de obra, limitando sua viabilidade em larga escala. Diante disso, este estudo propõe uma abordagem inovadora baseada na contagem de vagens para estimar perdas visíveis e invisíveis de forma ágil e eficiente. Adicionalmente, buscamos compreender a relação entre esses dois tipos de perdas, avaliando a possibilidade de estimar perdas invisíveis a partir das visíveis. Para alcançar os objetivos proposto neste estudo, os dados de perdas foram coletados em nove áreas comerciais de cultivo no estado de São Paulo, Brasil, onde as perdas foram avaliadas sob diferentes condições de solo. A análise de dados incluiu a aplicação de análise de correlação e modelos de regressão entre perdas visíveis, invisíveis e contagem de vagens. Os resultados indicaram que a contagem de vagens, especialmente as de dois grãos, é um indicador confiável para ambas as perdas, apresentando coeficientes de determinação elevados ($R^2 > 0,75$). Quanto à estimativa das perdas invisíveis com base nas visíveis, os modelos demonstraram boa acurácia e alinhamento com as condições observadas em campo, representando uma solução prática para mitigar as dificuldades da quantificação manual. Por fim, uma plataforma digital foi desenvolvida para simplificar a aplicação dos modelos em campo, permitindo que produtores realizem estimativas rápidas e precisas diretamente no local de colheita. Este estudo oferece uma contribuição significativa para a eficiência operacional da colheita mecanizada de amendoim, apresentando uma solução prática e sustentável para o gerenciamento de perdas.

Palavras-chaves: *Arachis hypogaea* L., Colheita mecanizada, Streamlit, Perdas de amendoim

1. Introdução

O amendoim é uma das oleaginosas mais cultivadas no mundo e representa uma importante fonte de proteínas tanto para consumo humano quanto para alimentação animal (Bonku and Yu 2020). Assim, atingir altos rendimentos de colheita nessa cultura é um critério comum e objetivo final na maioria dos produtores. No entanto, a colheita de amendoim é desafiadora e apresenta altos índices de perdas (Zerbato et al. 2017; Santos et al. 2021; Santos et al. 2019). Portanto, a quantificação dessas perdas é importante

para que os agricultores adotem estratégias adequadas de manejo, melhorando a tomada de decisões. Além disso, reduzindo as perdas não apenas eleva a qualidade da colheita, mas também contribui para ganhos socioeconômicos, ao mesmo tempo em que atende aos Objetivos de Desenvolvimento Sustentável (ODS), em destaque o ODS#12, que incentiva padrões de produção e consumo mais sustentáveis.

Na literatura algumas pesquisas têm utilizado as perdas como um indicador de eficiência da colheita mecanizada de amendoim, avaliando a influência de fatores intrínsecos ao processo (Santos et al. 2021; Brito Filho et al. 2023; Ormond et al. 2018; Zerbato et al. 2017; 2014). Entre esses fatores, as características físicas e texturais do solo, desempenham um papel fundamental na variabilidade das perdas existentes na colheita de amendoim (Zerbato et al. 2017). O amendoim é uma cultura de natureza hipógea, cujos frutos se desenvolvem abaixo da superfície do solo. Assim, o tipo de solo, pode facilitar ou dificultar a recuperação dos frutos no momento da colheita, impactando diretamente os índices de perdas e a qualidade final da colheita.

Na colheita mecanizada do amendoim, destacam-se dois tipos principais de perdas: as visíveis, compostas por vagens e grãos deixados na superfície do solo após a operação, e perdas invisíveis, que permanecem retidas abaixo da superfície do solo. Monitorar esses dois tipos de perdas é essencial para otimizar o uso de recursos e assegurar a sustentabilidade econômica do sistema de produção. No entanto, os métodos tradicionais usados para quantificar essas perdas, especialmente as invisíveis, são lentos, exaustivos e altamente dependentes de mão de obra, limitando a obtenção de dados precisos em tempo hábil para a tomada de decisões no campo.

O método tradicional para estimá-las, envolve a coleta de amostras em uma estrutura retangular com área de 2 m², proporcional à largura de trabalho do arrancador ou recolhedor (Mesquita et al. 1998). Esse método, no entanto, apresenta limitações práticas em campo. O trabalhador responsável precisa procurar e coletar manualmente as vagens remanescentes no solo, isso quando se avalia as perdas visíveis. Para as perdas invisíveis, é necessária a arranquio do solo a uma profundidade de 15 a 20 cm para a coleta das vagens retidas abaixo da superfície do solo. Após a coleta, as amostras passam por um processo de limpeza, pesagem e correção de umidade, permitindo uma estimativa precisa das perdas. Portanto, essas limitações afetam a capacidade dos

produtores de tomar decisões em tempo real, comprometendo a eficiência operacional e o manejo adequado das perdas. Assim, têm-se a necessidade de aprimorar a estimativa de perdas na cultura do amendoim, especialmente no que diz respeito à quantificação das perdas invisíveis.

As estimativas manuais de perdas de amendoim são exaustivas, demoradas e suscetíveis a erros, especialmente após longos períodos de trabalho. Nesse contexto, assim como as perdas, a produtividade de grãos é geralmente determinada apenas após a colheita usando métodos intensivos de mão de obra (Stewart-Brown et al. 2019). Assim para facilitar nessas mensurações técnicas envolvendo as estimativas de rendimento por meio de seus componentes vem se tornando mais popular em culturas cujo componente de produtividade é o produto a ser comercializado (Reza et al. 2019; Wei and Molin 2020; Tedesco-Oliveira et al. 2020)

A cultura da soja oferece um exemplo relevante dessa prática, onde a contagem de vagens tem se mostrado um indicador confiável para prever a produtividade (Wei and Molin 2020). Através dessa abordagem, avanços tecnológicos, com o uso de visão computacional, têm apresentado grandes progressos na quantificação automática desses componentes em campo, permitindo estimativas mais rápidas e precisas (Riera et al. 2020; Uzal et al. 2018; Zhao et al. 2023). Esses avanços também impulsionaram a fenotipagem de alto rendimento, uma área que busca obter dados precisos sobre os componentes produtivos das plantas e, assim, melhorar as práticas de manejo e o desenvolvimento de cultivares mais eficientes. (Zhao et al. 2023; Uzal et al. 2018). Dessa forma a contagem de vagens sugere uma solução promissora para agilizar as estimativas de perdas na cultura do amendoim, cujo produto são as vagens.

Diante dessa perspectiva, formulamos as seguintes hipóteses para esta pesquisa: (1) As perdas na colheita de amendoim podem ser estimadas com precisão por meio da contagem do número de vagens; (2) Existe uma relação entre as perdas visíveis, que podem ser quantificadas mais facilmente, e as perdas invisíveis, mais difíceis e demoradas de quantificar. Com base nessa relação, acreditamos ser possível estimar as perdas invisíveis a partir das perdas visíveis, permitindo uma estimativa mais rápida e prática. Portanto, o desenvolvimento de modelos baseados nessas relações possibilitará aos produtores uma ferramenta prática para estimar rapidamente as perdas existentes

na colheita de amendoim, incluindo as perdas abaixo da superfície do solo, otimizando a tomada de decisões de forma mais assertivas.

O objetivo desse estudo foi desenvolver um método rápido e eficiente para a estimativa das perdas no arranquio mecanizado do amendoim, que possibilite ao produtor tomar decisões imediatas no campo. Os objetivos específicos foram: I - Explorar a relação entre as perdas visíveis, invisíveis e o número de vagens; II - Gerar um modelo para estimar as perdas de amendoim por meio da contagem de vagens; III - Criar um modelo para estimar as perdas invisíveis a partir das perdas visíveis; IV - Avaliar o efeito da classe de solo nos modelos de estimativa de perdas; V – Desenvolver um ambiente de fácil interação e aplicação dos modelos gerados.

2. Material e Métodos

Nesta seção, apresentamos informações sobre as áreas de estudo (Seção 2.1), o método de estimativa de perdas no arranquio (Seção 2.2), organização dos dados de perdas (Seção 2.3), análise estatística explorada no desenvolvimento dos modelos gerados (Seção 2.4), avaliação da performance dos modelos desenvolvidos (Seção 2.5), e implementação prática das abordagens desenvolvidas (Seção 2.6).

2.1 Descrição das áreas de estudo

Os dados de perdas foram coletados em doze áreas comerciais de cultivo de amendoim no estado de São Paulo, Brasil, ao longo de quatro safras consecutivas (Tabela 1). As áreas analisadas estão localizadas na região norte do estado de São Paulo, próximas ao município de Jaboticabal, uma das principais regiões produtoras de amendoim do estado. O clima da região é classificado como Aw (tropical com estação seca) de acordo com Köppen-Geiger (1948).

Os solos das doze áreas de estudo são classificados como Argissolos Vermelho-Amarelos (PVA) e Latossolos Vermelhos (LV), conforme o “Mapa Pedológico do Estado de São Paulo: revisado e ampliado” (Rossi, 2017). Assim, considerando o

desenvolvimento de modelos de perdas para cada classe de solo, as primeiras nove áreas foram divididas e cultivadas exclusivamente com a cultivar IAC OL3.

Tabela 1. Informações gerais sobre as doze áreas comerciais explorados no desenvolvimento desta pesquisa.

Área	Lat	Long	Safr	NP	Solo	Textura (%)			P (kg ha ⁻¹)
						Ar	S	Arg	
Área 1	-21,4145	-48,4246	2020/2021	80	PVA	63	3	34	6891
Área 2	-21,3312	-48,4890	2020/2021	80	PVA	74	7	18	7434
Área 3	-21,1071	-48,4093	2020/2021	20	LV	*	*	*	5717
Área 4	-21,2513	-48,4153	2020/2021	20	PVA	*	*	*	7294
Área 5	-21,1344	-48,3816	2021/2022	50	LV	*	*	*	7250
Área 6	-21,5024	-48,4739	2021/2022	50	PVA	66	7	27	8011
Área 7	-21,1622	-48,3885	2022/2023	20	PVA	71	5	24	4364
Área 8	-21,2026	-48,0094	2022/2023	80	LV	19	29	52	8519
Área 9	-21,2531	-48,3821	2023/2024	30	LV	29	2	69	6040
Área 10	-21,2531	-48,3821	2023/2024	30	LV	29	2	69	3625
Área 11	-21,2531	-48,3821	2023/2024	30	LV	29	2	69	3936
Área 12	-21,1988	-48,2603	2023/2024	30	LV	*	*	*	3285

Lat – Latitude; Long – Longitude; NP – Número de pontos de perdas coletados em cada área; Ar – Areia; S – Silte; Arg – Argila; P – Produtividade;

* Não foi realizado a análise de textura de solos.

Por outro lado, as áreas 10, 11 e 12 foram utilizadas na etapa de generalização e foram cultivadas com outras variedades de amendoim (IAC 503, Granoleico e IAC 677). Essas áreas adicionais permitiram testar a performance dos modelos desenvolvidos em diferentes cultivares, avaliando sua aplicabilidade em condições variadas.

A IAC OL3 foi selecionada nesse estudo pois é uma das principais cultivares produzidas no estado de São Paulo. Ela é renomada por seu ciclo de crescimento curto de cerca de 125 a 130 dias e pela boa qualidade de seus grãos. Esta cultivar é especialmente notável por sua alta concentração de ácido oleico no óleo, que constitui aproximadamente 70 a 80% de sua composição.

2.2. Estimativa de perdas no arranquio

A estimativas de perdas visíveis e invisíveis foram realizadas nas doze áreas de estudos. Na estimativa das perdas no arranquio, utilizou-se uma armação com área amostral de 2 m² (1,11 x 1,80 m). Essa medida foi definida para alcançar a largura de trabalho do arrancador-invertedor. A armação foi posicionada sobre duas fileiras de cultivo, permitindo a coleta das perdas visíveis e invisíveis, sendo que:

Perdas visíveis no arranquio (PV): foi realizada após o arranquio, sendo a leira levantada cuidadosamente, e neste local, foi posicionada a armação, sendo então recolhidas todas as vagens e grãos soltos que estavam sobre o solo, no interior na armação.

Perdas invisíveis no arranquio (PIA): com armação posicionada no mesmo local onde coletou-se as perdas visíveis, cavou-se o solo com uma enxada, a uma profundidade estimada entre 15 à 20 cm. Em seguida, coletou-se as vagens encontradas a partir dessa mobilização.

No momento da coleta, as amostras de PV e PIA foram colocadas em sacos plásticos com a numeração exata do ponto em questão. As amostras foram encaminhadas para laboratório onde foram limpas, pesadas em uma balança eletrônica com precisão de 0,01 g, e posteriormente colocadas em estufa a 65 °C por 24 horas, pesadas e recolocadas para secar, repetindo esse processo até a vagens atingirem a massa seca constante. Posteriormente, foi realizado a correção do teor de água das vagens para 8%. Após a correção da massa das amostras foi realizado o cálculo de estimativa das perdas.

2.3. Organização do conjunto de dados

Para responder às duas hipóteses propostas neste estudo, o conjunto de dados e as análises foram organizadas de forma específica para cada uma. Para tanto, o estudo foi estruturado em duas abordagens experimentais, cada um focado em testar uma hipótese.

2.3.1. Experimento 1

Para investigar a hipótese de que o número de vagens pode ser um indicador confiável das perdas na colheita de amendoim, foram utilizados os dados das áreas 5, 6, 8 e 9. Nessas áreas, além da estimativa geral das perdas visíveis e invisíveis, foi realizado uma etapa adicional de caracterização das perdas. Essa etapa consistiu na classificação das amostras que continham as vagens de amendoim perdidas em três categorias, baseadas no número de grãos por vagem: vagens de 1 grão (1g), 2 grãos (2g) e 3 grãos (3g), que são as mais comuns para a cultivar IAC OL3. Além disso, essas áreas foram escolhidas por apresentarem diferentes classes de solos (Argissolos Vermelho-Amarelos e Latossolos Vermelhos).

2.3.2. Experimento 2

O segundo experimento visou investigar a hipótese de que as perdas invisíveis podem ser estimadas a partir das perdas visíveis, considerando as duas diferentes classes de solo (Argissolos Vermelho-Amarelos e Latossolos Vermelhos). Para responder a essa hipótese, foram analisados os dados de perdas visíveis e invisíveis coletados nas áreas 1, 2, 3, 4, 5, 7, 8 e 9. Assim, as áreas foram agrupadas de acordo com a classe de solo, e, a partir dessa divisão, foi explorado a possibilidade de estabelecer uma relação que permita a estimativa de perdas invisíveis com base nas observações de perdas visíveis realizadas em campo.

2.4. Análise de dados

2.4.1. Transformação de dados

Dada a alta variabilidade nas perdas observadas nas áreas de colheita mecanizada, foram realizadas etapas específicas de transformação e análise dos dados para garantir a qualidade e a confiabilidade dos modelos estatísticos. Assim, antes das

análises de correlação e modelagem, foi aplicada uma transformação logarítmica aos indicadores PV e PIA.

Assim, foi calculado o logaritmo natural desses indicadores para mitigar assimetrias nos dados e promover uma distribuição mais simétrica e próxima da normalidade. Essa transformação foi fundamental para reduzir a influência de valores extremos, facilitando a validação de pressupostos de normalidade essenciais para as análises estatísticas subsequentes. O uso de dados transformados foi aplicado tanto na análise de correlação quanto na modelagem de regressão entre PV e PIA, assegurando que a interpretação dos modelos fosse estatisticamente robusta e menos afetada por dados assimétricos.

No entanto, para a análise de interação entre os tipos de perdas e o número de vagens, optou-se por utilizar os dados sem transformação. Essa decisão deve-se ao fato de que, para esse tipo específico de análise, a transformação logarítmica poderia distorcer as relações práticas e diretas entre os tipos de perdas e as quantidades reais de vagens. Assim, a análise de interação reflete a variação e a quantidade exata de vagens observadas em campo, enquanto as transformações logarítmicas serviram para aprimorar a robustez das correlações e modelos de predição entre PV e PIA.

2.4.2. Análise de Correlação

Após a transformação dos dados de PV e PIA, foi aplicada a análise de correlação de Spearman ($p < 0,05$), utilizando a plataforma Jupyter com linguagem Python. A correlação foi calculada para PV, PIA e o número de vagens nas diferentes classificações (1, 2, 3 grãos e total), tanto para os solos de classe Argissolos Vermelho-Amarelos quanto para os Latossolos Vermelhos. Seguindo Taylor (1990), os valores de correlação foram interpretados como: baixa ($< 0,36$), moderada (0,36 a 0,67) e alta (0,68 a 1,0).

2.4.3. Remoção de outliers

Identificando correlação entre as variáveis PV e PIA, foi aplicado a etapa de remoção de outliers multivariados. Essa abordagem ajudar a garantir que os modelos

gerados sejam robustos e representativos dos dados reais. Assim, foi utilizado o método Fator Local de *Outliers* (LOF), uma técnica baseada na densidade local, que compara a densidade de um ponto com a densidade dos pontos em sua vizinhança imediata. Assim, pontos com densidade significativamente menor do que a de seus pontos próximos são classificados como pontos não pertencentes aquele banco de dados.

O conjunto de dados foi gerado a partir de nove áreas distintas. Logo, considerou-se observar alta variabilidade e padrões de agrupamento nesses dados. Dessa forma, o uso do LOF mostrou-se apropriado, pois ele considera as variações de densidade local em vez de apenas padrões globais. Isso possibilita a identificação de pontos inconsistentes em áreas onde a densidade dos dados varia, preservando a representatividade dos dados e minimizando a influência de valores extremos que poderiam comprometer a precisão das análises. Dessa forma, o método assegura que os modelos estatísticos se baseiem em padrões reais e consistentes.

2.4.4. Modelagem das perdas

Após a remoção desses pontos extremos, foram realizadas as modelagens das perdas utilizando regressão entre as variáveis PV, PIA e o número de vagens perdidas. As comparações realizadas foram as seguintes:

- PV x Número de Vagens Visíveis
- PIA x Número de Vagens Invisíveis
- PIA x PV

Para avaliar a performance dos modelos, os coeficientes de determinação (R^2) das equações obtidas foram analisados para avaliar as hipóteses de que o número de vagens pode ser um estimador eficaz para PV e PIA e de que PIA pode ser estimado a partir de PV. Modelos com valores de R^2 próximos de 1 foram considerados mais representativos para a predição, indicando maior precisão nas estimativas.

2.5. Generalização

Para avaliar a robustez e a aplicabilidade dos modelos desenvolvidos para a cultivar IAC OL3, esses modelos foram aplicados a diferentes cultivares de amendoim (IAC 503, Granoleico e IAC 677). A precisão e a acurácia dos modelos foram verificados por meio do R^2 e do Erro Médio Absoluto (MAE), permitindo uma análise detalhada do desempenho dos modelos em novos cenários e sua capacidade de adaptação a outras cultivares.

Além disso, a Tabela 2 apresenta os valores médios de caracterização das perdas para todas as cultivares testadas, incluindo a cultivar IAC OL3 utilizada no desenvolvimento dos modelos. Essa caracterização, permite visualizar as diferenças morfológicas entre as cultivares, proporcionando uma análise comparativa entre elas.

Tabela 2. Valores médios da caracterização das perdas de amendoim para as cultivares trabalhadas.

Cultivar	Nº de Vagens	Massa (g.2m ⁻²)	MMV (g)	Classe	Quant.	Dimensões (mm)	
						Comprimento	Largura
IAC OL3	21	43,68	2,08	1g	3	17,29	12,73
				2g	17	29,00	13,52
				3g	1	39,01	13,05
IAC 503	17	29,51	1,48	1g	3	18,33	12,50
				2g	13	30,23	14,21
				3g	1	37,85	14,36
Granoleico	16	32,32	2,02	1g	3	17,75	12,78
				2g	12	30,30	13,41
				3g	1	37,00	12,35
IAC 677	23	34,97	1,52	1g	3	16,47	11,67
				2g	19	28,21	13,73
				3g	1	38,23	13,02

MMV – Massa média por vagem; Quant – Quantidade de vagens em cada classe de vagens encontradas; Classes: 1g – Vagens de um grão; 2g – Vagens com dois grãos; e 3g – Vagens de três grãos.

2.6. Elaboração da Plataforma Web

O desenvolvimento da plataforma de estimativa de perdas na colheita de amendoim foi conduzido em linguagem de programação Python, utilizando a biblioteca Streamlit para criar uma interface de usuário interativa e acessível. Para o ambiente de desenvolvimento, escolheu-se o Visual Studio Code (VSCode) devido às suas funcionalidades robustas, como suporte para depuração, controle de versão e

ferramentas de formatação, que garantiram a padronização do código e a minimização de erros.

O aplicativo foi estruturado em módulos funcionais para otimizar a manutenção e facilitar futuras atualizações. Para manipulação de dados e criação de gráficos interativos, foram empregadas as bibliotecas pandas, matplotlib e plotly, otimizando a eficiência e a visualização dos resultados. O código está hospedado no GitHub para facilitar o controle de versão e a colaboração, enquanto a aplicação é acessível publicamente via Streamlit Cloud.

3. Resultados e Discussão

3.1. Correlação entre os diferentes tipos de perdas e quantidade de vagens em solos de diferente classe

A análise de correlação (Figura 1) revelou uma forte relação entre as perdas (visíveis e invisíveis) e o número total de vagens (VT) encontradas em campo, com coeficientes acima de 0,87, independente da classe de solo. Assim, visualizamos que a estimativa de perdas é diretamente influenciada por esse componente produtivo da cultura. Assim, o número total de vagens em campo representa um indicador confiável e robusto para estimar as perdas.

Nesse contexto, outro achado particularmente relevante foi a forte correlação das vagens de dois grãos (2g) com as perdas, com coeficientes acima de 0,85. Na Tabela 2, observamos que as vagens de dois grãos são as mais abundantes nas amostras de campo, representando mais de 70% das vagens encontradas nas amostras de perdas. Logo, essa predominância confere às vagens de dois grãos um papel central na estimativa das perdas. Assim, a forte correlação observada sugere que a contagem isolada dessas vagens pode ser suficiente para estimar tanto as perdas visíveis quanto as invisíveis, simplificando as etapas de monitoramento e reduzindo o esforço necessário em campo.




Figura 1. Correlação de Spearman entre as perdas visíveis (PV) e invisíveis (PIA) e a quantidade de vagens, classificadas por número de grãos: 1, 2, 3 e totais. A abordagem geral representa a condição da união dos conjuntos de dados das duas classes de solo.

As vagens de um grão apresentaram correlações altas (0,72) com as perdas visíveis para ambas as classes de solos. Em relação as perdas invisíveis, as vagens de um grão apresentaram correlação alta para Argissolos Vermelhos-Amarelos (0,81) e moderada para Latossolos Vermelho (0,60). Esse resultado indica que, apesar de menos frequentes, elas podem contribuir para a estimativa das perdas visíveis e invisíveis. Por outro lado, as vagens de três grãos apresentaram correlações baixas com as perdas visíveis, com coeficientes variando entre 0,06 e 0,34. Quando analisadas em relação às perdas invisíveis, observou-se uma correlação baixa (0,18) na classe de solos Latossolos Vermelhos, mas correlação moderada (0,77) na classe de solos Argissolos Vermelhos-Amarelos. Esses resultados sugerem que, embora as vagens de três grãos possam ser mais difíceis de encontrar para a cultivar explorada nesse estudo (Tabela 2), sua contribuição para a estimativa das perdas invisíveis pode ser mais relevante para essa classe de solos.

Em relação às perdas visíveis e invisíveis, foi observada uma correlação moderada (0,63-0,64) para ambas as classes de solo. Essa correlação moderada pode ser atribuída à alta variabilidade dos valores de perdas existentes no processo de colheita mecanizada de amendoim (Santos et al., 2021; Ormond et al., 2018; Zerbato et al., 2017). A colheita mecanizada de amendoim é influenciada por uma combinação de fatores externos, como condições climáticas, ajustes e regulagens das máquinas, experiência do operador e características da cultura, incluindo fenologia, ciclo e hábitos de crescimento.

Além disso, ao considerarmos os dois tipos de perdas podemos supor que as perdas invisíveis são as que devem apresentar maiores dispersão em seus valores, por sofrerem maiores influências de fatores ambientais, como por exemplo, as condições que solos que podem variar desde o preparo desse solo (Brito Filho et al., 2023; Ormond et al., 2018) até sua estrutura física (Zerbato et al., 2017). Dessa forma, a alta variabilidade dos dois tipos de perdas influencia diretamente a relação entre as variáveis, apesar de ambas estarem fortemente relacionadas ao processo de colheita mecanizada.

3.2. Estimativas de perdas a partir da contagem do número de vagens

As Figuras S1, S2 e S3 (Material Suplementar) apresentam a modelagem das perdas visíveis e invisíveis no arranquio em função do número de vagens. A modelagem foi realizada considerando três cenários: A primeira considerando classes de solo Argissolos Vermelho-Amarelos, a segunda Latossolos Vermelhos e por fim a terceira uma abordagem geral a partir da união dos dados de ambas as classes de solos. Na Tabela 3, são apresentados os valores de coeficientes de determinação (R^2) para cada abordagem estabelecida.

As vagens de um e dois grãos, assim como a contagem total de vagens, apresentaram coeficientes de determinação elevados, superiores a 0,70, tanto em Argissolos Vermelho-Amarelos quanto Latossolos vermelhos. No entanto, as vagens de três grãos apresentaram coeficientes de determinação baixos para ambas as classes de solos. Dessa forma, essa categoria são as menos indicadas como indicador confiável para estimar as perdas de amendoim em campo.

Embora as vagens de um grão apresentarem bons coeficientes de determinação, sua baixa frequência no campo limita sua utilização como principal indicador de perdas, assim como ocorre com as vagens de três grãos. A representatividade reduzida dessas classes é evidente na Tabela 2, que mostra que vagens de um grão compõem cerca de 20% das amostras, enquanto as de três grãos representam apenas 5%. Essa baixa ocorrência dificulta o uso exclusivo dessas vagens para estimar as perdas de maneira confiável. Isso indica que, embora possam ser úteis em situações específicas, não são

ideais como base única para o monitoramento de perdas, pois sua ausência em algumas amostras comprometeria a precisão das estimativas.

Tabela 3. Coeficiente de determinação das equações de modelagem para estimativa de perdas de amendoim em solos arenosos e argilosos, com base no número de vagens.

Condição	Nº de vagens	PV	PIA	PV+PIA
		R ²		
Argissolos Vermelho-Amarelos	1 grão	0,77	0,77	0,77
	2 grãos	0,97	0,97	0,97
	3 grãos	0,08	0,59	0,50
	NV	0,98	0,49	0,98
Latosolos Vermelhos	1 grão	0,76	0,77	0,77
	2 grãos	0,92	0,90	0,91
	3 grãos	0,06	0,06	0,04
	NV	0,93	0,93	0,93
Geral	1 grão	0,75	0,76	0,75
	2 grãos	0,92	0,94	0,94
	3 grãos	0,05	0,39	0,29
	NV	0,93	0,96	0,95

PV – Perdas visíveis no arranquio; PIA – Perdas invisíveis no arranquio; PV+PIA – União dos dados de perdas visíveis e invisíveis; NV - número total de vagens.

Portanto, os resultados obtidos confirmam as análises de correlação anteriores, demonstrando que a contagem do número totais de vagens e somente a contagem das vagens de dois grãos são variáveis eficazes para estimar perdas na colheita mecanizada de amendoim. Além disso, os modelos desenvolvidos demonstraram consistência independentemente da classe de solo analisada. Modelos específicos foram estabelecidos para Argissolos Vermelho-Amarelos e Latossolos Vermelhos, ambos apresentando bom desempenho.

Da mesma forma, quando os dados das duas classes foram agrupados, a abordagem geral também resultou em um modelo robusto, com alto coeficiente de determinação. Esse achado sugere que, apesar das características específicas de cada classe de solo, essas variações não impactaram significativamente a relação entre o número de vagens e as perdas. Assim, a equação geral, desenvolvida a partir da combinação dos dados de ambas as classes de solo, foi capaz de capturar o comportamento das perdas de maneira precisa, evidenciando a robustez das correlações

observadas. Essa consistência amplia a aplicabilidade prática desse método em condições reais de campo, indicando que a abordagem pode ser adaptada para estimativas de perdas em outras condições de solo.

As vagens são a fração produtiva da planta, pois contêm os grãos que possuem valor econômico para a cultura. Nesse contexto, as vagens encontradas no campo representam o volume real de produção do amendoim, sendo a quantidade de vagens diretamente proporcional ao rendimento que pode ser obtido. Vagens deixadas no campo após a colheita refletem perdas significativas de produtividade. Portanto, a contagem de vagens não é apenas um indicador eficiente para estimar as perdas, mas também auxilia na avaliação da produtividade final da lavoura. Isso reforça sua importância como uma ferramenta essencial de monitoramento e gestão agrícola.

Um exemplo claro dessa prática é encontrado na cultura da soja, onde a produtividade é determinada por três fatores principais: o número de vagens por planta, o número de sementes por vagem e o tamanho das sementes (Uzal et al. 2018). Nesse sistema, a contagem de sementes tem uma relação direta com a produtividade, já que as sementes são a parte de interesse econômico (Wei and Molin 2020). No entanto, a contagem de vagens tem se mostrado uma alternativa mais prática e viável, pois a contagem de sementes é mais trabalhosa, demorada, dispendiosa e propensa a erros. As vagens, por serem maiores e mais fáceis de contabilizar, tornam-se um parâmetro eficiente para prever a produtividade da soja (Zhao et al. 2023).

Com base nessa perspectiva, a contagem de vagens se consolida como uma ferramenta essencial para estimar tanto a produtividade quanto as perdas na colheita. Pesquisas recentes focadas em fenotipagem de alto rendimento têm demonstrado um crescente interesse na obtenção de dados precisos sobre esse componente produtivo das plantas (Wei and Molin 2020; Uzal et al. 2018). Avanços tecnológicos, como o uso de visão computacional, têm mostrado grandes progressos na quantificação automática desses componentes em campo (Zhao et al. 2023; Riera et al. 2020; Uzal et al. 2018). Esse tipo de abordagem tecnológica pode ser facilmente adaptado para a quantificação de vagens de amendoim, permitindo uma identificação mais eficiente das perdas no campo.

O modelo proposto neste estudo, que utiliza a contagem de vagens para estimar as perdas na colheita de amendoim, demonstra grande potencial para apoiar o gerenciamento de propriedades agrícolas. A estimativa de perdas é um fator crucial na tomada de decisões que envolvem o manejo de operações mecanizadas e a mitigação de desperdícios. A aplicação de técnicas de aprendizado profundo para automatizar a quantificação das perdas em campo pode abrir novas perspectivas para o desenvolvimento de ferramentas inovadoras no manejo da colheita de amendoim, permitindo uma quantificação rápida e precisa das perdas e, consequentemente, a otimização do processo de colheita.

3.3. Estimativa de perdas invisíveis por meio das perdas visíveis

Após identificar uma correlação moderada na análise preliminar, procedemos com a modelagem das perdas invisíveis em função das perdas visíveis. O banco de dados foi construído a partir de oito áreas, categorizadas de acordo com a classe de solo (Argissolos Vermelho-Amarelos e Latossolos Vermelhos). A relação e variabilidade entre as perdas visíveis e invisíveis sob diferentes condições de solo estão representadas na Figura 2.

A análise de regressão linear revelou relações moderadas entre essas duas variáveis para ambas as classes de solos, com os valores de R^2 variando entre 0,44 e 0,48 (Figuras 2A e 2B). Além disso, a combinação dos dados dos dois tipos de solo resultou em uma correlação semelhante ($R^2 = 0,48$) (Figura 2C). Assim, nossos resultados indicam que, nas condições avaliadas, as perdas visíveis explicam aproximadamente 48% da variação nas perdas invisíveis.




Figure 2. Análise de regressão linear e diagrama de caixas entre as perdas visíveis e invisíveis sob diferentes classes de solo. A – Modelo para Argissolos Vermelho-Amarelo; B – Modelo para Latossolos Vermelhos; C – Modelo geral; D – Variabilidade das perdas em cada área trabalhada.

Para entender a relação entre os dois tipos de perdas (visíveis e invisíveis) nas diferentes áreas estudadas, analisou-se o comportamento dessas perdas individualmente em cada área (Figura 2D). Foi observado que as perdas apresentaram alta variabilidade em todas as áreas, independentemente da classe de solo. No entanto, nas áreas classificadas como Latossolos Vermelhos, predominantemente argilosas (Tabela 1), as perdas invisíveis exibiram maior dispersão em relação às perdas visíveis. Essa dispersão foi evidenciada pela maior amplitude dos diagramas de caixas e pelo número elevado de *outliers*, indicando uma variação mais acentuada entre as amostras coletadas.

Essa alta variabilidade das perdas invisíveis em solos argilosos pode ser explicada pelas características físicas desses solos. Latossolos possuem maior profundidade, estrutura mais homogênea e uma maior proporção de argila, o que confere maior coesão entre as partículas do solo. Essa estrutura mais compacta dificulta a penetração e movimentação do ginóforo durante o arranquio, aumentando as chances de vagens se desprenderem e permanecerem enterradas, resultando em maiores perdas invisíveis. Em contraste, os Argissolos, que apresentam textura mais arenosa ou média, possuem

menor coesão entre as partículas, facilitando o rompimento do solo ao redor do sistema radicular e reduzindo as perdas invisíveis.

Portanto, a alta variabilidade observada nas perdas da colheita de amendoim impediu o estabelecimento de uma correlação mais forte entre os dois tipos de perdas (Visíveis com invisíveis). Ainda assim, ao considerar apenas as classes de solo e suas texturas predominantes, foi possível explicar cerca de 48% da variação nas perdas invisíveis com base nas perdas visíveis. Isso demonstra que a textura do solo é um fator relevante para compreender as perdas, mas não o único. A inclusão de outros fatores no modelo, como as condições de manejo e as características da colheita, pode melhorar sua capacidade de explicar as variações nas perdas invisíveis, tornando-o mais robusto e abrangente.

A colheita mecanizada de amendoim é influenciada por uma interação complexa de fatores ambientais e operacionais. Um exemplo relevante é o teor de água do solo, que está diretamente relacionado às características texturais de cada classe de solo. Solos argilosos são compostos por partículas menores e mais compactas, assim têm uma maior capacidade de reter água. Em contraste, solos arenosos, compostos por partículas maiores e mais espaçadas, retêm menos umidade. Como as vagens de amendoim se desenvolvem abaixo da superfície do solo, essas variações na retenção de água influenciam diretamente a eficiência da colheita mecanizada. Solos com menor teor de água resultam em maiores valores de perdas, comprometendo o desempenho da colheita (Zerbato et al. 2014). Logo, conforme o teor de água do solo diminui, a resistência do ginóforo à ruptura também diminui, o que leva o aumento nas perdas durante a colheita (Ince and Guzel 2003).

Nesse sentido, Zerbato et al. (2017) demonstraram que o teor de água das vagens segue o mesmo padrão do teor de água do solo; à medida que o teor de água do solo aumenta, o teor de água das vagens e dos ginóforos também aumenta. Esse aumento de umidade nos ginóforos, contribui para uma maior resistência à ruptura, o que pode reduzir as perdas invisíveis durante o arranquio. Desta maneira, a resistência do ginóforo à ruptura pode ser considerado um fator crítico na determinação das perdas durante o arranquio, estando diretamente relacionada à estrutura do solo e ao seu teor de água no momento da operação (Ince and Guzel 2003).

Portanto, nossos resultados indicam que uma abordagem local para a modelagem das perdas pode não ser eficaz, uma vez que a variabilidade de fatores ambientais e operacionais nas áreas individuais dificulta a precisão da estimativa. Nesse contexto, o modelo geral desenvolvido, reduziu a influência dos fatores específicos de cada local, permitindo que o modelo capturasse tendências mais gerais e representativas das condições de campo. Assim, ao invés de ajustar-se às particularidades locais, o modelo generalizado mostrou-se mais robusto, considerando uma maior variabilidade e gerando uma estimativa mais precisa.

3.4. Avaliação do desempenho da generalização dos modelos criados

Para avaliar a performance dos modelos desenvolvidos, foi criado um cenário de teste utilizando um conjunto de dados totalmente diferente do que foi utilizado nas etapas de modelagem para estimativa de perdas visíveis e invisíveis pela contagem de vagens e estimativa das perdas invisíveis pelas visíveis. Nesta nova etapa, foram avaliados três diferentes cultivares de amendoim. A fim de compreender o comportamento das perdas em cada cultivar. Na Tabela 4 é apresentada a análise descritiva das perdas observadas, fornecendo uma visão detalhada sobre as características de dispersão e variabilidade entre as cultivares avaliadas. Nela observamos, que existe alta variabilidade nos dados de perdas (visíveis e invisíveis) nos quais, todas as três cultivares apresentaram os valores de coeficiente de variação (CV) superiores a 35%. Com isso temos a existência de valores mais dispersos em relação ao valor central de medida (média). Destaca-se ainda, que os CVs dos dados de perdas invisíveis foram superiores aos das perdas visíveis.

Tabela 4. Análise descritiva dos valores de perdas encontrados em campo para as cultivares de amendoim Granoleico, IAC 503 e IAC 677.

Medição	Granoleico		IAC 503		IAC 677	
	PVA	PIA	PVA	PIA	PVA	PIA
	(kg ha ⁻¹)					
N	28	28	29	29	27	27
Mínimo	25,05	36,47	43,64	23,23	49,24	62,28
Mediana	91,98	123,32	124,02	105,83	151,90	125,54
Média	104,94	123,44	119,58	110,28	156,51	128,83

Máximo	218,91	357,72	225,16	254,07	295,92	367,88
DP	47,66	67,79	42,73	57,94	59,49	60,99
Variância	2271,35	4595,83	1826,16	3357,29	3539,68	3719,87
CV (%)	45,42	54,92	35,74	52,54	38,01	47,34

N – Número de observação; DP – Desvio padrão; CV – Coeficiente de variação.

Para estimar as perdas visíveis e invisíveis, utilizamos as duas melhores abordagens identificadas na etapa de modelagem: a primeira baseada na contagem total de vagens e a segunda na contagem das vagens de dois grãos. Dentro de cada cenário os modelos gerais foram escolhidos. Esses modelos gerais foram desenvolvidos a partir de todo o conjunto de dados, incluindo tanto as perdas visíveis quanto as invisíveis, e consideram as duas condições de solo avaliadas no estudo. Assim, as equações 1 e 2 foram usadas para realizar as estimativas de perdas:

$$\text{Perdas (kg ha}^{-1}\text{)} = 8,047 \text{ NTV} \quad (1)$$

$$\text{Perdas (kg ha}^{-1}\text{)} = 10,16 \text{ NVD} \quad (2)$$

Em que:

NTV – Número total de vagens de amendoim.

NVD – Número total de vagens contendo dois grãos de amendoim.

Em seguida, para alcançar os valores das perdas invisíveis por meio das visíveis utilizamos a equação geral desenvolvida a partir da combinação dos valores de perdas para os dois tipos de classe de solo explorados nesse estudo, conforme apresentada pela equação 3.

$$\text{PIA} = 10^{0,8269 \log_{10} \text{PVA} + 0,438} \quad (3)$$

Em que:

PIA – Perdas invisíveis estimada no arranquio de amendoim (kg ha⁻¹).

PVA – Perdas visíveis encontradas em campo (kg ha⁻¹).

Os modelos desenvolvidos para estimar as perdas por meio da contagem de vagens podem ser usados tanto para as estimativas das perdas visíveis quanto as invisíveis, independentemente da classe de solo. Na Figura 3, observamos que o desempenho dos modelos desenvolvidos para estimar as perdas apresentam valores significativos de R^2 , variando entre 0,76 e 0,92 para as três cultivares avaliadas (Granoleico, IAC 503 e IAC 677). Além disso, ao comparar os valores de MAE (métrica de erro), entre as estimativas baseadas na contagem total de vagens e na contagem específica de vagens de dois grãos, notou-se uma variação modesta nos valores. Isso sugere que ambos os métodos de contagem fornecem estimativas confiáveis das perdas, com o modelo baseado na contagem total de vagens apresentando um leve aumento na precisão em algumas situações.

Nossos resultados indicam que os modelos desenvolvidos são capazes de explicar com precisão a variabilidade das perdas em relação aos dados observados, proporcionando estimativas confiáveis. Além disso, os valores de MAE estão consistentemente abaixo ou muito próximos do desvio padrão dos dados, sugerindo que os modelos operam com precisão dentro da variabilidade natural das perdas reais observadas no campo. Nesse sentido, a capacidade de generalização demonstrada por esses modelos é uma grande vantagem, pois eles podem ser empregados de forma eficaz, tendo a flexibilidade de se adaptar a diferentes cultivares de amendoim, sem comprometer a qualidade das estimativas.




Figura 3. Regressão linear entre as perdas observadas e estimadas para as cultivares de amendoim Granoleico, IAC 503 e IAC 677. As perdas estimadas foram baseadas no número total de vagens e na contagem de vagens de dois grãos. Os valores de perdas incluem tanto as perdas visíveis quanto as invisíveis.

Adicionalmente, a possibilidade de estimar as perdas somente com base na contagem das vagens de dois grãos se destaca como uma contribuição significativa para a eficiência do trabalho em campo. Esse método não só reduz a necessidade de contagens mais complexas, como também facilita o gerenciamento das perdas em nível de fazenda de maneira mais prática e simplificada. Assim, os produtores podem tomar decisões mais rápidas e assertivas, otimizando o manejo das colheitas e o controle de perdas ao longo da cadeia produtiva.

Na Figura 4, apresentamos o desempenho do modelo ao estimar as perdas invisíveis a partir dos dados observados das perdas visíveis para as três cultivares de amendoim: Granoleico, IAC 503 e IAC 677. Observamos que o valor de R^2 varia significativamente entre as cultivares, indicando uma relação fraca entre as perdas estimadas e observadas, especialmente para as variedades Granoleico ($R^2 = 0,06$) e IAC 677 ($R^2 = 0,19$). No caso do IAC 503, o valor de R^2 é consideravelmente maior (0,48),

apresentando desempenho semelhante ao encontrado para a cultivar IAC OL3 (Figura 2).

Os valores baixos de R^2 indicam que o modelo tem baixa precisão em suas estimativas, demonstrando, pouca capacidade de explicar a variabilidade das perdas invisíveis dentro das condições apresentadas por cada cultivar. Por outro lado, analisamos os valores de MAE (Granoleico = 55,53; IAC 503 = 41,26; IAC 677 = 63,08), vemos que os valores estão abaixo ou muito próximos do desvio padrão dos dados reais (Granoleico = 67,79; IAC 503 = 57,94; IAC 677 = 60,99). Logo, isto sugere que os erros que o modelo comete estão dentro do intervalo de variabilidade natural dos dados. Assim, o desempenho do modelo nos mostra que ele pode fornecer estimativas que, em média, não se afastam drasticamente dos valores observados.




Figura 4. Regressão linear entre as perdas invisíveis observadas e estimadas para as cultivares Granoleico, IAC 503 e IAC 677. As perdas invisíveis foram estimadas utilizando uma equação que tem as perdas visíveis como indicador principal.

O processo de quantificação e estimativa das perdas invisíveis é notoriamente trabalhoso, exaustivo e demorado. Isso se deve ao fato de ser necessário escavar o solo até uma profundidade de 15 a 20 cm para identificar e coletar as vagens remanescentes. Após a coleta, o material deve ser submetido a um processo de secagem e limpeza para que, finalmente, as perdas possam ser estimadas em quilogramas por hectare. Devido à complexidade e ao tempo envolvido, muitos produtores acabam realizando um número limitado de amostragens em campo para avaliar a eficiência do processo de colheita. No entanto, essa prática pode ser insuficiente para refletir a verdadeira realidade da

operação, o que pode levar a decisões equivocadas, especialmente no que diz respeito à regulação de máquinas e à gestão das perdas.

Tendo em vista essas limitações, o modelo proposto para estimar as perdas invisíveis, que inicialmente foi desenvolvido para a cultivar OL3, apresenta-se como uma solução inovadora para mitigar essas dificuldades. Mesmo que o modelo não tenha alta precisão em todas as suas estimativas, ele oferece uma boa acurácia com estimativas que estão alinhadas com a realidade observada em campo. Isso significa que os valores estimados pelo modelo são suficientemente confiáveis para proporcionar uma visão abrangente do desempenho da colheita.

Nesse contexto, a aplicação desse modelo pode permitir que os produtores ampliem o número de amostragens em campo de maneira mais eficiente, reduzindo a necessidade de processos demorados e exaustivos. Assim, com mais dados à disposição e resultados em tempo hábil, os produtores terão mais opções para tomadas decisões rápidas e mais assertivas, como ajustes na regulação do maquinário durante a colheita. Essa abordagem não só otimiza a gestão operacional, mas também promove um maior controle das perdas, melhorando o rendimento e a eficiência do processo como um todo.

É importante reconhecer que os modelos foram desenvolvidos originalmente para a cultivar OL3. Assim, algumas limitações podem surgir ao aplicá-lo a outras cultivares. Por exemplo cultivares com características morfológicas muito distintas podem afetar ainda mais a precisão dos modelos. Nestes casos, ajustes no modelo ou calibrações específicas podem ser necessários para melhorar ainda mais sua performance.

Por fim, os modelos propostos para as estimativas de perdas tanto pela contagem de vagens, assim como a estimativas das perdas invisíveis pelas visíveis, independentemente da classe de solo, têm o potencial de revolucionar a forma como os produtores monitoram e gerenciam suas colheitas. Assim seu desempenho robusto em diferentes cultivares deve ser visto como um ponto de partida para aprimoramentos futuros, garantindo que ele possa ser adaptado e ajustado conforme as necessidades específicas de cada variedade e as condições específicas a cada local de colheita.

3.5. Aplicação dos modelos por meio de uma plataforma de servidor web

Pensando em tornar o processo de estimativa de perdas na colheita de amendoim mais acessível e eficiente para produtores e técnicos, foi desenvolvida uma plataforma baseada em servidor web, utilizando os modelos desenvolvidos para a estimativa de perdas visíveis e invisíveis. Essa plataforma denominada Sapeca¹, foi construída utilizando o pacote Streamlit em Python, conhecido por sua simplicidade e capacidade de criar interfaces intuitivas para o usuário final. A plataforma, disponível no link <https://estimativa-perdas-amendoim.streamlit.app/>, foi projetada para ser amigável e prática, oferecendo uma interface que facilita a utilização dos modelos sem a necessidade de conhecimentos técnicos avançados (Figura 5).

O fluxo de navegação começa com um título claro, seguidos por uma aba lateral que permite ao usuário navegar entre as principais opções: “Página Inicial”, “Instruções” e “Estimar Perdas”. Cada uma dessas seções oferece funcionalidades essenciais para o uso eficaz da plataforma. Logo, a interface se adapta dinamicamente de acordo com as escolhas do usuário.




Figura 5. Interface da plataforma construída com base no pacote Streamlit.

¹ Sistema de Avaliação de Perdas na Colheita de Amendoim

A “Página Inicial” fornece uma introdução detalhada sobre o aplicativo, com uma visão geral do desenvolvimento do ambiente e os seus objetivos. Na opção “Instruções” estão disponíveis informações detalhadas sobre o desenvolvimento da armação para quantificação das perdas, considerando o tipo de maquinário empregado na colheita. Além disso, oferece orientações práticas e outras informações úteis que auxiliam os usuários tanto na utilização da plataforma quanto na condução das estimativas de perdas em campo.

A opção “Estimar Perdas” é o ponto principal da ferramenta. Nela o usuário tem acesso a duas modalidades de aplicação, permitindo que escolha a abordagem que melhor atende às suas necessidades: estimar as perdas visíveis e invisíveis com base na contagem de vagens ou calcular as perdas invisíveis a partir das perdas visíveis. A interface adapta-se automaticamente conforme a opção selecionada, otimizando a inserção de dados.

- Se o usuário optar por **estimativa de perdas com base na contagem de vagens**, os campos de entrada ajustam-se para permitir a adição do número de vagens coletadas em campo, garantindo uma análise detalhada e precisa.

- Caso o objetivo seja **calcular as perdas invisíveis a partir das perdas visíveis**, os campos de entrada serão configurados para receber diretamente os valores de perdas visíveis previamente estimados, tornando o processo de cálculo mais ágil e simplificado.

Após a inserção dos dados, a plataforma gera um relatório completo das estimativas, que pode ser baixado em formato digital. Isso permite que os produtores mantenham um registro das perdas estimadas, auxiliando na tomada de decisões mais informadas sobre ajustes operacionais e estratégias de manejo da colheita.

4. Conclusões

Neste estudo, demonstramos que as perdas na colheita mecanizada de amendoim podem ser estimadas por meio da contagem de vagens, independentemente

da classe de solo. Apesar da variabilidade espacial observada nas áreas de estudo, o modelo geral, desenvolvido a partir da combinação de diferentes áreas e solos, mostrou-se robusto, com bom coeficiente de determinação ($R^2 > 0,75$) tanto para a contagem total de vagens quanto para as vagens de dois grãos. Esses modelos apresentam grande potencial de aplicação prática no campo, auxiliando na otimização do processo de colheita mecanizada e na melhoria da gestão das perdas pelos produtores.

No que se refere à estimativa das perdas invisíveis com base nas perdas visíveis, os resultados indicam que as perdas visíveis podem servir como um indicador para as invisíveis, embora com limitações, especialmente ao considerar a variabilidade espacial entre áreas específicas. O melhor modelo encontrado sugeriu que as perdas visíveis explicam até 48% da variabilidade das perdas invisíveis na cultivar IAC OL3. Quando avaliada sua performance nas cultivares Granoleico e IAC 677, o modelo teve baixa precisão. Para a cultivar IAC 503 o desempenho foi igual ao obtido para IAC OL3. Contudo, os erros associados às estimativas (MAE) dentro de cada cultivar mantiveram-se dentro de limites aceitáveis, sugerindo que, apesar das limitações, o modelo pode fornecer uma visão geral confiável do desempenho da colheita.

Assim, pensando em maximizar o potencial desses modelos de estimativa de perdas na colheita de amendoim, foi desenvolvida uma plataforma web de fácil uso, que funciona como uma ferramenta prática para produtores de todos os níveis. Esta plataforma permite estimar as perdas visíveis e invisíveis de forma eficiente, eliminando a necessidade de processos manuais complexos e demorados. Além de reduzir os custos e esforços associados à estimativa de perdas, a plataforma promove uma abordagem mais abrangente e eficaz para otimizar o desempenho das operações agrícolas.

Por fim, os modelos desenvolvidos representam um avanço significativo na quantificação e gestão das perdas na colheita de amendoim, com potencial para melhorar a eficiência operacional e reduzir os desperdícios. As próximas etapas incluem a incorporação de variáveis ambientais, como o teor de água do solo, para refinar ainda mais as estimativas, além de ajustes para aumentar a aplicabilidade dos modelos em diferentes cultivares e condições de campo. O uso desses modelos, aliado a plataformas

tecnológicas, como a desenvolvida neste estudo, pode facilitar a adoção de práticas agrícolas mais eficientes e economicamente viáveis.

5. Referências

Bonku R, Jianmei Y (2020) Health Aspects of Peanuts as an Outcome of Its Chemical Composition. **Food Science and Human Wellness** 9(1): 21-30. <https://doi.org/10.1016/j.fshw.2019.12.005>

Brito Filho AL, Carneiro FM, Souza JBC, Almeida SLH, Lena BP, Silva RP (2023) Does the Soil Tillage Affect the Quality of the Peanut Picker? **Agronomy** 13(4): 1024-16. <https://doi.org/10.3390/AGRONOMY13041024>

Ince A, Guzel E (2003) Effects of Gynophore Breaking Resistance on Losses in Mechanized Peanut Harvesting. In **International Conference on Crop Harvesting and Processing**. St. Joseph, MI: American Society of Agricultural and Biological Engineers. <https://doi.org/10.13031/2013.15189>

Mesquita C de M, Costa N P da, Mantovani EC, Andrade JGM de, França Neto JB, Silva JG da, Fonseca JR, Portugal FAF, Guimarães Sobrinho JB (1998) Manual Do Produtor: Como Evitar Desperdícios Nas Colheitas de Soja, Do Milho e Do Arroz. Londrina: EMBRAPA CNPSO. v. 2. Disponível em: <<http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/460388>>. Acesso em: 29 out. 2024.

Ormond ATS, Santos AF dos, Alcantara AS, Zerbato C, Furlani CEA (2018) Tillage Interference in the Quality of Peanut Mechanized Harvest. **Engenharia Agrícola** 38(2): 251–59. <https://doi.org/10.1590/1809-4430-ENG.AGRIC.V38N2P251-259/2018>

Reza, MN, Na IS, Baek SW, Lee KH (2019) Rice Yield Estimation Based on K-Means Clustering with Graph-Cut Segmentation Using Low-Altitude UAV Images. **Biosystems Engineering** 177:109–21. <https://doi.org/10.1016/J.BIOSYSTEMSENG.2018.09.014>

Riera, LG, Carroll ME, Zhang Z, Shook JM, Ghosal S, Gao T, Singh A, Bhattacharya S, Ganapathysubramanian B, Singk AK, Sarkar S (2021) Deep Multiview Image Fusion for Soybean Yield Estimation in Breeding Applications. *Plant Phenomics* 2021: 1-12. <https://doi.org/10.34133/2021/9846470>

Rossi, M. (2017). Mapa pedológico do Estado de São Paulo: revisado e ampliado.

Santos, AF dos, Alcântara AS, Corrêa LN, Queiroz RF de, Silva RP da (2021) Does Moisture in Pods Interfere with Mechanized Harvesting of Peanuts? **Engenharia Agrícola** 41(1): 98–106. <https://doi.org/10.1590/1809-4430-Eng.Agric.v41n1p98-106/2021>

Santos, AF dos, Luan Pereira de Oliveira, Bruno Rocca de Oliveira, Antonio Tassio Santana Ormond, and Rouverson Pereira da Silva. 2021. “Can Digger Blades Wear Affect the Quality of Peanut Digging?” *Revista Engenharia Na Agricultura - Reveng* 29 (April):49–57. <https://doi.org/10.13083/reveng.v29i1.10444>

Santos AF dos, Silva RP da, Zerbato C, Menezes PC de, Kazama EH, Paixão CSS, Voltarelli MA (2019) Use of Real-Time Extend GNSS for Planting and Inverting Peanuts. **Precision Agriculture** 20(4): 840–56. <https://doi.org/10.1007/s11119-018-9616-z>

Stewart-Brown BB, Song Q, Vaughn JN, Li Z (2019) Genomic Selection for Yield and Seed Composition Traits Within an Applied Soybean Breeding Program. **G3 Genes|Genomes|Genetics** 9(7): 2253–65. <https://doi.org/10.1534/G3.118.200917>

Taylor R (1990) Interpretation of the Correlation Coefficient: A Basic Review. **Journal of Diagnostic Medical Sonography** 6:35–39.

Tedesco-Oliveira D, Silva RP da, Maldonado Junior W, Zerbato C (2020) Convolutional Neural Networks in Predicting Cotton Yield from Images of Commercial Fields. **Computers and Electronics in Agriculture** 171(105307): 1-10. <https://doi.org/10.1016/J.COMPAG.2020.105307>

Uzal LC, Grinblat GL, Namías R, Larese MG, Bianchi JS, Morandi EN, Granitto PM (2018) Seed-per-Pod Estimation for Plant Breeding Using Deep Learning. **Computers and Electronics in Agriculture** 150:196–204. <https://doi.org/10.1016/J.COMPAG.2018.04.024>

Wei MCF, Molin JP (2020) Soybean Yield Estimation and Its Components: A Linear Regression Approach. **Agriculture (Switzerland)** 10(8): 1–13. <https://doi.org/10.3390/agriculture10080348>

Zerbato C, Furlani CEA, Silva RP da, Voltarelli MA, Santos AF dos (2017) Statistical Control of Processes Applied for Peanut Mechanical Digging in Soil Textural Classes. **Engenharia Agrícola** 37(2): 315–22. <https://doi.org/10.1590/1809-4430-Eng.Agric.v37n2p315-322/2017>

Zerbato C, Silva VFA, Torres LS, Silva RP da, Furlani CEA (2014) Peanut Mechanized Digging Regarding to Plant Population and Soil Water Level. **Revista Brasileira de Engenharia Agrícola e Ambiental** 18(4): 459–465.

Zhao J, Kaga A, Yamada T, Komatsu K, Hirata K, Kikuchi A, Hirafuji M, Ninomiya S, Guo W (2023) Improved Field-Based Soybean Seed Counting and Localization with Feature Level Considered. **Plant Phenomics** 5: 1-9. <https://doi.org/10.34133/plantphenomics.0026>

Material Suplementar




Figura S1. Modelos para estimativa de perdas visíveis em função do número de vagens em classes de solo: Argissolos Vermelho-Amarelos (PVA) e Latossolos Vermelhos (LV).




Figura S2. Modelos para estimativa de perdas invisíveis em função do número de vagens em classes de solo: Argissolos Vermelho-Amarelos (PVA) e Latossolos Vermelhos (LV).




Figura S3. Modelos geral para estimativa de perdas no arranquio de amendoim em função do número de vagens em classes de solo: Argissolos Vermelho-Amarelos (PVA) e Latossolos Vermelhos (LV). O desenvolvimento desses modelos foi por meio da união dos dados de perdas visíveis e invisíveis.

CAPÍTULO 4 – Redes convolucionais profundas baseadas em YOLOv8 para detecção e estimativa de perdas de amendoim a partir de imagens em ambientes pós-colheita²

RESUMO - A estimativa de perdas de amendoim é a chave para o monitoramento da qualidade operacional do sistema de colheita mecanizada. No entanto, estimativas manuais enfrentam limitações práticas no campo, pois tendem a ser exaustivas, demoradas e propensas a erros, especialmente após longos períodos de trabalho. Portanto, o principal objetivo deste estudo foi desenvolver uma estrutura de processamento de imagens automatizada para detectar, contar e estimar perdas de vagens de amendoim durante a operação de colheita. Nós propusemos uma abordagem robusta abrangendo diferentes condições ambientais e algoritmos de detecção de treinamento, especificamente baseados na arquitetura leve YOLOv8, com imagens adquiridas com um smartphone móvel em seis horários diferentes do dia (10, 11, 13, 14, 15 e 16h). Os resultados experimentais mostraram que a detecção de vagens de amendoim com dois grãos foi mais eficaz do que a detecção de vagens com um grão, com maior precisão, revocação e valores de mAP50. Os melhores resultados para aquisição de imagens foram entre 10 e 14h. O estudo também comparou métodos de contagem manual e automatizado, revelando que os melhores cenários para contagem alcançaram um R^2 acima de 0,80. Além disso, mapas georreferenciados de perdas de amendoim revelaram variabilidade espacial significativa, fornecendo insights críticos para intervenções direcionadas. Essas descobertas demonstram o potencial de aumentar a eficiência da colheita mecanizada e estabelecer as bases para a integração futura em sistemas totalmente automatizados. Ao incorporar esse método em máquinas de colheita, o monitoramento em tempo real e a quantificação precisa das perdas podem ser alcançados, reduzindo substancialmente a necessidade de avaliações manuais intensivas em mão de obra.

Palavras-chaves: *Arachis hypogaea* L., Colheita inteligente, Detecção de objeto, Perdas de amendoim, YOLOv8

1. Introdução

O gerenciamento eficaz da colheita mecanizada é essencial para controlar os custos de produção e garantir o retorno econômico nas atividades agrícolas. Assim, a

² Este capítulo corresponde ao artigo científico submetido à revista Computers and Electronics in Agriculture (JCR - 7,7) e encontra-se em avaliação.

redução de perdas durante a colheita é um elemento crucial dos sistemas de produção agrícola sustentáveis. O amendoim é uma oleaginosa essencial para o setor agrícola e a indústria alimentícia. Suas sementes são essenciais para a produção de óleos comestíveis e diversos produtos, como manteiga, pastas e salgadinhos. Dada sua importância, estimativas precisas de perdas durante a colheita são vitais para a tomada de decisões por agricultores e cooperativas. No entanto, a eficiência da operação pode ser impactada por muitos fatores, incluindo as condições ambientais (Ormond et al., 2018; Zerbato et al., 2017), as características do maquinário utilizado (Santos et al., 2019), a qualidade da matéria-prima (Santos et al., 2021) e o nível de qualificação da força de trabalho (Brito Filho et al., 2023). Portanto, desenvolver novos métodos para identificar perdas no processo de colheita do amendoim pode ser uma excelente estratégia para melhorar significativamente o monitoramento das operações mecanizadas e promover práticas de colheita mais sustentáveis.

Tradicionalmente, a estimativa de perdas de amendoim na colheita tem sido baseada em metodologias desenvolvidas por Mesquita et al. (1998) e Augsburger (1992). O método de Mesquita et al. (1998) envolve uma estrutura retangular cobrindo uma área de 2 m², proporcional ao tamanho da largura útil da plataforma de corte da colhedora. O método de Augsburger (1992), por outro lado, emprega quatro estruturas circulares, cada uma de dimensões idênticas, que juntas correspondem a uma área de 1 m². No entanto, ambas as metodologias enfrentam limitações práticas no campo. O trabalhador responsável deve caminhar pelo campo, procurar e contar manualmente as vagens restantes no solo para estimar as perdas. Assim, estimativas manuais tendem a ser exaustivas, demoradas e suscetíveis a erros, principalmente após longos períodos de trabalho. Portanto, um sistema automático para identificar perdas de amendoim é uma solução promissora.

A tecnologia de visão computacional teve diversas aplicações para identificação automática de objetos usando Redes Neurais Convolucionais (CNN) e obteve grande sucesso (Dias et al., 2018; Rahman et al., 2023; Ruiz-Ponce et al., 2023; Zhuang et al., 2018). Pesquisas anteriores mostraram que, usando CNN, Liu et al. (2020) identificaram e classificaram imagens hiperespectrais de amendoins saudáveis, danificados e mofados, alcançando uma precisão de 92,07%. Por outro lado, Yang et al. (2021) usaram uma CNN aprimorada para identificar e classificar

imagens coletadas por scanner de 12 cultivares de amendoim, alcançando uma precisão de identificação de 96,70%. No entanto, ambos os estudos demonstram informações em ambientes controlados e livres da influência de fatores externos, como luminosidade e oclusão parcial (causada por palhas). Além disso, eles usaram diferentes plataformas de aquisição de imagens que são economicamente inviáveis para integração futura em sistemas automáticos de detecção de perdas na colheita mecanizada de amendoim. Em contraste, o uso de smartphones para adquirir dados de imagem apresenta uma solução viável e econômica. Devido à sua ampla disponibilidade e facilidade de operação, esses dispositivos permitem a coleta de um grande volume de dados de imagem, o que é essencial para o treinamento robusto de algoritmos de CNN.

No campo de detecção de objetos, a série YOLO (You Only Look Once) se destaca por sua técnica exclusiva de propagação direta para detecção e classificação de objetos. Este algoritmo de um estágio emprega caixas de âncora para integrar simultaneamente classificação e regressão na localização de objetos. Comparado com algoritmos de detecção de dois estágios, o YOLO é notável por sua velocidade de detecção mais rápida e oferece as vantagens de operação em tempo real, alta eficiência e flexibilidade. Sua capacidade de identificar objetos de forma rápida e precisa o torna adequado para várias tarefas do setor agrícola. Por exemplo, gerenciamento de campo (Khalid et al., 2023; Xu et al., 2023), detecção de plantas daninhas (Dang et al., 2023; Zhang et al., 2022), detecção e contagem de frutos (Li et al., 2023; Yang et al., 2023; Zhu et al., 2023; Zhuang et al., 2018) e detecção de doenças de plantas (Cap et al., 2023; Qing et al., 2023). Embora os algoritmos de detecção de objetos baseados em aprendizado profundo forneçam soluções convenientes, rápidas e precisas, mais pesquisas são necessárias para detectar e contar vagens de amendoim em condições desafiadoras em um ambiente pós-colheita de amendoim.

Nesse contexto, nosso trabalho se distingue pela obtenção de imagens proximais de vagens de amendoim usando smartphones em diferentes condições ambientais e temporais em áreas de produção comercial. Nossa hipótese é que o uso de visão computacional, por meio de imagens proximais e aprendizado profundo, facilitará a identificação e classificação das perdas de amendoim e, dessa forma,

obterá valores de perdas estimadas com precisão e em tempo real, auxiliando os agricultores a gerenciar essa operação mecanizada. Portanto, este estudo foi motivado pela necessidade de desenvolver um novo método robusto para estimar com precisão as perdas na colheita mecanizada de amendoim. Assim, pretendemos investigar o potencial de identificar perdas quantitativas da produção de amendoim usando imagens de um dispositivo móvel e um modelo CNN. As principais contribuições desta pesquisa são as seguintes: (1) desenvolvemos um conjunto de dados robusto com imagens adquiridas de um campo de produção comercial em diferentes horários do dia. O banco de dados contém 1.264 imagens de amendoim anotadas com 29.047 exemplos de perdas; (2) Nosso estudo representa um avanço significativo no desenvolvimento de novas técnicas para identificar perdas no processo de colheita de amendoim, considerando sua complexidade. Estas constituem uma evolução notável em comparação com as abordagens tradicionais, conhecidas por serem demoradas e exaustivas. Além disso, visualizamos esses resultados usando mapas interpolados pelo método do Inverso do Quadrado da Distância (IDW). Essa abordagem abre novas perspectivas para o desenvolvimento de sistemas inteligentes projetados para serem integrados em máquinas de colheita de amendoim

2. Material e Métodos

2.1. Configuração Experimental

Os dados de perdas foram coletados durante as safras de 2020-2021 e 2022-2023 em áreas de cultivo comercial no Estado de São Paulo, Brasil (Figura 1). A fase inicial do experimento, conduzida durante a safra 2020-2021, foi desenvolvida com o intuito de construir um conjunto de dados abrangente de perdas do Campo #1 (Município de Ibitinga). Posteriormente, a safra 2022-2023 foi alocada para uma fase de testes intensivos do Campo #2 (Município de Sertãozinho). O amendoim foi cultivado utilizando um sistema de preparo convencional, aderindo a uma densidade de semeadura de 18 sementes por metro e mantendo um espaçamento entre fileiras

de 0,90 metros. A cultivar de amendoim selecionada para este estudo foi a IAC OL 3, renomada por seu ciclo de crescimento abreviado de cerca de 125 a 130 dias e pela boa qualidade excepcional de seus grãos. Esta cultivar é especialmente notável por sua alta concentração de ácido oleico no óleo, que constitui aproximadamente 70 a 80% de sua composição.




Figura 1. Mapa de localização das áreas experimentais dos campos #1 (Município de Ibitinga) e #2 (Município de Sertãozinho) estavam no Estado de São Paulo, Brasil. Campo 1 de treinamento e campo 2 de teste. Os pontos marcados no campo 2 indicam os locais georreferenciados onde as imagens foram capturadas para o conjunto de dados de teste.

2.1.1. Aquisição de imagens

Dados experimentais foram coletados após a colheita mecanizada do amendoim, particularmente durante a operação do recolhimento. A colheita do amendoim é realizada indiretamente, necessitando-se de múltiplas operações. A operação inicial, conhecida como arranquio, envolve cortar a raiz pivotante abaixo do solo, “puxar” as plantas do solo e expor a parte subterrânea (vagens) para cima para secagem natural sob a luz solar. O segundo estágio ocorre após esse processo de secagem natural, onde o teor de umidade atinge entre 18 a 24%. As plantas de amendoim foram coletadas durante essa operação, e as vagens foram separadas da planta. Após esse processo de recolhimento, foram observadas as perdas visíveis totais das etapas de arranquio e recolhimento mecanizado.

No processo agrícola convencional, a fase de recolhimento de amendoim geralmente ocorre por volta das 10 às 18h. Para esta pesquisa, a aquisição de imagens foi conduzida em amostras aleatórias dentro da área comercial usando uma câmera de telefone celular padrão (iPhone Xs, Apple Inc, CA, EUA), que apresenta recursos de gravação de vídeo 4K a 60 quadros por segundo. A filmagem foi realizada a uma altura aproximada de 1,5 metros (m) acima da superfície do solo para permitir a identificação de todas as perdas visíveis. Cada filme teve uma duração total de dez minutos, espaçados durante cada período de coleta. Assim, ao cortar esses arquivos de vídeo, diferentes imagens foram selecionadas visualmente para que não houvesse imagens idênticas no banco de dados.

O conjunto de dados robusto foi criado com imagens adquiridas em seis horários diferentes do dia (10h, 11h, 13h, 14h, 15 e 16h) abrangendo diferentes níveis de luminosidade. Além disso, as imagens foram tiradas sob várias condições que detalham as variações que ocorrem durante o tempo de colheita ao longo do dia em um campo comercial de amendoim. Assim, imagens de vagens de amendoim com diferentes tamanhos, formas, brilho, sombra e grau de oclusão foram coletadas para criar um conjunto de dados robusto.

2.1.2. Construção de conjunto de dados

O conjunto de dados foi formado por 1.264 imagens com exemplos de perdas de amendoim. Cada vagem encontrada na imagem foi anotada usando o projeto de código aberto Labellmg no GitHub (<https://github.com/tzutalin/labellmg>). As anotações foram classificadas em vagens de um grão e dois grãos. Após observar a descoberta de poucos exemplos da classificação de três grãos no conjunto de dados, optamos por não trabalhar com essa classe, pois não seria possível balancear o conjunto de dados. A abordagem de resumo elaborada neste estudo é mostrada na Figura 2.




Figura 2. Resumo gráfico com as etapas de construção do banco de dados. (a) aquisição de imagem; (b) filmagem da área de interesse; (c) exemplo de classificação de perdas.

No conjunto de dados, 29.047 vagens foram rotuladas (Tabela 1). O conjunto de dados foi dividido aleatoriamente em 80% (1.009 imagens) e 20% (255 imagens) para o conjunto de treinamento e conjunto de validação, respectivamente.

Tabela 1. Exemplos de notas de caixa delimitadora e o número de imagens nos conjuntos de treinamento e validação são categorizados de acordo com as condições ambientais.

Período do dia/Tempo		TI	QIT	QIV	Vagens	TV	TVT	TVV
Manhã	10h	272	217	55	1 grão	2.859	2.245	614
					2 grãos	3.044	2.442	602
	11h	287	229	58	1 grão	1.689	1.388	301
					2 grãos	2.790	2.204	586
Tarde	13h	98	78	20	1 grão	437	340	97
					2 grãos	1.040	809	231
	14h	174	139	35	1 grão	1.270	994	276
					2 grãos	1.813	1.452	361
	15h	199	159	40	1 grão	4.096	3.328	768
					2 grãos	5.167	4.215	952
	16h	234	187	47	1 grão	2.352	1.911	441
					2 grãos	2.490	1.992	498
Total		1.264	1.009	255		29.047	23.320	5.727

TI – Total de imagens; QIT – Quantidade de imagens para treinamento; QIV – Quantidades de imagens para validação; TV – Total de vagens encontradas; TVT – Total de vagens encontradas no treinamento; TVV – Total de vagens encontradas na validação

2.2. Construção de modelo de detecção de perdas de amendoim

O modelo YOLO tem sido referência em visão computacional, destacando-se pelo seu sucesso e inovações significativas, principalmente em aplicações que exigem detecção rápida e eficiente de objetos. Sua capacidade de detectar e reconhecer uma ampla gama de objetos em imagens ou vídeos, aliada à alta velocidade e precisão, o torna ideal para aplicações em tempo real. No contexto agrícola, onde a detecção rápida em campo é crucial, o YOLOv8 se destaca como uma excelente opção por ser leve e eficiente.

O YOLOv8 contém cinco versões com diferentes tamanhos de modelo, a saber, YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l e YOLOv8x. A diferença entre vários modelos é a profundidade e a largura do modelo. O YOLOv8n tem a estrutura de rede mais simples entre as variantes, enquanto o YOLOv8x é o modelo com a estrutura mais profunda, consequentemente oferecendo maior desempenho em muitos cenários. Neste artigo, focamos na versão YOLOv8n devido ao seu peso leve e capacidade de oferecer detecções rápidas no campo. Portanto, sua simplicidade pode

facilitar a integração com máquinas agrícolas e sistemas automatizados, contribuindo para a otimização das operações diretamente nas áreas de cultivo.

A arquitetura do algoritmo YOLOv8n compreende uma rede de espinha dorsal, uma rede de pescoço e uma rede de cabeça. A rede de espinha dorsal realiza operações convolucionais para extrair recursos de imagens coloridas RGB (R-vermelho, G-verde e B-azul) em várias escalas. A rede de pescoço integra os recursos extraídos pela rede de espinha dorsal, normalmente empregando uma estrutura de pirâmide de recursos (Feature Pyramid Networks, FPN) para agregar recursos de baixo nível em representações de nível superior. A camada líder (rede cabeça) é responsável por prever a categoria de destino, usando três conjuntos de detectores com tamanhos variados para selecionar o conteúdo da imagem. A Figura 3 ilustra a estrutura do algoritmo YOLOv8n padrão.




Figura 3. Diagrama da estrutura do modelo de YOLOv8n.

2.3. Configurações ambientais

Os processos de treinamento, validação e teste do modelo foram conduzidos uniformemente em uma plataforma Python. O sistema foi operado em uma estação de trabalho (CPU, Intel Core i9 11.900KF @ 3,50 GHz; RAM 64 GB) equipada com

NTV – Número médio de vagens por amostra de perdas; NV – Número de vagens;

Além das amostras de perdas de amendoim coletadas manualmente, registramos os quadros retangulares usando uma câmera simples de smartphone (iPhone 11, Apple Inc, CA, EUA), capaz de gravar vídeo 4K a 60 FPS. As filmagens foram sempre feitas na mesma altura para a criação do banco de dados na fase de treinamento. Usamos essas gravações para gerar um mosaico (Figura S1), que serviu de base para os algoritmos treinados detectarem perdas automaticamente. Todos os processos foram padronizados em um ambiente virtual usando a plataforma Google Colaboratory (www.colab.research.google.com). O Google Colab, com sua infraestrutura de computação em nuvem integrada ao Jupyter Notebooks, facilitou a implementação dos códigos necessários para processar os vídeos e criar o mosaico. Além disso, procedemos com uma contagem manual das perdas nos mosaicos gerados.

2.5. Avaliação de desempenho

Precisão (P), Revocação (R), mAP@50, número de parâmetros e número de operações de ponto flutuante giga por segundo (GFLOPs) foram usados como indicadores de avaliação do desempenho de detecção do modelo. Precisão (Equação 1) refere-se à proporção de vagens de amendoim detectados corretamente em relação ao número total de objetos detectados pelo modelo. Revocação (Equação 2) diz respeito à proporção de vagens de amendoim identificados corretamente e ao número total de vagens no conjunto de dados. O número de parâmetros refere-se ao número de variáveis treináveis no modelo. Assim, quanto mais parâmetros, maior a capacidade do modelo de aprender representações complexas, mas isso também aumenta o tamanho e o uso de memória do modelo. GFLOPs medem o número de operações computacionais realizadas pelo modelo por segundo, indicando sua complexidade computacional. O modelo proposto foi comparado aos padrões YOLOv8s, YOLOv5n e YOLOv3-Tiny. As equações de precisão e recall são mostradas a seguir:

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (1)$$

$$\text{Revocac\~ao} = \frac{TP}{TP + FN} \quad (2)$$

Neste contexto, TP (Verdadeiros Positivos) refere-se ao nmero de amostras positivas corretamente identificadas, FN (Falsos Negativos) s amostras positivas incorretamente previstas como negativas, e FP (Falsos Positivos) s amostras negativas incorretamente previstas como positivas.

O mAP@50 (Preciso mdia na interseco acima do limite de unio de 50%)  uma mtrica que avalia a preciso mdia (AP) do modelo em diferentes nveis de Interseco sobre Unio (IoU). O conjunto de interseco IoU indica a taxa de sobreposio entre as caixas delimitadoras previstas e verdadeiras. Normalmente, o limite para IoU  definido como 0,50. A amostra  definida como TP quando IoU  maior que 0,50. Se IoU for menor que 0,50, essa amostra  definida como uma FP de amostra falsa. As frmulas para mAP@0,50 so as seguintes:

$$AP = \int_0^1 P(r) dr \quad (3)$$

$$mAP = \frac{\sum_{i=1}^C AP_i}{C} \quad (4)$$

$P(r)$  a curva de preciso-recall suavizada; C  o nmero de categorias; e AP_i denota a taxa de preciso mdia da categoria. Alm disso, uma curva de preciso-recall com valores variando de 0 a 1 foi usada para avaliar o desempenho da deteco de perda de amendoim. Assim, os melhores momentos para aquisio de imagens foram escolhidos e usados na etapa de teste usando esses indicadores.

Na etapa de teste, os melhores cenrios para contagem de vagens de amendoim usando imagens foram escolhidos comparando as contagens de cada cenrio com aquelas feitas manualmente na prpria imagem aps sua aquisio e calculando o Erro Absoluto Percentual Mdio (MAPE):

$$MAPE (\%) = \frac{\sum_{i=0}^n \left(\left| \frac{C_{automatic} - C_{manual}}{C_{manual}} \right| * 100 \right)}{n} \quad (5)$$

Em que: n - número total de imagens, $C_{Automatic}$ - número de perdas contadas automaticamente e C_{manual} - o número real de perdas contadas manualmente na imagem.

Além disso, com base nesses resultados, uma análise de regressão foi realizada para avaliar o ajuste do modelo, usando o coeficiente de determinação (R^2) e o erro absoluto médio (MAE) como as principais métricas. R^2 indica a qualidade do ajuste do modelo aos dados de teste; quanto mais próximo de 1, melhor o modelo explica a variabilidade observada, demonstrando maior precisão. Em contraste, valores menores de MAE indicam menos discrepância entre previsões e valores reais, refletindo maior precisão na estimativa de perdas.

2.6. Mapas de perdas de amendoim

Esta seção detalha o método usado para criar mapas que ilustram a distribuição das perdas de campo estimadas. Nossa observação inicial revelou que as perdas estimadas pelos métodos manual e automático não apresentaram dependência espacial significativa nas amostras, conforme indicado pela análise de interpolação dos dados georreferenciados. Assim, empregamos o método Inverso do Quadrado da Distância (IDW) no software QGIS®, versão 2.18.26. Essa técnica interpola os mapas de variabilidade espacial estimando valores em áreas desconhecidas com base nas distâncias entre os pontos amostrados.

Utilizando esta abordagem, geramos três tipos diferentes de mapas que permitem a visualização da dispersão das perdas de campo estimadas:

Mapa de perdas reais de campo: Este mapa foi gerado a partir de dados de amostragem tradicionais coletados diretamente no campo. Ele reflete as perdas reais de amendoim observadas em cada ponto de amostragem e serve como referência para comparações com estimativas feitas por outros métodos.

Mapa de perdas estimadas por contagem visual: Este mapa apresenta as perdas estimadas de amendoim com base na contagem visual de vagens nas imagens capturadas durante a fase de teste. As vagens foram identificadas e quantificadas manualmente por observadores humanos.

Mapa de perdas estimadas por contagem automática: Este mapa se refere às perdas de amendoim estimadas pela quantificação automática de perdas pelo algoritmo YOLOv8n. Neste caso, o modelo de detecção automática processou as imagens e quantificou as vagens de um e dois grãos de forma totalmente automática, sem intervenção humana.

Para converter as contagens de vagens em estimativas de perdas visíveis, tanto manual quanto automaticamente, o peso médio das vagens teve que ser calculado. Este valor, calculado com base em 80 amostras coletadas no campo de teste (Tabela 2), resultou em uma média de 23,60 gramas por vagem. Após estabelecer o peso médio das vagens, as quantidades de vagens perdidas, contadas manual e automaticamente pelo algoritmo YOLOv8n, foram multiplicadas por este valor. Isso permitiu a conversão das contagens em estimativas de massa, que foram então extrapoladas para representar perdas em quilogramas por hectare.

3. Resultados

3.1. Comparação de desempenho dos algoritmos de última geração

Para comparar a eficiência do modelo YOLOv8n proposto neste artigo, conduzimos experimentos comparativos usando versões anteriores do YOLO, como YOLOv3-Tiny e YOLOv5n, e uma versão mais complexa, YOLOv8s. Esses experimentos foram conduzidos usando o mesmo dispositivo, conjunto de dados e métodos de aumento de dados. Garantimos que as proporções entre os conjuntos de treinamento e validação fossem iguais. Os resultados da comparação são apresentados na Tabela 4.

Tabela 4. Comparações entre as versões do algoritmo YOLO.

Modelo	Precisão (%)	Revocação (%)	mAP ₅₀ (%)	Parâmetros (M)	GFLOPs
YOLOv3-Tiny	44,0	44,4	40,3	12,12	18,9
YOLOv5n	53,8	55,9	54,7	2,503	7,1
YOLOv8n	54,2	57,1	55,0	3,006	8,1
YOLOv8s	57,2	58,6	57,1	11,12	28,4

De acordo com a Tabela 4, comparado com YOLOv3-tiny, os índices de desempenho de YOLOv8n são melhores, com P, R e mAP_{50} aumentando em 10,2%, 13,3% e 14,7%, respectivamente. Além disso, a complexidade de YOLOv8n é reduzida, implicando vantagens na velocidade de processamento. Comparado com YOLOv5n, YOLOv8n mostrou uma diferença de 0,4% e 0,3% para precisão e mAP_{50} , respectivamente. No entanto, o valor de recall aumentou em 1,2%, sugerindo que YOLOv8n perde menos casos relevantes, aumentando sua confiabilidade para aplicações práticas. Isso é importante ao considerar a complexidade de identificar perdas em um ambiente pós-colheita. Por outro lado, YOLOv8n tem mais parâmetros e GFLOPs do que YOLOv5n, resultando em maior tempo de treinamento e complexidade. YOLOv8s mostrou melhor desempenho de detecção do que YOLOv8n, com aumentos de 3%, 1,5% e 2,1% para P, R e mAP_{50} , respectivamente. No entanto, ele requer mais de três vezes os recursos computacionais do modelo proposto. Essa maior demanda por recursos pode representar desvantagens significativas na velocidade de processamento, tornando o modelo mais pesado para aplicações em tempo real.

3.2. Desempenho do conjunto de dados de validação em função do tempo de aquisição da imagem

A Figura 4 mostra as curvas P-R (Precisão-Revocação) de classes de perdas de amendoim sob diferentes condições de iluminação ao longo do dia. As curvas de vagens de um grão (Figura 4A) demonstram uma tendência de desempenho inferior em P conforme o R aumenta, sugerindo um desafio na identificação e classificação de vagens de um grão em todas as condições de captura de fotos. Em contraste, as curvas P-R para vagens de dois grãos (Figura 4B) são notavelmente mais estáveis e mais próximas umas das outras, indicando que o modelo tem desempenho consistente, resultando em maior P em níveis mais altos de R.




Figura 4. Curvas de precisão-recall para cada condição de captura fotográfica de perda de amendoim da câmera de smartphone móvel. A - Vagens de um grão identificadas; B - Vagens de dois grãos identificadas.

Analisando o desempenho geral do conjunto de dados de validação (Figura 5), observamos que a classificação de vagens de dois grãos superou os de um grão, caracterizada por uma diferença média para P, R e mAP_{50} de 36%, 34% e 45%, respectivamente. Além disso, o desempenho de identificação e classificação para vagens de dois grãos atingiu valores acima de 70% para as métricas P, R e mAP_{50} , com pequenas variações em função dos tempos de aquisição de imagem.

Os resultados mostram que para ambos os cenários de classes de perdas (um e dois grãos por vagem), os melhores horários para aquisição de imagens foram às 11h e 13h, conforme mostrado nas curvas P-R (Figura 4). Além disso, após 13h, a precisão das identificações diminuiu para ambos os cenários (Figura 5). Tais padrões são semelhantes para as métricas R e mAP_{50} para a classe de um grão, onde após 14h, o desempenho do modelo diminuiu. Por outro lado, para a classe de dois grãos, o intervalo de tempo das 15h tem desempenho semelhante aos horários das 11h e 13h para as métricas de R e mAP_{50} .




Figura 5. Resultados de validação do YOLOv8n em cada classe treinada como uma função do tempo de aquisição de imagem. A – Taxa de precisão; B – Taxa de revocação; e C – mAP_{50} .

3.3. Desempenho de teste de campo

3.3.1. Contagem manual versus automática de perdas de amendoim

Para avaliar a eficácia do modelo proposto, conduzimos uma fase de testes em um ambiente distinto daquele utilizado para treinamento e validação. O horário de aquisição das imagens foi das 10 às 13h. A Figura 6 apresenta os resultados dessa contagem automática de perdas de amendoim, em contraste com os dados de contagem real. O Erro Absoluto Percentual Médio (MAPE) foi usado como métrica avaliativa para determinar a precisão do modelo proposto na identificação precisa de vagens de um e dois grãos (Figura 6D).

Analisando as variações na contagem automática gerada pelo modelo proposto com contagem manual, notamos que a precisão na detecção de vagens com um grão é consideravelmente baixa, com um MAPE maior que 75%, mostrando mais inconsistência com os valores observados nas imagens. Em contraste, as contagens para vagens com dois grãos se mostraram mais precisas. Elas seguiram as tendências das contagens manuais e obtiveram um MAPE de aproximadamente 45%.




Figura 6. Comparação entre contagem manual e automática de perdas de amendoim por imagem. A - Vagem de um grão; B - Vagens de dois grãos; C - Número total de vagens encontradas na imagem; e D - Erro Absoluto Percentual Médio (MAPE) de contagens de perdas de amendoim para diferentes classes de vagens.

Além disso, uma terceira abordagem foi realizada que contou o número total de vagens, combinando aquelas com uma e dois grãos. Esta abordagem mostrou resultados semelhantes à contagem de vagens de dois grãos, com um MAPE de cerca de 43%. Esta descoberta reforça que o modelo tem melhor desempenho ao analisar vagens com dois grãos. Este resultado é particularmente interessante quando analisamos situações práticas nas quais não é crucial distinguir entre os tipos de vagens, mas sim, obter uma contagem total precisa.

3.3.2. Estimativa de perdas de amendoim por imagem

Após identificar os cenários em que o modelo proposto apresentou melhor desempenho com o MAPE, foi realizada uma análise de regressão para entender como as perdas observadas na Figura 7 podem explicar variações nas perdas estimadas. Analisando o desempenho do YOLOv8n na estimativa de perdas (Figuras 7A e 7B), observou-se que o modelo atingiu valores de R^2 de 0,81 e 0,84 para perdas estimadas pela contagem de vagens de dois grãos e vagens totais, respectivamente.

Em outras palavras, existe uma forte relação linear entre perdas estimadas e observadas.




Figura 7. Regressão linear entre perdas observadas e estimadas de amendoim por YOLOv8n. A - Estimativa de perdas pela contagem de vagens de dois grãos; B – Estimativa de perdas pela contagem de vagens totais.

3.3.3. Mapas de perdas de amendoim

As perdas resultantes da operação de colheita apresentam alta variabilidade em seus dados (Santos et al., 2019; Zerbato et al., 2017). Portanto, utilizamos o método IDW para visualizar e analisar a variabilidade espacial entre perdas reais em campo e perdas estimadas pela contagem de vagens nas imagens (manual e automática) em uma área agrícola comercial (Figura 8). Dessa forma, a Figura 8A demonstra a variabilidade das perdas encontradas em campo, servindo como referência para avaliar a acurácia das perdas estimadas pela contagem visual a partir de imagens (Figura 8B) e das perdas estimadas pela contagem automática utilizando o modelo YOLOv8n (Figura 8C).

Seguindo esse raciocínio, observamos que a contagem manual de vagens na imagem e a contagem automática pelo YOLOv8n detectaram áreas com altas e baixas perdas, semelhantes aos resultados encontrados em campo. Entretanto, o mapa interpolado das estimativas de perdas pela contagem automática pelo YOLOv8n demonstrou uma tendência a subestimar os valores de perdas.




Figura 8. Mapas de interpolação conforme coleta de perdas de amendoim em teste de campo, em que: A - valores reais de perdas de amendoim encontrados em campo; B - mapas estimados de perdas por contagem visual nas imagens; C - mapas estimados de perdas obtidos pela contagem automática realizada pelo algoritmo YOLOv8n.

Comparando o comportamento dos 80 pontos de perdas utilizados para a criação dos mapas usando o boxplot (Figura 9A), observamos que as perdas estimadas pela contagem de vagens nas imagens (manual e automática) apresentaram distribuições de dados semelhantes, mostrando menor variabilidade do que os dados de perdas reais de campo. Os valores de perdas reais no campo exibiram cinco outliers, resultando em uma alta variação nos valores de perdas do amendoim. O maior outlier registrado foi aproximadamente cinco vezes ($612,00 \text{ kg ha}^{-1}$) o valor médio ($123,24 \text{ kg ha}^{-1}$). No entanto, as perdas estimadas pela contagem visual ainda se assemelham mais aos dados de perdas reais de campo, do que a estimativa feita com o método proposto, que obteve MAE de $48,35 \text{ kg ha}^{-1}$ e $72,42 \text{ kg ha}^{-1}$, respectivamente (Figura 9B).




Figura 9. Comparação da variabilidade entre perdas reais de amendoim estimadas no campo e estimativas de perdas de amendoim usando contagem manual e automática com YOLOv8n em imagens. A - Boxplots ilustrando a variabilidade entre diferentes abordagens de estimativa de perdas de amendoim; B - Erro Absoluto Médio das estimativas de perdas da contagem manual e automática de vagens em comparação com os valores reais de campo.

4. Discussão

Nosso estudo propôs um novo método para estimar perdas quantitativas na colheita mecanizada de amendoim. Usando imagens de um dispositivo móvel e treinando os algoritmos YOLO, buscamos identificar e classificar os amendoins restantes no campo após a etapa de colheita. Até onde sabemos, este é o primeiro uso de uma rede convolucional profunda para identificar perdas na colheita de amendoim por meio de sensores móveis de baixo custo em função de condições ambientais e temporais que representam a realidade dos campos de produção comercial.

4.1. Dificuldades na identificação de perdas de amendoim

A fase de colheita é vital na produção agrícola, representando o resultado final do tempo e dos recursos investidos em fases anteriores. Esta fase está intrinsecamente ligada à renda econômica dos agricultores. A execução inadequada ou negligente desta operação pode acarretar perdas substanciais. Portanto, identificar perdas é um fator essencial para aumentar a eficácia das operações agrícolas. Envolve identificar e abordar fatores potenciais que contribuem para a variabilidade

imprevista no processo. Logo, tais abordagens tornam viável a implementação de estratégias específicas para resolver essas questões. Consequentemente, isso protege os interesses dos agricultores e garante a continuidade e a persistência da sustentabilidade do ciclo de produção.

A obtenção de boa precisão na detecção de vagens é crucial para uma excelente estimativa de perdas. De acordo com os critérios PASCAL, uma detecção é considerada precisa se a sobreposição entre a área delimitada manualmente e as regiões detectadas for mais significativa do que 50% (Everingham et al., 2010). Assim, os resultados deste estudo mostraram desempenho satisfatório na detecção de vagens sob condições específicas de captura de imagem, atingindo um valor de mAP_{50} de 54% (Tabela 4). No entanto, o desempenho geral de detecção do modelo YOLOv8n foi influenciado pelo baixo desempenho de detecção da classe de um grão.

A dificuldade em reconhecer vagens de um grão foi evidenciada pela baixa pontuação mAP_{50} (abaixo de 45%), conforme mostrado na Figura 5 C. Em contraste, a detecção de vagens de dois grãos demonstrou mAP_{50} consistentemente acima de 50%. Vagens de dois grãos são mais facilmente identificáveis devido ao seu maior tamanho. Para entender essa variação, medimos amostras de cada tipo de vagem com base nos 80 pontos de perdas realizados na etapa de teste, conforme detalhado na Tabela 3. A análise mostrou que vagens de dois grãos são, em média, 10,91 mm maiores do que vagens de um grão. Além disso, descobrimos que mais de 80% das vagens identificadas no campo eram vagens de dois grãos. Observamos a mesma situação no número total de vagens usadas no treinamento do modelo YOLOv8n, no qual aproximadamente 80% eram desta categoria. Portanto, vagens de um grão não são tão fáceis de serem encontradas em campo.

A tecnologia de detecção de objetos baseada em aprendizado profundo oferece fortes capacidades de generalização. No entanto, no ambiente pós-colheita, a complexidade ambiental pode comprometer a eficácia da identificação de vagens de amendoim. Devido ao seu pequeno tamanho, as vagens de amendoim enfrentam desafios específicos, pois são facilmente escondidas, camufladas ou confundidas com o fundo complexo. Além disso, variações nas condições de iluminação podem alterar sua aparência, tornando o processo de detecção ainda mais desafiador. A Figura 10 ilustra esses desafios observados em nosso banco de dados.




Figura 10. Desafios potenciais durante a detecção de vagens em ambiente pós-colheita.

A detecção de objetos em ambientes agrícolas é um desafio significativo, especialmente para culturas com alvos pequenos, como amendoim, que tendem a ser mais difíceis de identificar (Li et al., 2023). Esses objetos geralmente se camuflam no ambiente devido a semelhanças de cor e textura, dificultando a distinção de seus limites visuais (Shi et al., 2023). Desafios semelhantes são observados na detecção de frutas e outros objetos. Neste contexto, Parvathi e Tamil Selvi (2021) observaram que a identificação do coco é prejudicada por oclusões causadas por folhagens e caules. Da mesma forma, Apolo-Apolo et al. (2020) relataram que a detecção de laranja na copa das árvores é influenciada por variações de cor, textura e contornos, com foco principalmente nas frutas mais visíveis. Kazama et al. (2024) também relataram dificuldades na detecção da maturação dos frutos de café em condições de campo, causadas por oclusões e variações de iluminação, demonstrando a necessidade de soluções que melhorem a precisão da detecção em ambientes complexos.

As condições de iluminação desempenham um importante papel na aquisição de imagens. Assim, nosso conjunto de dados foi projetado para garantir que o algoritmo tenha um bom desempenho sob várias condições de iluminação, tornando-

o adaptável ao longo do dia. Essa flexibilidade é essencial para aplicações práticas, pois a colheita de amendoim convencional geralmente ocorre entre às 10h e 18h. Nosso estudo descobriu que a detecção de vagens de dois grãos foi particularmente eficaz para estimar com precisão as perdas de amendoim. Os melhores resultados foram obtidos entre às 10h e 14h. No entanto, a precisão do algoritmo diminui devido às mudanças nas condições de luz à medida que o dia avança. Apesar disso, o algoritmo permanece robusto o suficiente para manter uma precisão de detecção razoável mesmo em condições menos favoráveis, garantindo sua eficácia em diferentes ambientes de campo.

Mudanças na iluminação ao longo do dia podem impactar significativamente a qualidade da imagem e a precisão da detecção (Hossain e Kabir, 2023; Sakeef et al., 2023). Variações nas condições de luz podem alterar as cores aparentes dos objetos, sendo uma ação fundamental na detecção de objetos onde a cor é um fator-chave e pode resultar em classificações errôneas ou detecção falha (Chu et al., 2021; Tedesco-Oliveira et al., 2020). Esse aspecto é particularmente crítico ao considerar a identificação de perdas de amendoim, pois a cor das vagens pode ser muito semelhante à do material vegetal residual (palha) presente no solo durante a operação ou mesmo à cor do próprio solo. Assim, para enfrentar esses desafios, ajustar as configurações da câmera, como determina a sensibilidade do sensor da câmera à luz (Organização Internacional de Padronização – ISO) e velocidade do obturador, pode ajudar a controlar a sensibilidade à luz e a duração da exposição, otimizando a qualidade da imagem em diversas condições de iluminação. Isso permite que o sistema continue fornecendo dados confiáveis para a tomada de decisões, mesmo quando as condições de iluminação são piores que as ideais.

4.2. Estimativas e mapas de perdas de amendoim

A identificação das vagens do amendoim é um fator-chave na estimativa de perdas pós-colheita. No entanto, o ambiente pós-colheita é altamente complexo e influenciado por vários fatores que resultam em alta variabilidade nos valores de perdas, conforme demonstrado pela visualização espacial (Figura 8A). Apesar dessa complexidade, nossos resultados indicam que a contagem automática usando o

algoritmo YOLOv8n conseguiu identificar padrões de perdas que se aproximam dos dados reais coletados em campo, conforme demonstrado nos mapas de interpolação. Apesar de atingir esse nível de precisão, o MAE encontrado foi de 72,42 kg ha⁻¹, indicando que ainda há lacuna para melhoria no desempenho do algoritmo.

Da mesma forma, a contagem manual de vagens em imagens também capturou a variabilidade das perdas observadas no campo. No entanto, esse resultado era esperado, pois um observador humano realizou a identificação das vagens. No entanto, essa abordagem apresentou um MAE de 48,35 kg ha⁻¹. Essa semelhança entre os resultados obtidos pelos métodos manual e automático sugere que, embora ambos enfrentem limitações na identificação completa das vagens, o algoritmo de detecção automática está bastante próximo de atingir uma precisão comparável aos métodos manuais. Tais resultados também podem ser vistos na Figura 7, onde foi observada uma forte relação entre as perdas estimadas pelos dois métodos, com valores de R² maiores que 0,80.

Por outro lado, esses resultados indicam que as discrepâncias nas estimativas de perdas não são necessariamente causadas pela falha do YOLOv8n em detectar vagens, mas sim por características inerentes ao ambiente agrícola. Fatores como variações na luz, obstruções físicas e condições naturais do solo afetam igualmente a contagem manual e automática, criando desafios comuns para ambos os métodos. Isso sugere que as limitações observadas não são exclusivas de sistemas automatizados e, portanto, esses sistemas podem ser vistos como alternativas viáveis para o monitoramento de perdas em larga escala.

Além disso, a diferença relativamente pequena de 24 kg ha⁻¹ no erro absoluto médio entre os dois métodos mostra que a automação está muito próxima de atingir níveis de precisão equivalentes aos métodos manuais. Isso indica o grande potencial que a inteligência artificial tem para auxiliar no monitoramento agrícola, não apenas em termos de precisão, mas também por proporcionar maior eficiência operacional, permitindo que estimativas de perdas sejam feitas em tempo real e em grandes áreas.

4.3. Implicações e perspectivas futuras

Implementar um sistema automatizado para detectar perdas de amendoim impacta diretamente a eficiência operacional e o gerenciamento da colheita. A capacidade de quantificar essas perdas com precisão não só permite que os agricultores ajustem suas práticas de gerenciamento, mas também os capacita a tomar decisões mais consistentes durante o processo de colheita, minimizar o desperdício e maximizar a produtividade.

O uso de algoritmos como o YOLOv8n oferece uma solução viável para reduzir a coleta manual de dados ao permitir a detecção de perdas em tempo real. A criação de sistemas inteligentes que podem ser integrados diretamente em máquinas de colheita e detectar perdas de forma automatizada e em tempo real representa um avanço significativo na eficiência operacional da colheita. A adoção dessas tecnologias, juntamente com o investimento contínuo em pesquisa e desenvolvimento, tem o potencial de transformar a colheita mecanizada de amendoim. Equipamentos e métodos desenvolvidos especificamente para essa cultura resultariam em ganhos substanciais na precisão da detecção de perdas, beneficiando toda a cadeia produtiva, do produtor ao consumidor. Essa inovação otimizaria o processo, reduziria custos e aumentaria a competitividade do cultivo de amendoim.

O estudo de algoritmos para identificação automática de perdas de amendoim marca um avanço significativo no monitoramento de precisão agrícola. Este estudo se concentrou na detecção de duas categorias específicas de perdas de amendoim: vagens de um grão e vagens de dois grãos. No entanto, como observado nos resultados, desafios ainda precisam ser superados para garantir a máxima eficácia da detecção, especialmente em condições adversas.

Portanto, as direções futuras podem incluir a integração de módulos de atenção avançados, como o proposto por Yang et al. (2023) e Kazama et al. (2024), para melhorar o desempenho do algoritmo. A aplicação desses módulos permitiu que os algoritmos de detecção processassem detalhes cruciais em múltiplas escalas, aumentando a precisão em ambientes complexos, como campos agrícolas com iluminação variável e obstáculos físicos, como resíduos de colheita e vegetação. Além disso, para enfrentar os desafios apresentados por ambientes agrícolas complexos, a adoção de métodos como o proposto por Shi et al. (2023), que melhora a consciência do contexto e as informações de borda, pode melhorar significativamente a detecção

de objetos camuflados. Este método seria benéfico para identificar vagens de amendoim, que variam em tamanho, encontram-se parcialmente escondidas por detritos e têm bordas difíceis de distinguir em ambientes agrícolas. Melhorias na detecção de objetos ocluídos, pequenos e de contornos complexos desempenhariam um papel crucial na melhoria da detecção de vagens em condições adversas.

Outra direção importante seria o desenvolvimento de um conjunto de dados público especificamente para perdas de amendoim, semelhante ao conjunto de dados COCO. Este conjunto de dados incluiria imagens de perdas de amendoim capturadas sob várias condições de iluminação, resoluções e ângulos de câmera. Um conjunto de dados tão diverso formaria uma base sólida para pesquisas futuras em detecção automatizada de vagens, com foco em redes de detecção leves e ágeis que podem operar em tempo real e de forma barata. Essas inovações tecnológicas, juntamente com a criação de um conjunto de dados mais abrangente, têm o potencial de superar as limitações atuais e levar a um sistema de detecção de perdas de amendoim mais preciso, eficiente e escalável. A aplicação dessas melhorias impactaria diretamente a produtividade agrícola e a sustentabilidade do cultivo de amendoim, promovendo a adoção de práticas agrícolas mais eficientes e tecnológicas.

5. Conclusões

A detecção de vagens de amendoim é o primeiro passo essencial para o desenvolvimento de um sistema de monitoramento e quantificação de perdas ocorridas durante a colheita mecanizada de amendoim. Neste estudo, os resultados experimentais mostraram que a detecção de vagens de dois grãos forneceu melhores resultados para contagem e estimativas de perdas. Os valores de precisão, revocação e mAP_{50} da classe de dois grãos são maiores em comparação à classe com perdas de um grão. Além disso, mostramos que as condições ideais para aquisição de imagens são entre 10h e 14h. O algoritmo YOLOv8n se destacou na contagem de vagens, exibindo capacidade de generalização superior e robustez às variações ambientais. A comparação entre a contagem manual e automática revelou que os melhores cenários de contagem de vagens (apenas vagens de dois grãos e contagem total de vagens) atingiram um R^2 acima de 0,80, confirmando a eficácia do modelo proposto.

6. Referências

- Apolo-Apolo OE, Martínez-Guanter J, Egea G, Raja P, Pérez-Ruiz M (2020) Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV. **European Journal of Agronomy** 115(126030): 1-11. <https://doi.org/10.1016/j.eja.2020.126030>
- Augsburger HKM (1992) **Determinación de perdidas en la cosecha de granos**. Montevideo, UY.
- Brito Filho AL, Morlin Carneiro F, Souza JBC, Almeida SLH, Patias BL, Silva RP (2023) Does the Soil Tillage Affect the Quality of the Peanut Picker? **Agronomy** 13(4): 1024-16. <https://doi.org/10.3390/AGRONOMY13041024>
- Cap QH, Fukuda A, Kagiwada S, Uga H, Iwasaki N, Iyatomi H (2023) Towards robust plant disease diagnosis with hard-sample re-mining strategy. **Computers and Electronics in Agriculture** 215 (108375): 1-11. <https://doi.org/10.1016/j.compag.2023.108375>
- Chu P, Li Z, Lammers K, Lu R, Liu X (2021) Deep learning-based apple detection using a suppression mask R-CNN. **Pattern Recognit Lett** 147: 206–211. <https://doi.org/10.1016/j.patrec.2021.04.022>
- Dang F, Chen D, Lu Y, Li Z (2023) YOLOWeeds: A novel benchmark of YOLO object detectors for multi-class weed detection in cotton production systems. **Computers and Electronics in Agriculture** 205 (107655): 1-13. <https://doi.org/10.1016/j.compag.2023.107655>
- Hossain MRH, Kabir MA (2023) Machine Learning Techniques for Estimating Soil Moisture from Smartphone Captured Images. **Agriculture** 13(3): 574-25. <https://doi.org/10.3390/agriculture13030574>
- Kazama EH, Tedesco D, Carreira V dos S, Barbosa Júnior MR, de Oliveira MF, Ferreira FM, Maldonado Junior W, da Silva RP (2024) Monitoring coffee fruit maturity using an enhanced convolutional neural network under different image acquisition settings. **Scientia Horticulturae** 328(112957):1-7. <https://doi.org/10.1016/j.scienta.2024.112957>

Khalid S, Oqaibi HM, Aqib M, Hafeez Y (2023) Small Pests Detection in Field Crops Using Deep Learning Object Detection. **Sustainability** 15(8), 6815-19. <https://doi.org/10.3390/su15086815>

Li R, Ji Z, Hu S, Huang X, Yang J, Li W (2023) Tomato Maturity Recognition Model Based on Improved YOLOv5 in Greenhouse. **Agronomy** 13(2): 603-16. <https://doi.org/10.3390/agronomy13020603>

Li X, Chen J, He Y, Yang G, Li Z, Tao Y, Li Yanda, Li Yu, Huang L, Feng X (2023) High-through counting of Chinese cabbage trichomes based on deep learning and trinocular stereo microscope. **Computers and Electronics in Agriculture** 212(108134): 1-14. <https://doi.org/10.1016/j.compag.2023.108134>

Liu Z, Jiang J, Qiao X, Qi X, Pan Y, Pan X (2020) Using convolution neural network and hyperspectral image to identify moldy peanut kernels. **LWT** 132(109815): 1-9. <https://doi.org/10.1016/j.lwt.2020.109815>

Mesquita CM, Costa NP, Mantovani EC, Andrade JGM, França Neto JB, Silva JG, Fonseca JR, Portugal FAF, Guimarães Sobrinho JB (1998) **Manual do produtor: como evitar desperdícios nas colheitas de soja, do milho e do arroz**. Londrina: EMBRAPA CNPSO. 32 p. (EMBRAPA-CNPSO. Documentos, 112; EMBRAPA-CNPM. Documentos, 11; EMBRAPA-CNPAF. Documentos, 87).

Ormond ATS, Dos Santos AF, Alcantara AS, Zerbato C, Furlani CEA (2018) Tillage interference in the quality of peanut mechanized harvest. **Engenharia Agrícola** 38: 251–259. <https://doi.org/10.1590/1809-4430-ENG.AGRIC.V38N2P251-259/2018>

Parvathi S, Tamil Selvi S (2021) Detection of maturity stages of coconuts in complex background using Faster R-CNN model. **Biosystems Engineering** 202: 119–132. <https://doi.org/10.1016/j.biosystemseng.2020.12.002>

Qing J, Deng X, Lan Y, Li Z (2023) GPT-aided diagnosis on agricultural image based on a new light YOLOPC. **Computers and Electronics in Agriculture** 213(108168): 1-14. <https://doi.org/10.1016/j.compag.2023.108168>

Sakeef N, Scandola S, Kennedy C, Lummer C, Chang J, Uhrig RG, Lin G (2023). Machine learning classification of plant genotypes grown under different light conditions through the integration of multi-scale time-series data. **Computational and Structural Biotechnology Journal** 21: 3183–3195. <https://doi.org/10.1016/j.csbj.2023.05.005>

Santos AF, Alcântara AS, Corrêa LN, de Queiroz RF, Silva RP (2021) Does moisture in pods interfere with mechanized harvesting of peanuts? **Engenharia Agrícola** 41: 98–106. <https://doi.org/10.1590/1809-4430-ENG.AGRIC.V41N1P98-106/2021>

Santos AF, Silva RP, Zerbato C, de Menezes PC, Kazama EH, Paixão CSS, Voltarelli MA (2019) Use of real-time extend GNSS for planting and inverting peanuts. *Precis Agric* 20: 840–856. <https://doi.org/10.1007/S11119-018-9616-Z/FIGURES/7>

Shi, C., Ren, B., Chen, H., Zhao, L., Lin, C., Zhao, Y., 2023. Camouflaged object detection based on context-aware and boundary refinement. **Applied Intelligence** 53: 22429–22445. <https://doi.org/10.1007/s10489-023-04645-x>

Tedesco-Oliveira D, Pereira da Silva R, Maldonado W, Zerbato C (2020) Convolutional neural networks in predicting cotton yield from images of commercial fields. *Computers and Electronics in Agriculture* 171(105307): 1-10. <https://doi.org/10.1016/J.COMPAG.2020.105307>

Xu W, Xu T, Alex Thomasson J, Chen W, Karthikeyan R, Tian G, Shi Y, Ji C, Su Q, (2023) A lightweight SSV2-YOLO based model for detection of sugarcane aphids in unstructured natural environments. **Computers and Electronics in Agriculture** 211(107961): 1-16. <https://doi.org/10.1016/J.COMPAG.2023.107961>

Yang G, Wang J, Nie Z, Yang H, Yu S (2023) A Lightweight YOLOv8 Tomato Detection Algorithm Combining Feature Enhancement and Attention. **Agronomy** 13(7): 1824-14. <https://doi.org/10.3390/agronomy13071824>

Yang H, Ni J, Gao J, Han Z, Luan T (2021) A novel method for peanut variety identification and classification by Improved VGG16. *Scientific Reports* 11(15756): 1-17. <https://doi.org/10.1038/s41598-021-95240-y>

Zerbato C, Furlani CEA, da Silva RP, Voltarelli MA, dos Santos AF (2017) Statistical control of processes applied for peanut mechanical digging in soil textural classes. **Engenharia Agrícola** 37: 315–322. <https://doi.org/10.1590/1809-4430-ENG.AGRIC.V37N2P315-322/2017>

Zhang H, Wang Z, Guo Y, Ma Y, Cao W, Chen D, Yang S, Gao R (2022) Weed Detection in Peanut Fields Based on Machine Vision. **Agriculture** 12(10): 1541-15. <https://doi.org/10.3390/agriculture12101541>

Zhu Y, Li S, Du W, Du Y, Liu P, Li X (2023) Identification of table grapes in the natural environment based on an improved YOLOv5 and localization of picking points. **Precision Agriculture** 24: 1333–1354. <https://doi.org/10.1007/s11119-023-09992-w>

Zhuang JJ, Luo SM, Hou CJ, Tang Y, He Y, Xue XY (2018) Detection of orchard citrus fruits using a monocular machine vision-based method for automatic fruit picking applications. **Computers and Electronics in Agriculture** 152: 64–73. <https://doi.org/10.1016/j.compag.2018.07.004>


Material Suplementar

Figura S1. Exemplo de como as imagens para a fase de testes foram geradas a partir de vídeos gravados em cada unidade de amostragem.

CAPÍTULO 5 – Considerações finais e trabalhos futuros

Esta Tese de Doutorado representa um avanço significativo no monitoramento e gerenciamento de perdas na colheita mecanizada de amendoim. Atualmente, poucos estudos se dedicam a desenvolver métodos precisos e acessíveis para a estimativa de perdas nessa cultura, especialmente no contexto da agricultura digital e orientada por dados. Com as soluções aqui desenvolvidas, oferecemos novas ferramentas que permitem aos produtores melhorar o controle sobre as operações de colheita, garantindo maior rentabilidade e práticas agrícolas mais responsáveis.

Em resumo, algumas das principais contribuições desta pesquisa incluem:

1. Desenvolvemos e validamos modelos inovadores que permitem estimar perdas na colheita com agilidade e precisão, simplificando o processo, uma vez que dispensa etapas demoradas dos métodos manuais. Baseado na contagem de vagens, um dos modelos oferece uma solução prática e acessível para a estimativa de perdas visíveis e invisíveis diretamente em campo. Além disso, outro modelo foi desenvolvido para inferir perdas invisíveis a partir das visíveis, ampliando o valor do monitoramento ao possibilitar estimativa de perdas totais sem a necessidade de processos exaustivos e demorados.

2. Desenvolvemos uma plataforma digital intuitiva que possibilita a aplicação dos modelos diretamente no campo. Esta plataforma transforma a estimativa de perdas em uma atividade acessível aos produtores, permitindo que realizem avaliações precisas e rápidas no próprio local de colheita.

3. Apresentamos uma solução automatizada utilizando redes convolucionais profundas para detectar e estimar perdas de amendoim a partir de imagens capturadas no ambiente pós-colheita. Essa tecnologia permite a contagem automática e precisa das vagens, proporcionando maior agilidade e precisão na coleta de dados em comparação aos métodos tradicionais. Essa abordagem demonstra a possibilidade de aumentar o número de amostragens em campo, e por meio delas desenvolver mapas detalhados da variabilidade espacial das perdas. Essa inovação capacita os produtores a identificar com exatidão áreas críticas de perda e a implementar estratégias de manejo mais direcionadas e eficientes, resultando em uma colheita mais produtiva e sustentável.

Com base nessas contribuições, destacamos algumas direções promissoras para futuras pesquisas e aplicações:

1. Desenvolver um sistema inteligente embarcado nas máquinas colhedoras, utilizando o modelo de detecção de vagens, que permita a contagem de vagens e a estimativa de perdas em tempo real durante a operação de colheita. Essa implementação possibilitará uma avaliação contínua do desempenho da colheita mecanizada em condições reais e fornecerá dados para ajustes e melhorias imediatas no processo.

2. Utilizar os dados gerados por esse sistema inteligente para criar mapas de variabilidade espacial das perdas, possibilitando a análise da associação dessas perdas com fatores específicos das áreas de colheita. Com essa análise, será possível investigar correlações com outros atributos relacionados solo-cultura-ambiente, promovendo novas estratégias de intervenção e manejo orientado por dados.

3. Explorar técnicas de visão computacional para monitorar a qualidade do material colhido, permitindo uma avaliação mais detalhada e precisa da integridade e qualidade do amendoim pós-colheita, atendendo a critérios industriais e comerciais de qualidade.

4. Avaliar a possibilidade de estimar a produtividade por meio da contagem automática de vagens, utilizando plataformas móveis e aéreas para coleta de dados, integradas a técnicas de visão computacional. Essa abordagem permitirá uma previsão precisa da produtividade diretamente em campo, beneficiando o planejamento da produção.

5. Investigar novas tecnologias para mensuração de perdas na colheita de amendoim, integrando dados de sensoriamento remoto, informações climáticas, parâmetros agronômicos e algoritmos de aprendizado de máquina. Essa integração pode oferecer insights preditivos, auxiliando os produtores a antecipar perdas e otimizar o manejo agrícola com base em condições específicas de cada safra e região.

CONTRIBUIÇÕES DOS AUTORES



ARMANDO LOPES DE BRITO FILHO

Ele é o principal autor e pesquisador desta Tese de Doutorado.

Capítulo 1: Conceitualização, Análise formal, Redação - preparação do rascunho original, Redação - revisão e edição.

Capítulo 2: Conceitualização, Metodologia, Validação, Análise formal, Investigação, Preparação dos dados, Redação - rascunho original, Redação - revisão e edição, Visualização. Capítulo 3: Conceitualização, Metodologia, Validação, Análise formal, Investigação, Redação - rascunho original, Redação - revisão e edição, Visualização. Capítulo 4: Conceitualização, Metodologia, Software, Validação, Análise formal, Investigação, Redação - rascunho original, Redação - revisão e edição, Visualização. Capítulo 5: Conceitualização, Análise formal, Redação - preparação do rascunho original, Redação - revisão e edição.



ROUVERSON PEREIRA DA SILVA

Capítulo 1: Redação - revisão e edição, supervisão. *Capítulo 2:*

Redação - revisão e edição, visualização, administração do projeto, supervisão. *Capítulo 3:* Conceitualização, Redação - revisão e edição, Supervisão, Visualização, Administração do projeto.

Capítulo 4: Conceitualização, Redação - revisão e edição, Supervisão, Visualização, Administração do projeto. *Capítulo 5:* Conceitualização, Redação - revisão e edição, supervisão.



LUCIANO SHOZO SHIRATSUCHI

Capítulo 3: Visualização, Redação - revisão e edição.

**JARLYSON BRUNNO COSTA SOUZA**

Capítulo 3: Investigação, Redação - revisão e edição. *Capítulo 4:* Investigação, Redação - revisão e edição.

**BRUNO RAFAEL DE ALMEIDA MOREIRA**

Capítulo 2: Metodologia, Redação - revisão e edição. *Capítulo 4:* Investigação, Redação - revisão e edição.

**IGOR CRISTIAN DE OLIVEIRA VIEIRA**

Capítulo 2: Conceitualização, Metodologia, Análise formal, Investigação, Preparação dos dados, Redação - rascunho original, Redação - revisão e edição. *Capítulo 3:* Metodologia, Software, Redação - revisão e edição.

**FRANCIELE MORLIN CARNEIRO**

Capítulo 4: Metodologia, Análise formal, Redação - revisão e edição.

**VINICIUS DOS SANTOS CARREIRA**

Capítulo 4: Redação - revisão e edição, Metodologia, Software.

**DANILO TEDESCO**

Capítulo 4: Conceitualização, Metodologia, Investigação, Redação - revisão e edição.

**MARCELO RODRIGUES BARBOSA JÚNIOR**

Capítulo 4: Investigação, Redação - revisão e edição.

**LUIS ALBERTO ROCHA RODRIGUES JUNIOR**


Capítulo 2: Conceitualização, Metodologia, Análise formal, Investigação, Preparação dos dados, Redação - rascunho original, Redação - revisão e edição.

**BRENO DOS SANTOS SILVA**

Capítulo 2: Conceitualização, Metodologia, Análise formal, Investigação, Preparação dos dados, Redação - rascunho original, Redação - revisão e edição.

**FRANCISCO PAULO AMARAL JÚNIOR**

Capítulo 2: Conceitualização, Metodologia, Análise formal, Investigação, Preparação dos dados, Redação - rascunho original, Redação - revisão e edição.



GABRIEL PEREIRA COSTA

Capítulo 3: Investigação, Redação - revisão e edição.