

UNIVERSIDADE NOVE DE JULHO – UNINOVE
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO
CONHECIMENTO – PPGI

ROBSON APARECIDO GOMES

**INSPEÇÃO VISUAL AUTOMÁTICA DE GRÃOS AGRÍCOLAS: demandas,
potenciais aplicações e desafios para transferência de tecnologia no setor
agrícola**

SÃO PAULO
2024

**UNIVERSIDADE NOVE DE JULHO – UNINOVE PROGRAMA DE PÓS-
GRADUAÇÃO EM INFORMÁTICA E GESTÃO DO CONHECIMENTO**

ROBSON APARECIDO GOMES

**INSPEÇÃO VISUAL AUTOMÁTICA DE GRÃOS AGRÍCOLAS: demandas,
potenciais aplicações e desafios para transferência de tecnologia no setor
agrícola**

Tese apresentada ao Programa de Pós-Graduação em Informática e Gestão do Conhecimento – PPGI da Universidade Nove de Julho (UNINOVE), como parte dos requisitos para obtenção do título de Doutor em Informática.

Orientador: Prof. Dr. Sidnei Alves de Araújo

Coorientador: Prof. Dr. Peterson Adriano Belan

Linha de pesquisa: 2 – Sistemas Inteligentes

**SÃO PAULO
2024**

Gomes, Robson Aparecido.

Inspeção visual automática de grãos agrícolas: demandas, potenciais aplicações e desafios para transferência de tecnologia no setor agrícola. / Robson Aparecido Gomes. 2024.

107 f.

Tese (Doutorado) - Universidade Nove de Julho - UNINOVE, São Paulo, 2025.

Orientador (a): Prof. Dr. Sidnei Alves de Araújo.

1. Inspeção visual. 2. Grãos. 3. Agricultura. 4. Agroindústria. 5. Transferência de tecnologia.

I. Araújo, Sidnei Alves de. II. Título.

CDU 004

ATA DE DEFESA DA TESE

Ao vigésimo dia do mês de dezembro de dois mil e vinte e quatro, às 10h00, no programa de Pós-Graduação, desta Universidade, reuniu-se em sessão pública a Comissão Julgadora da tese de doutorado de Robson Aparecido Gomes sob o título "INSPEÇÃO VISUAL AUTOMÁTICA DE GRÃOS AGRÍCOLAS: demandas, potenciais aplicações e desafios para transferência de tecnologia no setor agrícola". Integraram a comissão os professores Doutores: Sidnei Alves de Araújo (UNINOVE), Peterson Adriano Belan (UNINOVE), André Felipe Henriques Librantz (UNINOVE), Geraldo Cardoso de Oliveira Neto (UFABC) e André Augusto Gutierrez Fernandes Beati (FATEC), sob a presidência do primeiro, orientador da tese. A banca examinadora, tendo decidido aceitar a tese, passou à arguição pública do candidato. Encerrados os trabalhos, os examinadores deram parecer final sobre a Tese.

Prof(a). Dr(a). Sidnei Alves de Araújo	Aprovado
Prof(a). Dr(a). Peterson Adriano Belan	Aprovado
Prof(a). Dr(a). André Felipe Henriques Librantz	Aprovado
Prof(a). Dr(a). Geraldo Cardoso de Oliveira Neto	Aprovado
Prof(a). Dr(a). André Augusto Gutierrez Fernandes Beati	Aprovado


Parecer: Aprovado


Em conclusão, o candidato foi considerado **Aprovado**, no grau de Doutor em Informática e Gestão do Conhecimento. E, para constar, eu, Prof. Dr. Sidnei Alves de Araújo, professor do Programa de Mestrado e Doutorado em Informática e Gestão do Conhecimento, lavrei a presente ata que assino juntamente com os membros da banca examinadora.

São Paulo, 20 de dezembro de 2024.

Sidnei Alves de Araújo _____


Peterson Adriano Belan _____


André Felipe Henriques Librantz _____


Geraldo Cardoso de Oliveira Neto _____


André Augusto Gutierrez Fernandes Beati _____


DEDICATÓRIA

"A Deus, por acreditar que Ele esteve comigo; à minha esposa Eneli, pelo amor, paciência e compreensão nesta etapa da vida; aos meus familiares, por toda a ajuda."

AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão ao Prof. Dr. Sidnei Alves de Araújo, que, com paciência e dedicação, me orientou, aconselhou e guiou ao longo de todo o processo. Além de ser um grande amigo, esteve sempre presente, oferecendo conselhos e encorajamentos nos momentos mais desafiadores, ajudando-me a manter a motivação e a perseverança.

Ao Prof. Dr. André Felipe Henriques Librantz, pelo acompanhamento próximo, incentivo constante, e as valiosas contribuições para a realização deste trabalho.

Ao Prof. Dr. Peterson Adriano Belan, cuja assistência e orientação foram fundamentais para a conclusão desta pesquisa.

À minha esposa, Eneli, pela compreensão e apoio incondicional durante os períodos de ausência em compromissos sociais, demonstrando paciência e incentivo em cada etapa desta jornada.

Agradeço a todos os professores da ETEC de Atibaia e Bragança Paulista, bem como da FATEC de Bragança Paulista e de outras FATECs, pelo suporte e incentivo prestados ao longo da minha formação.

A todos os professores do corpo docente do PPGI, cujos ensinamentos acadêmicos foram essenciais e permanecerão comigo ao longo da minha trajetória profissional e intelectual.

Aos membros da minha família: minha mãe Maria, meu pai José, minhas irmãs Renata e Raiana, e minha filha Rebeca, pelo carinho, apoio e compreensão durante todo o percurso acadêmico.

Ao povo da Bahia, em especial Gabriel e Milton, cujas contribuições foram essenciais para o avanço desta pesquisa.

Aos membros da banca examinadora, pelas sugestões e correções que contribuíram significativamente para o aprimoramento e conclusão deste trabalho.

À Universidade Nove de Julho, pela oportunidade e pela concessão da bolsa de estudos, possibilitando a realização deste projeto.

Por fim, expresso minha sincera gratidão a todas as pessoas que direta ou indiretamente colaboraram para o desenvolvimento desta pesquisa.

RESUMO

As tecnologias para inspeção visual automática de grãos agrícolas (IVAGA), em geral, servem para analisar amostras de grãos visando classificá-los e identificar defeitos. A crescente demanda global por grãos agrícolas e a busca por eficiência nos processos produtivos têm impulsionado a pesquisa científica sobre essas tecnologias. No entanto, apesar do crescente número de estudos, especialmente na última década, são raros aqueles que discutem a aplicação dessas tecnologias na agroindústria. Além disso, o levantamento bibliográfico conduzido, que envolveu 137 trabalhos da literatura, revelou que nenhum deles abordou transferência de tecnologia. Assim, importantes lacunas do conhecimento ainda persistem nesse campo. Uma delas é a falta de compreensão sobre as motivações dos pesquisadores para proposição das tecnologias. Outra limitação reside na implementação prática em larga escala das soluções tecnológicas propostas na literatura, levando a um descompasso entre o avanço científico e sua aplicação em larga escala no setor agrícola. Assim, a presente pesquisa teve como objetivo investigar as motivações para a proposição de tecnologias de IVAGA, sua relação com as demandas do setor agrícola e os fatores que dificultam a transferência dessas tecnologias para a agroindústria. Para tanto, foram empregados os seguintes métodos qualitativos e quantitativos: revisão bibliométrica, revisão sistemática da literatura, e uma *survey* para a coleta de dados sobre conhecimento e uso das tecnologias de IVAGA, e sobre os desafios e barreiras para a transferência de tecnologia no setor agrícola. A pesquisa evidenciou a maioria das soluções de IVAGA propostas na literatura possui baixa maturidade tecnológica, exigindo adaptações para ambientes reais. Também evidenciou que as principais barreiras para a aplicação em larga escala dessas soluções tecnológicas são a falta de disseminação do conhecimento científico, a necessidade de mão de obra qualificada, os custos elevados e a resistência a mudanças nos processos. Apesar disso, a literatura destaca benefícios como automação, eficiência e redução de perdas, evidenciando um grande potencial das tecnologias de IVAGA para modernização do setor agrícola.

Palavras-chave: Inspeção Visual, Grãos, Agricultura, Agroindústria, Transferência de Tecnologia

ABSTRACT

Technologies for automatic visual inspection of agricultural grains (IVAGA), in general, are used to analyze grain samples in order to classify them and identify defects. The growing global demand for agricultural grains and the search for efficiency in production processes have driven scientific research on these technologies. However, despite the growing number of studies, especially in the last decade, few discuss the application of these technologies in the agroindustry. Furthermore, the bibliographic survey conducted, which involved 137 works in the literature, revealed that none of them addressed technology transfer. Thus, important knowledge gaps still persist in this field. One of them is the lack of understanding of researchers' motivations for proposing technologies. Another limitation lies in the large-scale practical implementation of the technological solutions proposed in the literature, leading to a mismatch between scientific advances and their large-scale application in the agricultural sector. Thus, this research aimed to investigate the motivations for proposing IVAGA technologies, their relationship with the demands of the agricultural sector and the factors that hinder the transfer of these technologies to the agroindustry. To this end, the following qualitative and quantitative methods were used: bibliometric review, systematic literature review, and a survey to collect data on knowledge and use of IVAGA technologies, and on the challenges and barriers to technology transfer in the agricultural sector. The research showed that most of the IVAGA solutions proposed in the literature have low technological maturity, requiring adaptations to real environments. It also showed that the main barriers to the large-scale application of these technological solutions are the lack of dissemination of scientific knowledge, the need for qualified labor, high costs and resistance to changes in processes. Despite this, the literature highlights benefits such as automation, efficiency and loss reduction, evidencing a great potential of IVAGA technologies for modernizing the agricultural sector.

Key words: Visual Inspection, Grains, Agriculture, Agroindustry, Technology Transfer.

LISTA DE ILUSTRAÇÕES

Figura 1. Diagrama da estrutura do trabalho	22
Figura 2. Equipamento típico x aparato usual em experimentos da literatura	26
Figura 3. Volume de publicações por grão	30
Figura 4. Volume de publicações por ano	32
Figura 5. Volume de publicações por país	32
Figura 6. Mapa de calor indicando volume de publicações por país	33
Figura 7. Produção de grãos por país	34
Figura 8. Correlação entre volume de publicação científica e volume de produção de grãos	35
Figura 9. Consumo de grãos por país (em milhões de toneladas)	36
Figura 10. Correlação entre volume de publicação científica e consumo de grãos	36
Figura 11. Ilustração do SVC desenvolvido por Antonucci <i>et al.</i> (2017)	44
Figura 12. Ilustração do SVC proposto por Payman <i>et al.</i> (2018)	44
Figura 13. Ilustração do equipamento desenvolvido por Liu <i>et al.</i> (2018)	45
Figura 14. Ilustração do SVC proposto por Shen <i>et al.</i> (2020)	46
Figura 15. Ilustração do SVC proposto por Chen <i>et al.</i> (2020)	47
Figura 16. Ilustração do SVC proposto por Belan <i>et al.</i> (2020)	48
Figura 17. Ilustração do SVC desenvolvido por Gao <i>et al.</i> (2021)	49
Figura 18. Ilustração do SVC proposto por Xu <i>et al.</i> (2021)	50
Figura 19. Ilustração do SVC desenvolvido por Fan <i>et al.</i> (2024)	51
Figura 20. Síntese metodológica	54
Figura 21. Organização das palavras-chave e suas cognatas na forma de árvore	57
Figura 22. Fluxo de seleção dos artigos de acordo o método PRISMA	58
Figura 23. Distribuição dos respondentes por grau de instrução	68
Figura 24. Distribuição dos respondentes por ramo de atividade	69
Figura 25. Respondentes cuja atividade está diretamente relacionada com produtos agrícolas	69
Figura 26. Distribuição dos respondentes por tempo de experiência no setor agrícola	70
Figura 27. Distribuição dos respondentes por nível do cargo que ocupam	70
Figura 28. Distribuição dos respondentes por tipo de produto ao qual sua atividade está relacionada	71
Figura 29. Tipos de tecnologias utilizadas no local de trabalho do respondente	72

Figura 30. Distribuição dos respondentes de acordo com seus conhecimentos sobre trabalhos propondo tecnologias para IVAGA	73
Figura 31. Percepção dos respondentes sobre a importância das tecnologias para IVAGA	73
Figura 32. Percepção dos respondentes sobre a contribuição das tecnologias de IVAGA	74
Figura 33. Percepção dos respondentes sobre fatores que desfavorecem o emprego de tecnologias para IVAGA	75
Figura 34. Percepção dos respondentes sobre os fatores mais importantes para viabilizar o emprego de tecnologias de IVAGA	77

LISTA DE TABELAS

Tabela 1. Escala da TRL	28
Tabela 2. Artigos com potencial de apresentar produtos com maior grau de maturidade tecnológica	43
Tabela 3. Palavras-chave e suas cognatas	56
Tabela 4. Expressões de busca.....	57

LISTA ABREVIATURAS E SIGLAS

2D	Imagens bidimensionais
3D	Imagens tridimensionais
A4.0	Agricultura 4.0
AM	Aprendizagem de Máquina
AP	Aprendizagem Profunda
AP	Agricultura de Precisão
BNDES	Banco Nacional de Desenvolvimento
CCD	<i>Charge-Coupled Device</i> (Dispositivo de Carga Acoplada)
CMOS	<i>Complementary Metal-Oxide-Semiconductor</i> (Semicondutor de Metal Oxido complementar)
CMP_MET	Comparação de Métodos
CNN	<i>Convolutional Neural NetWork</i> (Rede Neural Convolucional)
COR	Cor
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
EST	Estatística
FAO	<i>Food and Agriculture Organization</i> (Organização das Nações Unidas para a Alimentação e a Agricultura)
GEO	Geométricos
GPS	<i>Global Position System</i> (Sistema de Posicionamento Global)
HDW	Hardware
HIP	Hiperespectrais
I4.0	Indústria 4.0
IA	Inteligência Artificial
ICML	International Conference on Machine Learning (Conferência Internacional de Aprendizagem de Máquina)
IEEE	<i>Institute of Electrical and Electronics Engineers</i> (Instituto de Engenheiros Eletrônicos e Elétricos)
IoT	<i>Internet of Things</i> (Internet das Coisas)

IVAGA	Inspeção Visual Automática de Grãos Agrícolas
LED	<i>Light Emission Diode</i> (Diodo Emissor de Luz)
MAPA	Ministério da Agricultura e Pecuária e Abastecimento
MET	Métodos
MRL	Manufacturing Readiness Levels (<i>Manufacturing Readiness Levels</i>)
MVS	<i>Machine Vision System</i> (Sistema de visão de máquina)
NASA	<i>National Aeronautics and Space Administration</i> (Administração Nacional da Aeronáutica e Espaço)
PRISMA	<i>Preferred Reporting Items for Systematic Reviews and Meta-Analyses</i> (Principais itens para relatar Revisões sistemáticas e Meta-análises)
QUI	Químicos
RGB	<i>Red, Green e Blue</i> (Vermelho, Verde, Azul)
RHA	Representações Hierárquicas e Abstratas
RNA	Redes Neurais Artificiais
RNC	Rede Neural Convolucional
RSL	Revisão Sistemática da Literatura
SVC	Sistema de Visão Computacional
SVM	<i>Support Machine Vector</i> (Máquina de Vetores de Suporte)
TER	Imagens termais
TRL	<i>Technology Readiness Levels</i> (Níveis de Prontidão Tecnológica)
TT	Transferência tecnológica
USDA	<i>United States Department of Agriculture</i> (Departamento de Agricultura dos Estado Unidos)
VC	Visão Computacional

SUMÁRIO

1. INTRODUÇÃO	16
1.1. Contextualização do tema	16
1.2. Lacunas e questões de pesquisa	18
1.3. Objetivos.....	20
1.3.1 Objetivo geral.....	20
1.3.2 Objetivos específicos	20
1.4. Justificativa e motivação.....	20
1.5. Estrutura do trabalho.....	21
2. REVISÃO BIBLIOMÉTRICA E SISTEMÁTICA DA LITERATURA SOBRE INSPEÇÃO VISUAL AUTOMÁTICA DE GRÃOS AGRÍCOLAS	23
2.1 Conceitos fundamentais	23
2.1.1 Agricultura de Precisão, Agricultura 4.0 e Agroindústria 4.0.....	23
2.1.2 Inspeção da qualidade visual de grãos agrícolas	24
2.1.3 Inspeção visual automática de grãos agrícolas	25
2.1.4 Inovação e transferência de tecnologia	26
2.1.5 Nível de maturidade tecnológica (TRL/MRL)	28
2.2 Revisão bibliométrica.....	29
2.3 Revisão sistemática da literatura (RSL).....	38
2.3.1 Panorama da literatura sobre a temática “inspeção visual automática de grãos agrícolas”	38
2.3.2 Trabalhos da literatura propondo hardware para inspeção visual	43
3. METODOLOGIA	53
3.1 Caracterização metodológica da pesquisa.....	53
3.2 Procedimentos para o levantamento bibliográfico	54
3.2.1 Definição das bases científicas.....	55
3.2.2 Palavras-chave e composição das expressões de busca.....	56

3.2.3 Definição dos critérios de elegibilidade e análise das publicações elegíveis	58
3.3. Instrumento de coleta de dados	58
3.3.1 Aplicação e público-alvo	59
3.3.2 Descrição das perguntas	59
3.3.3 Validação e testagem	61
3.3.4 Tratamento e análise dos dados	62
3.4 Limitações da pesquisa.....	62
4. RESULTADOS E DISCUSSÕES.....	63
4.1 Análise quantitativa de padrões e correlações identificados na produção científica e tecnológica de soluções para inspeção visual automática.....	63
4.2 Potencial de aplicação, desafios e tendências das tecnologias propostas na literatura para inspeção visual automática de grãos agrícolas	65
4.2.1 Contribuições e desafios identificados na literatura	67
4.3 Demandas tecnológicas na inspeção visual da qualidade de grãos e os desafios para a transferência de tecnologia no setor agrícola brasileiro.....	67
4.3.1 Perfil socioeconômico e profissional dos respondentes.....	68
4.3.2 Conhecimentos e percepções sobre as tecnologias para inspeção visual automática de grãos e sobre as expectativas e demandas do setor agrícola.....	71
5. CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS.....	78
REFERÊNCIAS.....	84
APÊNDICE I. Artigos elegíveis identificados na literatura.....	94
APÊNDICE II. Instrumento de coleta de dados	102

1. INTRODUÇÃO

1.1. Contextualização do tema

A agroindústria desempenha um papel crucial na economia global, especialmente em países onde a agricultura é uma parte significativa do setor econômico. A expectativa de aumento da população mundial (25% até 2050 ou 9,7 bilhões) tem exigido que a agricultura evolua passando de métodos tradicionais de produção para sistemas mais avançados (WOLFERT, 2014; AYAZ *et al.*, 2019; SOTT *et al.*, 2020; UNITED NATIONS, 2022; CONAB, 2024). Em adição, a constante inovação e adoção de novas tecnologias na agroindústria têm impulsionado o crescimento do setor e contribuído para o desenvolvimento sustentável da agricultura em escala global (RÉVILLION *et al.*, 2004; SIDONIO, *et al.*, 2013; BUAINAIN *et al.*, 2021; SOTT *et al.*, 2021; AGGARWAL *et al.*, 2022).

Entre os diversos desafios enfrentados pela agroindústria destaca-se a necessidade de processos acurados de inspeção visual, imprescindíveis para garantir a qualidade dos produtos e para determinar seus preços de venda. Esses processos geralmente são conduzidos de forma manual e apresentam limitações pois dependem da subjetividade da interpretação humana, que pode levar a imprecisões, inconsistências e falta de padronização de resultados (PATIL; YADAHALLI; PUJARI, 2011; ARAÚJO *et al.*, 2015; BELAN *et al.*, 2015; BELAN *et al.*, 2018; BELAN *et al.*, 2020; MACUÁCUA *et al.*, 2023). Neste contexto, as ferramentas computacionais para automação de tarefas de inspeção visual da qualidade podem gerar diferenciais competitivos para as empresas visto que possibilitam incrementar a quantidade de itens inspecionados, além de produzirem resultados mais acurados e com maior padronização (BROSNAN e SUN, 2002; BELAN *et al.*, 2020).

A automatização de processos agrícolas tem sido de suma importância para o desenvolvimento do setor, tornando-se imprescindível com o advento da Agricultura de Precisão (AP) e da Agroindústria 4.0 (A4.0) que preconizam o uso das novas tecnologias para otimizar a tomada de decisões e melhorar os processos produtivos visando a obtenção de produtos com maior qualidade e maior respeito ao meio ambiente (MASSRUHÁ e LEITE, 2017; AUDU e AREMU, 2021).

Enquanto a AP se concentra na otimização dos recursos agrícolas por meio do emprego de tecnologias de geolocalização e de sensoriamento remoto, a Agricultura 4.0 (A4.0) vai além, buscando a transformação digital completa dos sistemas agrícolas por meio da integração de tecnologias avançadas de automação, análise de dados e

conectividade, entre as quais podemos citar Internet das Coisas (*Internet of Things – IoT*), Big Data, Computação em Nuvem (*Cloud Computing*), Inteligência Artificial (IA) e Visão Computacional (VC). Cabe destacar que AP e A4.0 têm sido amplamente discutidas quando o assunto é o enfrentamento dos desafios relacionados à produção agrícola.

No contexto da A4.0, o emprego de VC combinada com IA tem propiciado o desenvolvimento de sistemas inteligentes para inspeção visual automática de produtos agrícolas, desde a etapa de plantio até a etapa de pós-colheita. Um exemplo é a inspeção visual de grãos na etapa de pós-colheita.

Os grãos constituem a base de diversas cadeias alimentares, fornecendo nutrientes essenciais para bilhões de pessoas ao redor do planeta (MAPA, 2015; EMBRAPA 2020, BELAN, 2020). Não obstante, os grãos representam 91% de todas as culturas plantadas no mundo, sendo China, EUA, Índia e Brasil responsáveis por mais de 50% da produção mundial. Só em 2021 a produção de grãos foi superior a 3 bilhões de toneladas. Neste mesmo ano o Brasil exportou cerca de 130 milhões de toneladas de grãos, representando quase 6% do total comercializado no planeta (EMBRAPA, 2020).

Dada a importância dos grãos agrícolas, a eficiência na sua produção e beneficiamento é crucial para atender à crescente demanda e garantir estabilidade econômica e social, ressaltando a importância contínua de investimentos em pesquisa, tecnologia agrícola e práticas sustentáveis (NETO *et al.*, 2018; FONSECA *et al.*, 2024; BUAINAIN *et al.*, 2024; BANEAS *et al.*, 2024).

A inspeção da qualidade de grãos agrícolas desempenha um papel fundamental na produção de alimentos, garantindo que os grãos atendam aos padrões de qualidade estabelecidos para sua comercialização e consumo. Além de contribuir para a segurança alimentar e a saúde pública, a inspeção da qualidade de grãos agrícolas também tem impacto direto na economia, influenciando os preços de commodities agrícolas, o comércio internacional e a competitividade dos produtores no mercado global. Portanto, é uma prática essencial para garantir a integridade e a sustentabilidade da indústria agrícola em todo o mundo (FAN *et al.*, 2024).

De um modo geral, as avaliações físicas envolvem a verificação de características como tamanho, forma, cor e integridade dos grãos. As avaliações químicas incluem a análise de teores de umidade, proteínas, lipídios, fibras e outros constituintes químicos importantes. Já as avaliações biológicas envolvem a identificação e análise de organismos vivos que podem estar presentes nos grãos

agrícolas, como fungos, bactérias, insetos e outros microrganismos. Essas análises visam identificar possíveis contaminações biológicas que possam comprometer a qualidade e a segurança dos grãos, bem como avaliar a presença de patógenos que possam representar riscos à saúde humana ou animal (MAPA, 2015; ARAÚJO *et al.*, 2015; ALI *et al.*, 2021; DIM *et al.*, 2024). Soma-se à essas avaliações a inspeção visual dos grãos que leva em conta parâmetros como tamanho e cor, e a presença de danos externos, insetos, folhas, galhos ou organismos indesejados nos grãos legalmente instituídos por normativas (feijão 12/2008, milho 60/2011, soja 11/2007 e sorgo portaria 268/1984) (MAPA, 2008; MAPA, 2015; EMBRAPA, 2008).

A importância dos grãos agrícolas e a necessidade de processos produção eficientes para atender à demanda mundial justificam os investimentos em pesquisa e desenvolvimento de tecnologias que visam práticas sustentáveis. Assim, a produção científica acerca da temática “inspeção visual automática de grãos agrícolas” (IVAGA) tem crescido muito nas últimas duas décadas. De acordo com o levantamento bibliográfico realizado neste trabalho envolvendo 137 artigos publicados em periódicos no período de 2015 a 2024, há aplicações para classificação e identificação de variedades, como nos trabalhos de Qadri *et al.* (2021), Lin *et al.* (2018) e Belan *et al.* (2020); para detecção de defeitos e análise de qualidade, como relatado em Fan *et al.* (2024) e Belan *et al.* (2020); e para suporte à tomada de decisão em processos produtivos (ANTONUCCI *et al.*, 2017, RATHNAYAKE *et al.*, 2023).

1.2. Lacunas e questões de pesquisa

É inegável que a integração de métodos computacionais e hardware avançado está revolucionando a agricultura, contribuindo para tornar os processos de inspeção visual mais sustentável, aumentando a competitividade do setor e a qualidade na produção de alimentos. No entanto, embora os autores frequentemente destaquem as inovações tecnológicas introduzidas, especialmente no que se refere ao desenvolvimento de algoritmos (ARAÚJO *et al.*, 2015; HUANG *et al.*, 2016; HUANG *et al.*, 2022; FAN *et al.*, 2024), combinações de métodos computacionais (HE *et al.*, 2023; YASAR, 2024) e soluções passíveis de adaptação ou integração ao ambiente industrial (ANTONUCCI *et al.*, 2017; CHEN *et al.*, 2020; BELAN *et al.*, 2020; FAN *et al.*, 2024), poucos estudos abordam de maneira explícita a aplicação dessas soluções no contexto industrial. Ademais, verifica-se que nenhum dos trabalhos da literatura considerada nesta pesquisa discutiu questões relacionadas à transferência de tecnologia.

Primeiro, há uma lacuna significativa em relação ao entendimento das motivações dos pesquisadores por trás da proposição dos métodos computacionais e hardware para IVAGA. Enquanto muitos estudos focam na eficácia técnica e na precisão das tecnologias de inspeção, menos atenção é dada às razões que impulsionam os pesquisadores a desenvolverem tais tecnologias. As motivações podem variar amplamente, desde a busca por maior eficiência na cadeia de produção agrícola (YOOSEFZADEH-NAJAFABADI *et al.*, 2021; HOSSEN *et al.*, 2022; CHEN *et al.*, 2020; BELAN *et al.*, 2020) até a redução de desperdícios e a melhoria da qualidade dos produtos (WERKEMA, 2011; SANTOS, *et al.*, 2020). Compreender essas motivações pode ser um ponto de partida para direcionar futuras pesquisas, no sentido de alinhar as soluções propostas às demandas e desafios enfrentados pelos agricultores e pela indústria agrícola em escala global. Além disso, a análise das motivações pode fornecer *insights* valiosos sobre as prioridades de pesquisa e desenvolvimento em diferentes regiões do mundo, considerando a variação na produção e consumo de grãos entre países.

Outra importante lacuna está relacionada ao fato de que embora as pesquisas tenham levado ao desenvolvimento de algoritmos e sistemas computacionais capazes de identificar padrões, classificar e detectar defeitos em grãos de forma automatizada, a implementação prática dessas soluções em larga escala ainda é limitada (BELAN *et al.*, 2020; AZMI *et al.*, 2021; HU *et al.*, 2022). Questões como custo, complexidade técnica e adaptação às condições reais do ambiente de produção agrícola podem estar entre os desafios que impedem a implementação e comercialização em larga escala dessas tecnologias. Portanto, embora exista um grande potencial para a inspeção visual automatizada de grãos agrícolas, nota-se um descompasso entre as soluções propostas na literatura e suas aplicações efetivas na indústria agrícola. Nesse contexto emergem as seguintes questões de pesquisa:

- Q1: O volume de pesquisa científica sobre inspeção visual automática dos principais grãos reflete suas relevâncias no mercado global?
- Q2: Qual é a maturidade tecnológica das soluções de inspeção visual automática de grãos e quais barreiras impedem sua adoção na indústria agrícola?

1.3. Objetivos

1.3.1 Objetivo geral

Investigar as motivações para a proposição de tecnologias para inspeção visual automática de grãos agrícolas, sua relação com as demandas do setor agrícola e os fatores que dificultam a transferência dessas tecnologias para a agroindústria.

1.3.2 Objetivos específicos

- O1: Sintetizar o estado atual do conhecimento sobre a temática, empregando revisão bibliométrica, para identificar os grãos mais beneficiados pelas tecnologias de inspeção visual agrícola, a evolução ao longo do tempo, a distribuição geográfica da pesquisa e as tendências;
- O2: Investigar possíveis correlações entre a produção e/ou consumo de grãos e a quantidade de publicações científicas sobre inspeção visual automática nos países mais ativos nesse campo de pesquisa, também utilizando-se da revisão bibliométrica;
- O3: Conduzir uma análise abrangente da literatura científica, por meio da revisão sistemática da literatura (RSL), para mapear as principais aplicações de IVAGA e classificá-las conforme seu grau de maturidade tecnológica;
- O4: Investigar, a partir da *survey*, os desafios e limitações para a implementação em larga escala tecnologias de IVAGA propostas na literatura.

1.4. Justificativa e motivação

As pesquisas sobre IVAGA são importantes para elevar a eficiência e a qualidade na produção agrícola, visto que as soluções propostas permitem identificar defeitos, impurezas e contaminações nos grãos, contribuindo para a redução de desperdícios, e a padronização dos produtos de acordo com critérios de qualidade. Além disso, o desenvolvimento de soluções inovadoras impulsiona o avanço tecnológico no setor agrícola, promovendo práticas mais sustentáveis e contribuindo para uma produção agrícola responsável (DIAS *et al.*, 2023; ZAPAROLLI, 2020).

É razoável pensar que países com uma indústria agrícola mais desenvolvida ou que são grandes consumidores ou produtores de grãos tendem a investir mais em pesquisa e desenvolvimento relacionados à tecnologia agrícola, incluindo métodos de IVAGA (DIAS *et al.*, 2023). No entanto, outros fatores, como políticas governamentais e colaborações internacionais podem influenciar o volume de publicações científicas em um determinado campo (DE SOUZA, 2018). Assim, a compreensão das

motivações por trás da proposição de tecnologias de IVAGA permite identificar as necessidades e demandas dos pesquisadores, da indústria agrícola e de outros stakeholders envolvidos, o que pode orientar o desenvolvimento de soluções mais adequadas e eficazes. Não obstante, entender os fatores que dificultam a transferência dessas tecnologias para a agroindústria ajuda a identificar potenciais obstáculos e desafios que podem prejudicar a implementação bem-sucedida dessas soluções. Isso permite direcionar recursos e esforços para superar esses obstáculos de forma mais eficiente.


Esta pesquisa pode contribuir para o avanço do conhecimento científico ao fornecer *insights* sobre as motivações e desafios relacionados à aplicação de tecnologias de IVAGA. Essas informações podem ser úteis para pesquisadores, profissionais e tomadores de decisão interessados em melhorar a eficiência e a sustentabilidade da produção agrícola.

Ao compreender melhor as motivações e os obstáculos relacionados à adoção de tecnologias de IVAGA, a pesquisa pode contribuir para a promoção de práticas mais eficazes e sustentáveis na agroindústria, com potencial para melhorar as tecnologias de inspeção visual, bem como a qualidade, segurança e eficiência da produção agrícola.

1.5. Estrutura do trabalho

A estrutura deste trabalho está ilustrada na Figura 1. O primeiro capítulo apresenta a contextualização do tema investigado; as lacunas e questões de pesquisa; os objetivos e, por fim, a justificativa e motivação da pesquisa. Em seguida, no Capítulo 2, os conceitos fundamentais ao entendimento desta pesquisa, quais sejam: agricultura, agroindústria, Agricultura de Precisão e Agroindústria 4.0; inspeção da qualidade visual de grãos agrícolas; inspeção visual automática de grãos agrícolas, transferência de tecnologia e nível de maturidade tecnológica. Além disso, estão apresentadas ainda as revisões bibliométrica e sistemática da literatura sobre inspeção visual automática de grãos agrícolas. O Capítulo 3 contempla a metodologia empregada na realização da pesquisa. No Capítulo 4 são apresentados os resultados e discussões. Por fim, o Capítulo 5 discorre sobre as conclusões e as sugestões para trabalhos futuros.

Figura 1. Diagrama da estrutura do trabalho



Fonte: Autor

2. REVISÃO BIBLIOMÉTRICA E SISTEMÁTICA DA LITERATURA SOBRE INSPEÇÃO VISUAL AUTOMÁTICA DE GRÃOS AGRÍCOLAS

Neste capítulo, primeiro são apresentados os conceitos teóricos fundamentais para o entendimento da temática tratada na pesquisa. Na sequência são apresentadas as revisões bibliométrica e sistemática da literatura com intuito de reunir, sintetizar e analisar padrões e tendências em publicações científicas relacionadas à temática investigada.

2.1 Conceitos fundamentais

2.1.1 Agricultura de Precisão, Agricultura 4.0 e Agroindústria 4.0

A Agricultura de Precisão (AP) pode ser definida como uma abordagem tecnológica que utiliza dados e ferramentas avançadas, como sensores, GPS, drones e softwares de análise, para monitorar e gerenciar variáveis agrícolas de forma precisa e em tempo real. Seu objetivo é otimizar o uso de recursos (água, fertilizantes, defensivos, etc.), aumentar a produtividade, reduzir custos e minimizar impactos ambientais. Ao permitir decisões baseadas em informações detalhadas e específicas de cada área de cultivo, a AP promove uma gestão mais eficiente e sustentável das atividades agrícolas (BASSOI, 2019; CATANEO e CAVICHIOLI, 2024).

A AP é uma das tendências atuais para superar os desafios apontados, pois recomenda a aplicação de sistemas automatizados em tarefas como irrigação, processamento, armazenamento e transporte de produtos agrícolas. No entanto, o termo AP aparece na literatura intimamente relacionado a tarefas de preparo do solo, plantio e colheita. Em um contexto mais amplo, e mais relacionado à Indústria 4.0, destacam-se os termos Agronegócio 4.0, Agricultura 4.0 e Agroindústria 4.0, que sinalizam um novo marco no desenvolvimento do setor agrícola e que, sem dúvida, promoverão mudanças importantes nos próximos anos. Essas mudanças envolvem o uso massivo de diferentes tecnologias, como Internet das Coisas (IoT), Computação em Nuvem e Aprendizado de Máquina, para desenvolver processos mais inteligentes, otimizar a tomada de decisões e melhorar os processos produtivos, resultando na produção de produtos de maior qualidade e com respeito ao meio ambiente (FONSECA *et al.*, 2016; SCHWAB, 2019).

Muito se fala sobre as diversas tecnologias utilizadas no preparo do solo, plantio e colheita, mas pouco se discute sobre o beneficiamento de produtos agrícolas,

como os processos automatizados de inspeção visual de grãos. É nesse contexto que este trabalho se insere explorando as soluções propostas para a inspeção visual automatizada de grãos. Muitas dessas abordagens foram testadas apenas no campo teórico e poderiam ser aplicadas no contexto da Agroindústria 4.0, em ambientes reais de produção agrícola, agregando valor aos produtos destinados ao consumidor final.

2.1.2 Inspeção da qualidade visual de grãos agrícolas

A qualidade dos produtos agrícolas no Brasil tem como uma das bases reguladoras a Lei nº 9.972, de 25 de maio de 2000, a qual designa as normas do Ministério da Agricultura, Pecuária e Abastecimento (MAPA, 2021) como padrões oficiais para inspeção e classificação de produtos vegetais, entre os quais estão os grãos de arroz, feijão, milho, soja e trigo.

As tarefas de inspeção de grãos visam assegurar que os produtos estejam livres de odores anormais, umidade, corpos estranhos, impurezas, infestações de pragas e danos mecânicos, garantindo que eles cheguem em plenas condições até o consumidor (EMBRAPA, 2008; MAPA, 2015; EMBRAPA, 2015). Obviamente, quanto menor o número de defeitos encontrados, maior será o valor de mercado do produto.

A inspeção visual de grãos de feijão, por exemplo, é conduzida de forma manual a partir de uma amostra de no mínimo 1 Kg extraída de um lote do produto. Para tanto, primeiro separam-se os objetos estranhos como insetos, pedras e impurezas, utilizando-se uma peneira de crivos circulares com cinco milímetros de diâmetro. Depois disso, determina-se o Grupo, a Classe e o Tipo do feijão. O Grupo está relacionado à espécie botânica; a Classe é determinada de acordo com a coloração das películas dos grãos (Preto, Branco, Cores ou Misturado), independente do grupo. Por fim, o Tipo é definido de acordo com os limites máximos de tolerância de defeitos (ardidos, mofados, carunchados, germinados, impurezas, e matérias estranhas) encontrados na amostra inspecionada (EMBRAPA, 2008).

Os principais problemas associados ao processo manual de inspeção da qualidade são a alta probabilidade de ocorrência de erros, devido à fadiga visual, o alto custo do processo, e a dificuldade de padronização dos resultados (ARAÚJO *et al.*, 2015; PATIL; YADAHALLI; PUJUARI, 2011; BELAN *et al.*, 2020).

2.1.3 Inspeção visual automática de grãos agrícolas

Visão computacional (VC) consiste em um campo da ciência da computação responsável pelo estudo e desenvolvimento de sistemas computacionais voltados para interpretação de imagens digitais. Assim, a finalidade de um sistema de visão computacional (SVC) é fazer com que um computador imite algumas capacidades do sistema visual humano, como a habilidade de descrever e interpretar o conteúdo de uma imagem (GONZALEZ e WOODS, 2002).

Um SVC eficiente deve ser capaz de extrair um conjunto de características que descrevem com precisão os elementos de uma imagem, que seja compacto o suficiente para reduzir o tempo de processamento de forma a viabilizar a implementação de aplicações que possam ser empregadas na prática, por exemplo, em veículos autônomos, em sistemas de vigilância, em reconhecimento de padrões biométricos e na inspeção visual de produtos industriais e agrícolas (GONZALEZ e WOODS, 2002).


SVCs permitem reconhecer padrões associados aos produtos agrícolas, de forma que o produtor possa avaliar uma amostra de sua colheita e determinar a qualidade do produto, além de possibilitar a identificação de defeitos e pragas que necessitem do uso de defensivos agrícolas e/ou mudanças no manejo do plantio.

O uso da tecnologia de VC traz precisão na inspeção de uma grande variedade de produtos que podem ser analisados em um curto período, além de otimização de recursos humanos e redução dos custos de produção (XING *et al.*, 2021). Não obstante, VC tem se tornado uma das tecnologias habilitadoras da I4.0 e da A4.0, sendo amplamente utilizada nas indústrias, laboratórios, lavouras e cooperativas para automatizar as tarefas de inspeção da qualidade de produtos, principalmente aqueles cujas aparências visuais determinam qualidade para o consumo e preços de mercado.

Um SVC típico para inspeção visual de grãos é composto por um conjunto de software e hardware, como o ilustrado na Figura 2a, que contempla câmara de aquisição de imagens (1), alimentador de grãos (2), esteira (3), dispensador de grãos (4), motor de passo para movimentação da esteira (5) e um computador que executa o software de análise de imagens e controla o hardware (6). Contudo, a maioria dos estudos da literatura emprega um protótipo (ou aparato) mais simples na condução de experimentos, como ilustrado na Figura 2b, que é constituído por uma câmara (caixa ou receptáculo) para controle da iluminação, câmera digital para a captura de imagens, uma base com cor que facilite a remoção do fundo nas imagens, e um

computador para controlar o aparato além de executar o algoritmo proposto para análise. Há ainda estudos que empregam um scanner para aquisição de imagens no lugar do hardware

Figura 2. Equipamento típico x aparato usual em experimentos da literatura



2.1.4 Inovação e transferência de tecnologia

Inovação pode ser definida como um processo de criação, aprimoramento ou aplicação de novas ideias, métodos ou tecnologias para gerar valor e impacto significativo em produtos, serviços ou processos (BNDES, 2024). Vai além da invenção, e envolvendo a implementação prática de soluções que trazem melhorias mensuráveis, seja em eficiência, qualidade ou competitividade. No contexto industrial, a inovação é essencial para promover adaptação a mudanças, atender demandas do mercado e impulsionar o desenvolvimento sustentável (SCHWAB, 2015).

A Inovação Aberta é um modelo de gestão da inovação baseado na colaboração entre empresas, universidades, *startups*, governos e consumidores para o desenvolvimento de novas soluções, produtos e serviços (SCHWAB, 2015). Diferente da inovação tradicional, que ocorre de maneira fechada dentro dos limites de uma organização, a inovação aberta incentiva o compartilhamento de conhecimento, tecnologias e recursos, acelerando o processo de inovação e aumentando sua eficiência. Esse conceito destaca que as organizações podem se beneficiar tanto da incorporação de ideias externas, como trabalhos acadêmicos e pesquisas, quanto da comercialização de suas próprias inovações para outros mercados, promovendo um ecossistema mais dinâmico e competitivo (SCHWAB, 2015).

A transferência de tecnologia (TT) é o termo que indica a relação universidade-empresa é um assunto novo no Brasil e emergente no âmbito internacional. Assim, cresce a importância da compreensão do processo de transferência de tecnologia, caracterizado pela passagem de conhecimentos gerados pela universidade a uma empresa que lhe permitem inovar e ampliar sua capacidade tecnológica, possibilitando-lhe obter uma vantagem competitiva no mercado (CLOSS e FERREIRA, 2012). Ainda segundo Reisman (2005) tão importante quanto publicar pesquisas em uma área do conhecimento é revisar sistematicamente a totalidade dessa produção para a consolidação de conhecimentos.

A transferência de tecnologia é essencial para o progresso econômico, social e ambiental, tanto no contexto global quanto no Brasil. No cenário internacional, ela promove a disseminação de inovações entre países, permitindo que regiões em desenvolvimento acessem tecnologias avançadas de países mais industrializados. Isso contribui para a redução de desigualdades globais, acelera a modernização industrial, fomenta a pesquisa colaborativa e estimula soluções para desafios globais, como mudanças climáticas e crises de saúde (CARVALHO, 2019; DIAS *et al.* 2023; SILVA, 2023).

No Brasil, a transferência de tecnologia desempenha um papel estratégico no fortalecimento da economia e no aumento da competitividade global. Em setores como agronegócio, energia renovável e indústria, o acesso a tecnologias de ponta eleva a produtividade, incentiva a criação de empregos qualificados e impulsiona o desenvolvimento sustentável. Além disso, parcerias entre universidades, institutos de pesquisa e empresas nacionais são cruciais para internalizar inovações, promovendo a autonomia tecnológica e reduzindo a dependência de importações (SCHWAB, 2016; ALVES *et al.*, 2015).

No contexto social, a transferência de tecnologia também possibilita melhorias em áreas como saúde, educação e infraestrutura, ampliando o acesso a soluções modernas e contribuindo para o bem-estar da população. Em suma, a transferência de tecnologia é um motor indispensável para o avanço econômico, o fortalecimento da soberania tecnológica e a construção de sociedades mais equitativas no Brasil e no mundo (SINGH 2020).

2.1.5 Nível de maturidade tecnológica (TRL/MRL)

O “*Technology Readiness Levels*” (TRL) ou MRL “*Manufacturing Readiness Levels*”, um índice criado pela *National Aeronautics and Space Administration* (NASA). O TRL também conhecido como “Nível de Maturidade Tecnológica”, que basicamente é uma escala para avaliar o grau de inovação tecnológica muito utilizado no ecossistema de pesquisa, desenvolvimento e inovação (MANKINS, 1995; HÉDER, 2017).

Esse índice recentemente foi oficializado através da publicação em Diário Oficial da União em 17 de outubro de 2022 Ed. 199, Seção 1, Página 31. Dispondo sobre seu uso no âmbito tecnológico do Ministério da Ciência dos projetos desenvolvidos.

Tal índice compreende níveis variando de 1 a 9, conforme indicado na Tabela 1. O nível TRL - 1 sinaliza apenas um conceito ou produto em uma fase “embrionária”, enquanto TRL - 9 representa produto, ideia ou técnica pronta para ser utilizada pelo mercado, ou em ambiente de produção real.

Tabela 1. Escala da TRL

TRL	DESCRIÇÃO
1	Ideia da pesquisa que está sendo iniciada e esses primeiros indícios de viabilidade estão sendo traduzidos em pesquisa e desenvolvimento futuros.
2	Os princípios básicos foram definidos e há resultados com aplicações práticas que apontam para a confirmação da ideia inicial.
3	Em geral, estudos analíticos e/ou laboratoriais são necessários nesse nível para ver se uma tecnologia é viável e pronta para prosseguir para o processo de desenvolvimento. Nesse caso, muitas vezes, é construído um modelo de prova de conceito.
4	Coloca-se em prática a prova de conceito, que consiste em sua aplicação em ambiente similar ao real, podendo constituir testes em escala de laboratório.
5	A tecnologia deve passar por testes mais rigorosos do que a tecnologia que está apenas na TRL 4, ou seja, validação em ambiente relevante de componentes ou arranjos

	experimentais, com configurações físicas finais. Capacidade de produzir protótipo do componente do produto.
6	A tecnologia constitui um protótipo totalmente funcional ou modelo representacional, sendo demonstrado em ambiente operacional (ambiente relevante no caso das principais tecnologias facilitadoras).
7	O protótipo está demonstrado e validado em ambiente operacional (ambiente relevante no caso das principais tecnologias facilitadoras).
8	A tecnologia foi testada e qualificada para ambiente real, estando pronta para ser implementada em um sistema ou tecnologia já existente.
9	A tecnologia está comprovada em ambiente operacional (fabricação competitiva no caso das principais tecnologias facilitadoras), uma vez que já foi testada, validada e comprovada em todas as condições, com seu uso em todo seu alcance e quantidade. Produção estabelecida.

Adaptado (MANKINS, 1995)

Ao oferecer uma visão clara sobre o estágio de desenvolvimento de uma tecnologia, o TRL facilita a comunicação entre pesquisadores, empresas e financiadores, promovendo tomadas de decisão mais eficazes. No Brasil e no mundo, o uso do TRL é especialmente relevante para alinhar esforços tecnológicos com demandas de mercado e políticas públicas, garantindo maior eficiência na alocação de recursos e aumentando a competitividade em setores estratégicos. Assim, o TRL não apenas apoia o avanço tecnológico, mas também contribui para a sustentabilidade e a inovação contínua em diversas áreas (VERAS *et al.*, 2017).


2.2 Revisão bibliométrica

A revisão bibliométrica na presente pesquisa teve como finalidade o atingimento dos objetivos específicos 1 e 2, quais sejam: O1) identificar tendências, evolução ao longo do tempo, e distribuição geográfica da pesquisa; O2) Investigar possíveis correlações entre a produção e/ou consumo de grãos e a quantidade de publicações científicas sobre inspeção visual automática nos países mais ativos nesse campo de pesquisa;

Empregando os procedimentos metodológicos detalhados na seção 3.2, que incluem definição das palavras-chave e composição das expressões de busca, definição dos critérios de elegibilidade e análise das publicações elegíveis, foram identificados 137 trabalhos na literatura da última década propondo tecnologias para inspeção visual automática dos 5 grãos mais consumidos/produzidos no mundo (arroz, trigo, milho, soja e feijão).

O histograma da Figura 3 mostra o número de trabalhos publicados por tipo de grão. Como pode ser visto, dos 137 artigos elegíveis, 43% (59) propuseram soluções voltadas para o arroz, seguido pelo milho, com 18% (26) dos artigos favorecendo o grão. O trigo foi abordado em 28% (39) dos estudos, enquanto o feijão, apesar de ser o grão mais consumido no Brasil, correspondeu a apenas 7% (10) das pesquisas. A soja foi contemplada em 5% (7) dos trabalhos.

Figura 3. Volume de publicações por grão



Fonte: Autor

A elevada quantidade de artigos científicos para soluções automatizadas de inspeção da qualidade visual do arroz pode ser atribuída à sua posição como um dos cereais mais cultivados e consumidos globalmente, principalmente considerando a população da China (1,4 bilhão de habitantes), sendo a principal fonte de nutrientes para mais de 50% da população mundial. O Brasil participa com 2% da produção mundial do grão (FAO, 2022).

O trigo, contando com 39 trabalhos publicados, é a base para produção de diversos alimentos, incluindo pão e massas. Sua produção requer condições climáticas específicas como as da China, União Europeia, Índia e Rússia (USDA, 2024). O interesse científico acerca desse grão provavelmente está relacionado ao aumento de estudos sobre resistência a pragas, doenças e dificuldades ambientais, além de práticas agrícolas mais sustentáveis. Em 3º lugar aparece o milho, amplamente utilizado tanto para consumo humano quanto animal, contemplado em


26 trabalhos. A quantidade de publicações relacionadas à este grão pode estar diretamente relacionada à sua produção e consumo, principalmente nos países com maior relevância no setor agrícola.

Como o feijão tem menor impacto global, ele recebe menos atenção comparado a grãos como arroz, trigo e milho que possuem um peso econômico muito maior na cadeia alimentar e comercial mundial. Por fim, o reduzido número de publicações relacionadas à soja pode ser atribuído ao fato da sua inspeção visual não ser o principal critério de qualidade. Além disso, como a soja passa por maior processamento industrial, a necessidade de controle visual na pós-colheita é reduzida, limitando o interesse em pesquisas na temática considerada.

Cabe destacar que o somatório de trabalhos mostrados no gráfico da Figura 3, (141) é diferente da quantidade de artigos encontrados na literatura (137) em virtude de alguns trabalhos abordarem mais de um grão, como em Fan *et al.*, (2024), que consideraram arroz, trigo e sorgo; Qin *et al.* (2022), que contemplaram o arroz, trigo e milho, além de Tuates *et al.* (2016), que consideraram arroz e milho nos experimentos.

O histograma da Figura 4 mostra a distribuição das publicações científicas entre janeiro de 2015 e outubro de 2024. Ele evidencia que entre os anos de 2017 e 2022 houve um aumento expressivo no número de publicações, mesmo considerando o período de pandemia. Esse fenômeno pode ter relação com o crescimento da Indústria 4.0, que, durante esse período, estimulou uma ampla gama de estudos sobre a aplicação da automação e do uso de tecnologias avançadas, como IA, robótica e Internet das Coisas (IoT), no setor agrícola (SCHWAB, 2016). Esse aumento também reflete o avanço tecnológico e o crescente interesse em soluções automáticas para inspeção de qualidade, impulsionado pela demanda por maior eficiência no controle de qualidade de grãos. Os picos de publicações em 2022 e 2023 (28 e 27 trabalhos) podem ter sido influenciados pela liberação de trabalhos que estavam “represados” durante o período de restrições impostas pela pandemia de COVID-19. Já o número reduzido de publicações em 2024 é explicado pelo fato de as buscas nas bases científicas terem sido encerradas no mês de outubro desse ano.


Figura 4. Volume de publicações por ano



Fonte: Autor

O gráfico de Pareto mostrado na Figura 5 ilustra um panorama do volume publicações de artigos científicos por país. A linha vermelha reflete o volume acumulado de publicações e permite verificar, por exemplo, que China, Índia, Turquia, Brasil e Irã respondem por quase 60% das publicações.

Figura 5. Volume de publicações por país



Fonte: Autor


A China é líder em número de publicações (35), muito provavelmente devido ao fato de que esse país é um dos maiores produtores e consumidores de grãos no mundo, além dos constantes investimentos em pesquisa agrícola e tecnologias de inspeção visual automática de grãos (IVAGA). A Índia vem em segundo lugar com 21 publicações. Seu interesse acadêmico pela temática pode ser motivado pela necessidade de soluções inovadoras para lidar com desafios relacionados à pragas e mudanças climáticas, bem como pela necessidade de aumentar a produção de grãos para consumo de sua enorme população.

A Turquia e o Brasil com 8 e 7 publicações também se destacam. O Brasil é o maior exportador mundial de soja e um grande produtor de milho, segundo dados da (CONAB, 2024). Já a Turquia, por sua posição estratégica entre Europa e Ásia, tem investido em tecnologias para otimizar o uso de recursos naturais na agricultura (Turkpidya, 2024). Irã e Tailândia com 7 e 6 publicações, respectivamente demonstram interesse em tecnologias para IVAGA, mais focada em grãos específicos de relevância local.

Com relação aos EUA, que contribuem com apenas 4 artigos, o baixo volume de publicações pode estar relacionado com a utilização de métodos mais avançados, como espectroscopia e sensores, para avaliar a qualidade dos grãos. Além disso, a rigorosa padronização do USDA (*United States Department of Agriculture*) e o foco na produção em larga escala podem reduzir a necessidade de inspeção visual detalhada. A pesquisa americana prioriza automação agrícola, melhoramento genético e Agricultura de Precisão, enquanto a aparência visual dos grãos é menos relevante, visto que grande parte da produção é processada ou exportada. Assim, a baixa demanda por esse tipo de inspeção pode justificar o baixo número de estudos.

A Figura 6 ilustra um mapa de calor com um panorama da distribuição de publicações de artigos no mundo, destacando a concentração de pesquisas na Ásia e partes da Europa, enquanto a África possui contribuições limitadas. Com a globalização do conhecimento, é provável que colaborações entre países líderes, como China e Índia promovam a disseminação de tecnologias voltadas para inspeção visual de grãos (SCHWAB, 2016).

Figura 6. Mapa de calor indicando volume de publicações por país




Fonte: Autor

Dos quatro primeiros países com maiores volumes de publicações, três (China, Índia e Brasil) estão entre os principais produtores e consumidores de grãos do mundo, o que pode estimular pesquisas voltadas para inspeção e qualidade do produto, assim como a busca por eficiência e redução de perdas na cadeia de produção. Os gráficos das figuras 7 a 10 ajudam mitigar as correlações entre volume de publicações científicas e volumes de produção e de consumo de grãos.

O gráfico da figura 7 apresenta a distribuição da produção de arroz, trigo, milho, soja e feijão, em milhões de toneladas, por país. A linha vermelha indica o percentual e o volume de produção acumulados.

Figura 7. Produção de grãos por país



Fonte: Autor


A China lidera a produção agrícola, ultrapassando 700 milhões de toneladas o que reflete o consumo de arroz e trigo como alimentos básicos para atender à sua grande população, além da necessidade de avanços em tecnologias agrícolas. Os Estados Unidos respondem por uma produção acima de 500 milhões de toneladas, também se destacando como um dos maiores produtores de milho e soja, culturas amplamente usadas para consumo humano e animal, bem como para exportação (FAO, 2024). A Índia e o Brasil se incluem entre as potências agrícolas, sendo a Índia com aproximadamente 400 milhões de toneladas e Brasil com 300 milhões de toneladas. O Brasil é ainda o maior exportador de soja e um dos principais produtores de milho (FAO, 2024, CONAB, 2023).

Percebe-se uma menor produção em países da Europa e África. Vale lembrar que entre 2022 e 2024 a Europa foi palco de uma série de protestos liderados por agricultores em diversos países como França, Alemanha, Espanha, Grécia, Bulgária, Polônia, Romênia, Eslováquia, Hungria, Holanda e Bélgica, os quais buscavam

chamar a atenção para os desafios que estavam enfrentando e para pressionar por políticas que equilibrem a sustentabilidade ambiental com a viabilidade econômica do setor agrícola (BBC NEWS BRASIL, 2025). Coreia do Sul, Belarus, Alegria, Equador, Malásia, Bélgica, Taiwan, Zimbabue e Arábia Saudita não possuem um valor significativo de produção agrícola dos grãos considerados na pesquisa, sendo que alguns deles dependem de importação de outros países para o consumo interno (GIUSTI, 2024).


O gráfico da Figura 8 ilustra a correlação entre a publicação de trabalhos científicos (valores no eixo horizontal) e a produção agrícola (valores no eixo vertical). Ele indica a existência de correlação $R^2=0,5827$ que, de acordo com a classificação indicada em Cohen (2013), pode ser interpretada como forte. Os pontos concentrados na parte inferior esquerda do gráfico indicam baixa produção agrícola correlacionada com baixo volume de publicações. Alguns países como China, Índia e Brasil, representados por pontos localizados na parte superior direita do gráfico, se destacam pela alta produção de grãos correlacionada com alto volume de publicações científicas. Isso pode estar relacionado ao fato desses países possuírem relevância econômica e/ou tecnológica no cenário mundial.

Figura 8. Correlação entre volume de publicação científica e volume de produção de grãos



Fonte: Autor


O gráfico da Figura 9 mostra o consumo de arroz, trigo, milho, soja e feijão, por país. A linha vermelha indica o percentual e o volume de consumo cumulativos.

Figura 9. Consumo de grãos por país (em milhões de toneladas)

Fonte: Autor

China, EUA, Índia e Brasil são grandes consumidores de arroz, trigo, soja, milho e feijão devido à alta população, hábitos alimentares, grande produção agrícola, demanda industrial e pecuária, além de políticas de segurança alimentar. A interseção entre produção e consumo nesses países fortalece sua posição como líderes no mercado global de grãos.

O gráfico da Figura 10 mostra que o volume de publicações científicas sobre IVAGA apresenta uma correlação forte ($R^2=0,7178$) com os volumes de consumo desses grãos. A exemplo do gráfico da Figura 10, a maioria dos pontos está concentrada na parte inferior esquerda do gráfico, indicando consumo agrícola correlacionado com baixo volume de publicações científicas. Novamente, países como China, Índia e Brasil se destacam pelos altos consumos de grãos correlacionados com grandes volumes de publicações científicas

Figura 10. Correlação entre volume de publicação científica e consumo de grãos

Fonte: Autor

Embora seja possível correlacionar volume de produção e/ou consumo de grãos com volume de publicações científicas acerca da temática IVAGA, outros fatores também podem estar associados. A pesquisa científica não depende apenas da relevância econômica ou do volume de produção ou consumo de um grão, mas também de aspectos como avanços tecnológicos, demandas regulatórias, incentivos financeiros e desafios específicos da inspeção desses produtos. Um exemplo típico é os EUA que, apesar de apresentar altíssima relevância econômica e tecnológica, e grandes volumes de produção e consumo de grãos, não contribui de forma proporcional com a literatura sobre a temática investigada.

Por fim, uma análise das afiliações dos autores indica que a pesquisa sobre IVAGA está fortemente concentrada no meio acadêmico. Das 233 afiliações identificadas, 208 (89,3%) são de departamentos ligados a universidades, enquanto apenas 25 (10,7%) são de laboratórios ou institutos de pesquisa independentes, o que mostra uma baixa representatividade de instituições não acadêmicas.

2.3 Revisão sistemática da literatura (RSL)

A finalidade da RSL foi identificar e sintetizar os estudos da literatura sobre IVAGA, com intuito de formar uma base teórica sobre as tecnologias mais promissoras (objetivos específicos O3 e O4).

Considerando a dificuldade de realizar uma revisão individualizada das 137 publicações elegíveis identificados na literatura da última década, foi adotada a seguinte estratégia: primeiro os estudos foram explicados de forma agrupada na seção 2.3.1 e, na sequência, foi conduzida na seção 2.3.2 uma análise detalhada dos estudos apresentando produtos com maior maturidade tecnológica (com maiores níveis de TRL), visando otimizar os esforços da análise e focar nas contribuições mais relevantes. Para tanto, buscou-se identificar os trabalhos que propuseram algum tipo de hardware para IVAGA.

2.3.1 Panorama da literatura sobre a temática “inspeção visual automática de grãos agrícolas”

Os 137 estudos identificados, elencados no Apêndice I, foram conduzidos em 27 países diferentes, evidenciando uma significativa representatividade geográfica e o interesse global na temática. Além disso, eles apresentam uma diversidade significativa de propostas/objetivos, técnica/algoritmos, tipos de imagens e tipos de descritores extraídos das imagens para o reconhecimento de padrões visuais.

Com base nas propostas apresentadas, os trabalhos foram agrupados nas seguintes categorias: métodos (MET), comparação de métodos (CMP_MET), métodos com proposição de hardware (MET+HDW) e comparação de métodos com proposição de hardware (CMP_MET+HDW).

Na categoria MET, que abrange o desenvolvimento de novos métodos, destacam-se os estudos com resultados de alta acurácia, como os de Anami *et al.* (2015), que desenvolveram uma metodologia baseada em características de cor para reconhecimento de variedades de arroz, alcançando uma acurácia média de 94,33%; Lin *et al.* (2018), que propuseram um sistema baseado em redes neurais convolucionais (RNC) para classificar variedades de arroz, obtendo uma acurácia de 95,5%, superando métodos tradicionais de aprendizagem de máquina; e Qadri *et al.* (2021), que propuseram um método baseado no algoritmo LMT-Tree para discriminar variedades de arroz asiáticas, que atingiu uma acurácia de 97,4%. Outros exemplos incluem Li *et al.* (2024), que propuseram um modelo baseado na RNC ResNet50 para identificar variedades de milho, com desempenho de 91,23%, e Jollet *et al.* (2023),

que usaram Mask R-CNN para análise de qualidade em feijões e alcançaram até 95,5% de acurácia.

Na categoria CMP_MET, que foca na comparação de diferentes métodos, foram evidenciados estudos que detalharam os algoritmos avaliados. Kılıçarslan *et al.* (2024) compararam métodos de aprendizado profundo e aprendizado de máquina, como MobileNetV2, EfficientNetV2B0, SVM, Random Forest e RNA, com acurácia máxima de 98,65% alcançada pelo SVM na classificação de trigo. Rathnayake *et al.* (2023) exploraram a classificação de idade de sementes de arroz japonês utilizando boosting como XGBoost, CatBoost e LightGBM em um modelo cascata, demonstrando desempenho superior em relação a 13 algoritmos, avaliados por métricas como precisão e F1-score. Nayak *et al.* (2023) compararam *Extreme Gradient Boosting* (XGBoost), SVM e outras técnicas para classificar sete variedades de feijões, com o XGBoost obtendo a maior acurácia, de 97,32%. Além disso, Huang *et al.* (2023) empregaram uma RNC PointNet++ para classificação de grãos cheios e não vazios, alcançando 98,5% de acurácia, e Yasar (2024) usaram redes RNC pré-treinadas e SVM para classificar variedades de trigo, atingindo acurácia de até 97,57%.

Para as categorias MET+HDW e CMP_MET+HDW, que envolvem métodos e comparações com a proposição de hardware, destacam-se estudos que apresentaram melhores desempenhos. Antonucci *et al.* (2017) desenvolveram um protótipo de esteira transportadora para classificar grãos de arroz, que alcançou precisão superior a 99%. Fan *et al.* (2024) criaram um sistema de visão computacional (SVC) de câmera dupla para identificar defeitos em grãos de arroz, trigo e sorgo, que demonstrou precisão média de 98,4%, e desempenho 20 vezes mais rápido que inspeções manuais. Shen *et al.* (2020) integraram espectroscopia Vis/NIR e visão computacional para identificar contaminação fúngica em grãos de milho, relatando uma precisão de até 95% e 100% de acurácia. Belan *et al.* (2020) desenvolveram um SVC para classificar e identificar os principais defeitos em grãos de feijão brasileiro, em tempo real, obtendo taxas de acerto de 97,8% na classificação e acima de 81,9% na detecção de defeitos. Outros exemplos incluem Liu *et al.* (2018) que desenvolveram um SVC para identificar variedades de milho com acurácia de 88,7% e 96,7% e Gao *et al.* (2021), que propuseram um SVC que captura informações espaciais e espectrais de grãos de arroz, a partir de imagens hiperespectrais 3D, para então classificá-los obtendo acurácia de 97,5% e 94,21% na classificação.

Entre as técnicas empregadas, a Aprendizagem de Máquina (AM) lidera, sendo utilizada em 68 estudos. Um exemplo é o trabalho de Liu *et al.* (2018), que desenvolveu um método para determinar a pureza de sementes de milho com base em múltiplos atributos extraídos de imagens RGB, obtendo precisão de 96.7% e 88.7%. Outro exemplo é o estudo de Gao *et al.* (2021), que combinou aprendizado de máquina com imagens hiperespectrais e tridimensionais para análise de grãos de arroz com 97.5% de acurácia. Além disso, o estudo de Antonucci *et al.* (2017) também explorou o aprendizado de máquina em um protótipo de esteira para classificação de grãos. Já a Aprendizagem Profunda (AP) foi empregada em 41 trabalhos, como o caso de Fan *et al.* (2024), que implementou um sistema eficiente de dupla câmera para inspeção visual de grãos de arroz, e o trabalho de Gao *et al.* (2021), que utilizou RNC para melhorar a precisão da análise de dados hiperespectrais. Outro exemplo é o estudo de Zhou *et al.* (2020), que aplicou aprendizado profundo para segmentação e classificação automatizada de grãos em imagens RGB. Métodos baseados em Estatística (EST) aparecem em 12 estudos, como o trabalho de Antonucci *et al.* (2017), que explorou histogramas e texturas para classificação de grãos de arroz, o estudo de Payman *et al.* (2018), que desenvolveu um sistema de visão para caracterização geométrica de grãos de arroz.

Quanto aos tipos de imagens utilizadas, as imagens padrão RGB (*red, green e blue*) foram predominantes, sendo empregadas em 106 estudos, incluindo o trabalho de Antonucci *et al.* (2017), que utilizou imagens RGB em um protótipo de esteira para classificação de grãos de arroz, o estudo de Liu *et al.* (2018), que investigou a pureza de sementes de milho com base em atributos extraídos de imagens RGB, e o trabalho de Zhou *et al.* (2020), que aplicou segmentação e classificação automatizada de grãos com imagens RGB. As imagens hiperespectrais (HIP) aparecem em 23 estudos, como no caso de Gao *et al.* (2021), que desenvolveu um método para processar dados hiperespectrais com alta precisão, o estudo de Fan *et al.* (2024), que utilizou essas imagens para inspeção visual de grãos em um sistema eficiente. Por outro lado, imagens tridimensionais (3D) foram exploradas em menos estudos, sendo destaque o trabalho de Gao *et al.* (2021), que combinou imagens 3D e hiperespectrais para análises avançadas.

Em relação aos tipos de atributos extraídos das imagens, os atributos estatísticos (EST) foram os mais frequentes, aparecendo em 51 estudos, como no trabalho de Antonucci *et al.* (2017), que analisou texturas e histogramas para classificar grãos, no estudo de Gao *et al.* (2021), que utilizou esses atributos para

melhorar a análise de imagens hiperespectrais. As representações hierárquicas e abstratas (RHA) foram exploradas em 43 estudos, com destaque para o trabalho de Fan *et al.* (2024), que utilizou RNC para extrair abstrações de alto nível, o de Gao *et al.* (2021), que aplicou representações abstratas em dados hiperespectrais, e o estudo de Zhou *et al.* (2021), que explorou representações hierárquicas em imagens RGB para segmentação e classificação de grãos. Por fim, os atributos geométricos (GEO) foram empregados em 12 estudos, como no caso de Payman *et al.* (2018), que focou na análise da forma e tamanho dos grãos, o estudo de Antonucci *et al.* (2017), que considerou perímetro e área na classificação de grãos de arroz.

De maneira geral, os estudos analisados demonstram a evolução das tecnologias aplicadas à análise de grãos, com destaque para o uso crescente de imagens hiperespectrais e redes neurais profundas. Esses avanços têm contribuído significativamente para o aprimoramento dos métodos de classificação e inspeção, demonstrando a importância da visão computacional na agricultura e na indústria. Não obstante, os resultados apresentados pelos estudos analisados revelam uma ampla gama de aplicações proeminentes no setor agrícola, que podem ser agrupadas em três segmentos principais: classificação e identificação de variedades, detecção de defeitos e análise de qualidade, e suporte à tomada de decisão em processos produtivos, como descrito a seguir.

- **Classificação e Identificação de Variedades**

Uma das aplicações mais proeminentes está na classificação e identificação de variedades de grãos, que é crucial para garantir a pureza das sementes e otimizar o manejo agrícola. Estudos como o de Qadri *et al.* (2021) demonstraram a capacidade de técnicas de aprendizado de máquina para diferenciar variedades de arroz cultivadas em diferentes países asiáticos, com uma acurácia de 97,4%. Da mesma forma, Lin *et al.* (2018) alcançaram uma acurácia de 95,5% ao utilizar RNC para discriminar variedades de arroz, superando métodos tradicionais, e Belan *et al.* (2020) desenvolveram um SVC para classificar grãos de feijão brasileiro, com taxa de acerto de 97,8%. Esses exemplos evidenciam como as tecnologias atuais permitem uma identificação mais rápida e precisa de variedades de grãos, o que tem impacto direto na comercialização e no planejamento agrícola.

- **Deteção de Defeitos e Análise de Qualidade**

Outra aplicação destacada é a detecção de defeitos e a análise da qualidade de grãos e sementes. Fan *et al.* (2024) apresentaram um SVC para identificar defeitos em grãos de cereais com alta eficiência, enquanto Belan *et al.* (2020) desenvolveram um SVC que identifica os principais defeitos em grãos de feijão brasileiro, em tempo real, com taxas de acerto acima de 81,9%. Tecnologias como essas contribuem para redução da subjetividade e aumentam a consistência das avaliações, promovendo melhorias no controle de qualidade durante o processamento dos grãos.

- **Suporte à Tomada de Decisão em Processos Produtivos**

As tecnologias apresentadas também desempenham um papel central no suporte à tomada de decisão em processos produtivos no setor agrícola, contribuindo para o aumento da eficiência e redução de custos. Antonucci *et al.* (2017), por exemplo, desenvolveram um protótipo de esteira transportadora que integra visão computacional para otimizar o rendimento do arroz, automatizando o processo de classificação. Rathnayake *et al.* (2023) propuseram modelos baseados em algoritmos de *boosting* para prever a idade de sementes, oferecendo informações valiosas para melhorar a taxa de germinação e a produtividade das lavouras. Belan *et al.* (2020) desenvolveram um equipamento que gasta aproximadamente 40 s para analisar uma amostra 250 g de grãos de feijão, como instruído na norma brasileira de inspeção da qualidade do produto.

Em resumo, as aplicações demonstram como a integração de métodos computacionais e hardware avançado está transformando o setor agrícola, trazendo soluções mais precisas, rápidas e eficientes para desafios históricos, como classificação, análise de qualidade e manejo produtivo. Além de contribuir para a sustentabilidade agrícola, apresentando melhorias em relação aos métodos tradicionais de inspeção, essas tecnologias impulsionam a competitividade do setor ao atender às demandas crescentes por eficiência e qualidade na produção de alimentos.

Contudo, apesar dos autores frequentemente sublinharem as inovações tecnológicas introduzidas, especialmente no contexto de algoritmos e combinações de métodos computacionais e soluções que podem ser adaptadas ou integradas ao ambiente industrial, raros são os trabalhos que abordam de forma explícita como as soluções podem ser empregadas no contexto industrial, como em Antonucci *et al.*

(2017), Belan *et al.* (2020) e Fan *et al.* (2024). Ressalta-se ainda que nenhum dos trabalhos da literatura discutiu transferência de tecnologia.

2.3.2 Trabalhos da literatura propondo hardware para inspeção visual


Dos 137 trabalhos elegíveis, apenas os 9 elencados na Tabela 2 propuseram uma solução contemplando hardware. Em tais trabalhos o hardware é denominado pelos autores como protótipo, equipamento ou dispositivo, enquanto o método de análise de imagens proposto dá origem ao software que controla o hardware. Assim, nesses trabalhos o termo Sistema de Visão Computacional (SVC) se refere a um conjunto de software e hardware.

Tabela 2. Artigos com potencial de apresentar produtos com maior grau de maturidade tecnológica

Trabalho	País	Grão	TRL
Antonucci <i>et al.</i> (2017)	Itália	ARROZ	6
Payman <i>et al.</i> (2018)	Irã	ARROZ	3
Liu <i>et al.</i> (2018)	China	MILHO	5
Shen <i>et al.</i> (2020)	China	MILHO	5
Chen <i>et al.</i> (2020)	China	ARROZ	5
Belan <i>et al.</i> (2020)	Brasil	FEIJÃO	6
Gao <i>et al.</i> (2021)	Estados Unidos	ARROZ	4
Xu <i>et al.</i> (2021)	China	MILHO	4
Fan <i>et al.</i> (2024)	Austrália	ARROZ, TRIGO, SORGO	6

Antonucci *et al.* (2017) propuseram um SVC para classificar grãos de arroz, composto por uma esteira transportadora equipada com uma câmera RGB de 5 Mp, iluminação controlada, e uma interface gráfica para operação do SVC, como pode ser visto na Figura 11. O método de análise de imagens é baseado em técnicas de morfometria, descritores de Fourier e análise multivariada, incluindo a técnica *Partial Least Squares Discriminant Analysis* (PLS-DA). Nos experimentos realizados, o SVC alcançou precisão superior a 99% na classificação dos grãos. No entanto, a dependência de ambientes controlados para captura de imagens consistentes limita sua aplicação em condições industriais adversas.


Figura 11. Ilustração do SVC desenvolvido por Antonucci *et al.* (2017)



Fonte: Antonucci *et al.* (2017).

O SVC apresentado em Payman *et al.* (2018) ilustrado na Figura 12 contempla um scanner, um laptop e uma interface gráfica, e foi proposto para avaliar índices de qualidade de arroz, como fissuras, manchas e integridade dos grãos. O método de análise de imagens envolve transformada wavelet para detecção de fissuras, segmentação baseada em limiarização de componentes de cor e análise de textura. O SVC alcançou acurácia de 96,51% na detecção de fissuras e 98% na classificação de grãos inteiros e quebrados. Apesar dos bons resultados, as limitações impostas pelo hardware dificultam a inspeção de grãos em escala industrial.

Figura 12. Ilustração do SVC proposto por Payman *et al.* (2018)



(a) hardware

SUMMARIZED CHARACTERISTICS OF GRAINS		
Total Number of Grains: 104		
Dimensional Classification (ISIRI)		
	Number	Percent
Whole Kernel	96	92.6923
Very Long	12	11.5385
Long	60	57.6923
Medium	14	13.4615
Short	0	0
Broken Kernel	18	17.3077
Head Rice	5	4.8077
Large Broken	11	10.5769
Medium Broken	2	1.9231
Small Broken	0	0
Chips	0	0
Dimensional Characteristics		
	Average	Std.
Length (mm)	7.1495	0.35078
Width (mm)	1.9772	0.20324
Thickness (mm)	1.5422	0.09937
Appearance Characteristics		
	Number	Percent
Chalky Grains	3	3.4884
Red Stained Grains	0	0
Black Stained Grains	0	0
Green Grains	0	0
Brown or Not-Milled Grains	5	5.814
Cracked Grains	7	6.7308
Average Roundness: 0.2097		
Average Aspect Ratio: 3.6509		


(b) interface gráfica

Fonte: Payman *et al.* (2018)

O equipamento (hardware) desenvolvido por Liu *et al.* (2018) para identificar diferentes variedades de milho, ilustrado na Figura 13, é constituído pelas seguintes partes: (1) alça, (2) invólucro superior, (3) guia de ajuste horizontal, (4) estrutura de ajuste vertical, (5) estrutura da câmera, (6) e (19) câmeras CCD, (7) invólucro do trilho de suporte, (8) invólucro inferior, (9) lâmpada LED e placa de sombreamento, (10) porta de descarga, (11) correia transportadora de ranhura, (12) e (13) suporte da correia transportadora, (14) núcleo do trilho de suporte, (15) porta de alimentação, (16) fonte de alimentação móvel, (17) driver do motor de passo, (18) furos de terminal, (20) chip único, (21) estrutura de ajuste de nível, e (22) estrutura de ajuste vertical.

Para analisar imagens capturadas de sementes de milho foi empregado um algoritmo de multi-step clustering que encadeia as técnicas self-organizing maps (SOM) e K-means. O método combina ainda segmentação baseada em características visuais, como cor e textura, com agrupamentos iterativos que refinam a classificação das sementes. O SVC obteve acurácia acima de 95%, mas exige calibração específica para cada variedade de milho, o que pode significar uma limitação para seu uso prático.

Figura 13. Ilustração do equipamento desenvolvido por Liu *et al.* (2018)




Fonte: Liu *et al.* (2018)

Shen *et al.* (2020) apresentaram um SVC que integra espectroscopia Vis/NIR e visão computacional para identificar contaminação fúngica em grãos de milho. A unidade espectral inclui espectrômetros de fibra, fibras ópticas em configuração tipo Y e um detector de reflexão difusa com lâmpada halógena. Na unidade de visão, uma fonte de luz em anel LED ilumina a amostra de grãos de forma uniforme, enquanto uma câmera CCD posicionada a 15 cm da fonte de luz captura as imagens. Cada

amostra é colocada no meio de uma correia transportadora ajustada para uma velocidade máxima de 0,15 m/s. O hardware ilustrado na Figura 14 é controlado por um computador acoplado a ele. A análise de imagens se baseia em algoritmos de segmentação e extração de características de textura e cor. Esses dados são combinados com informações espectrais usando *Linear Discriminant Analysis* (LDA) e regressão de mínimos quadrados parciais (PLS). A fusão de dados resultou em 100% de acurácia na identificação de tipos de fungos após 12 dias de armazenamento dos grãos e 92,2% na classificação de níveis de infecção.

Figura 14. Ilustração do SVC proposto por Shen *et al.* (2020)



Fonte: Shen *et al.* (2020)


Embora resultados promissores tenham sido obtidos pelo SVC desenvolvido por Shen *et al.* (2020), ainda existem algumas limitações que dificultam sua aplicação prática. Primeiramente, as características de resposta espectral e de imagem podem ser afetadas pela variedade do grão, espécie fúngica infectada, bem como condições de armazenamento. Além disso, as informações coletadas em condições on-line são mais suscetíveis à interferência do estado da amostra e do ambiente ao redor.

Chen *et al.* (2020) desenvolveram um SVC para monitorar, em tempo real, as impurezas presentes nos grãos durante o processo de colheita de arroz com uma colheitadeira. Como ilustrado na Figura 15 (b), o SVC é acoplado na colheitadeira, sendo composto pelas seguintes partes: (1) abertura para entrada dos grãos; (2) caixa de amostragem; (3) câmera CMOS instalada dentro da caixa de amostragem; (4) placa de estrangulamento empurrada e puxada por um eletroímã e uma mola; (5) eletroímã e mola instalados na caixa de amostragem; (6) unidade de controle; (7)


interface; (8) unidade de processamento de imagem; (9) monitor RGB; (10) computador/laptop.

A análise de imagens utiliza algoritmos de segmentação para separar grãos e impurezas, enquanto um modelo baseado em árvore de decisão classifica as partículas detectadas. Os autores não relatam o desempenho do SVC em testes práticos, indicando apenas acurácia de classificação de 76% em dados de treinamento. A principal limitação do SVC está na dificuldade de operar em ambientes com iluminação inconsistente e partículas sobrepostas. Além disso, o método de análise de imagem poderia ser melhorado levando em conta características de textura e de cor, além das características geométricas que foram empregadas.

Figura 15. Ilustração do SVC proposto por Chen *et al.* (2020)



(a) Forma de acoplamento e diagrama esquemático do hardware. 1-elevador de grãos; 2-trado do silo de grãos; 3-caixa de amostragem; 4-suporte de montagem da câmera.



(b) partes do SVC

Fonte: Chen *et al.* (2020)


Belan *et al.* (2020) desenvolveram um SVC para classificar e identificar os principais defeitos em grãos de feijão brasileiro. O hardware (Figura 16) consiste em

um equipamento de baixo custo, fabricado com materiais eletromecânicos, incluindo uma estrutura de alumínio, câmara de aquisição de imagens com acrílico fosco e LEDs (iluminância de 1300 lux), correia transportadora controlada por um servo motor e mecanismos para alimentação e dispensa dos grãos. Uma câmera CMOS de alta resolução (1280×720 pixels) foi utilizada para aquisição de imagens. O servo motor é controlado por um microcontrolador Atmega 328P para garantir estabilidade, ajuste de velocidade e sincronização com o sistema de iluminação. De acordo com os autores, o custo total do foi de US\$1.207,26.

Figura 16. Ilustração do SVC proposto por Belan *et al.* (2020)



(a) hardware



(b) interface gráfica do software


Fonte: Belan *et al.* (2020)

O método de análise de imagens inclui segmentação por histogramas de cor, classificação dos grãos usando RNA e identificação de defeitos por RNC. Nos experimentos em modo online, nos quais lotes de feijão são derramados continuamente na esteira para serem inspecionados, o SVC obteve taxas de acerto

de 98,5% na segmentação, 97,8% na classificação e acima de 81,9% na detecção de defeitos. Os autores argumentam ainda que o SVC proposto é mais adequado para uso em laboratórios de inspeção de qualidade de grãos, e que ele levaria aproximadamente 40 s para analisar uma amostra 250 g. Como limitações, o SVC pode ser afetado pela alta densidade de grãos e não contempla todas as classes e defeitos do feijão brasileiro.

O SVC desenvolvido por Gao *et al.* (2021) usa imagens hiperespectrais 3D para capturar informações espaciais e espectrais de sementes. O hardware Figura 17 consiste em uma estrutura de alumínio estrutural para suportar uma câmera hiperespectral e uma fonte de luz. A iluminação é feita por uma unidade com duas linhas contendo quatro lâmpadas de tungstênio-halogênio de 20 W cada. Esse hardware é controlado por um computador acoplado a ele, por meio de interface gráfica.

Figura 17. Ilustração do SVC desenvolvido por Gao *et al.* (2021)




Fonte: Gao *et al.* (2021)

O método de análise de imagens apresentado em Gao *et al.* (2021) envolve a segmentação de sementes usando redes neurais convolucionais 3D (3D CNN), obteve acurácia de 97,5% na classificação, e permite a identificação de comprimentos de onda de interesse biológico. As limitações do SVC proposto pelos autores incluem o alto custo do equipamento e a necessidade de processamento intensivo de dados.

Xu *et al.* (2021) desenvolveram um SVC para classificar variedades de milho. O hardware (Figura 18) é composto por uma caixa de aquisição de imagens contemplando uma câmera CCD de alta resolução e duas lâmpadas halógenas, além

de uma superfície lisa para posicionamento da amostra de grãos e um computador, que executa algoritmos de aprendizagem de máquina para analisar as imagens.

Figura 18. Ilustração do SVC proposto por Xu *et al.* (2021)




Fonte: Xu *et al.* (2021).

Na análise de imagens foram extraídas 16 características, incluindo medidas dimensionais e de forma. Os algoritmos Support Vector Machine (SVM), *Decision Tree* (DT), *Naive Bayes*, *AdaBoost*, K-NN, MLP foram comparados na classificação de cinco variedades de milho. Na análise comparativa, SVM obteve a maior acurácia geral de 96,46%, mas apresentou dificuldades na separação de variedades visualmente semelhantes.

Fan *et al.* (2024) desenvolveram um SVC para identificar defeitos em grãos de arroz, trigo e sorgo. O hardware proposto por consiste em três partes principais: módulo de alimentação para pré-processar os grãos, separando-os uns dos outros; módulo de captura no qual são utilizadas duas câmeras para capturar imagens de alta resolução de grãos; e uma placa transparente para entregar e reciclar grãos, como mostrado na Figura 19. O método de análise é baseado em redes neurais convolucionais (RNC), que extraem características como forma, cor e textura dos grãos para classificá-los em normais ou defeituosos. A precisão média foi de 98,4%, com um desempenho 20 vezes mais rápido que inspeções manuais. Como limitações do SVC destacam-se o custo elevado do hardware e a adaptação para diferentes culturas agrícolas.

Figura 19. Ilustração do SVC desenvolvido por Fan *et al.* (2024)



Fonte: Fan *et al.* (2024).

Os nove trabalhos analisados apresentam propostas de sistemas de SVCs voltados para a classificação e inspeção de grãos, abrangendo culturas como arroz, milho, trigo, sorgo e feijão. De modo geral, as propostas compartilham características como o uso de métodos avançados de análise de imagens e visão computacional, baseados em aprendizagem de máquina (AM) e aprendizagem profunda (AP), além da integração com hardwares específicos, como esteiras transportadoras, câmeras de alta resolução e sistemas de iluminação controlada. Entre as técnicas aplicadas destacam-se redes neurais convolucionais (RNC), análise de componentes principais, e algoritmos como o SVM, DT e LDA. A maioria dos estudos relatou altas taxas de acurácia, frequentemente superiores a 95%, tanto para classificação quanto para a identificação de defeitos nos grãos.

No que tange ao Nível de Maturidade Tecnológica (TRL), os trabalhos analisados apresentam TRL variando entre 3, que corresponde às etapas iniciais de validação em laboratório, e TRL 6, indicando proximidade com a aplicação em ambientes operacionais ou industriais. Os estudos classificados com TRL 3 ou 4, como os de Payman *et al.* (2018), Gao *et al.* (2021) e Xu *et al.* (2021), mostram sistemas ainda em estágio inicial, com boas métricas de desempenho em ambientes controlados, mas que enfrentam desafios significativos para a aplicação prática. Dentre essas limitações, destacam-se a dependência de condições controladas e a dificuldade de adaptação a ambientes industriais.

Por outro lado, trabalhos classificados como TRL 5 ou 6, como os de Antonucci *et al.* (2017), Liu *et al.* (2018), Shen *et al.* (2020) e Chen *et al.* (2020), demonstram maior maturidade tecnológica, sendo validados em ambientes relevantes e apresentando resultados promissores para a classificação de grãos e identificação de defeitos. No entanto, os SVCs propostos em tais trabalhos ainda enfrentam limitações,

como a necessidade de calibração específica para diferentes variedades de grãos e dificuldades operacionais em condições adversas.

Os SVCs classificados como TRL 6, como os propostos em Fan *et al.* (2024) e Belan *et al.* (2020), se destacam por sua maior proximidade com a aplicação prática. Esses sistemas foram validados em condições simuladas ou reais e demonstram potencial para implementação comercial. Em particular, o trabalho de Belan *et al.* (2020) propõe um SVC fabricado com materiais de baixo custo, buscando viabilizar sua adoção por pequenos e médios produtores agrícolas. Apesar do progresso, esses sistemas ainda requerem validação mais ampla em diferentes contextos operacionais para garantir sua robustez em larga escala. Cita-se como exemplo o fato do SVC proposto em Belan *et al.* (2020) lidar com apenas três variedades de feijões brasileiros.

De modo geral, os trabalhos associados a TRL mais baixos apresentam grande potencial científico e tecnológico, mas ainda dependem de avanços significativos para alcançar níveis mais elevados de maturidade. Já os SVCs em TRL intermediário avançam para aplicações práticas, mas precisam superar desafios específicos relacionados à escalabilidade, adaptação a condições reais e redução de custos. Por fim, os SVCs classificados em TRL mais altos indicam maior viabilidade comercial, embora ainda demandem validação adicional para consolidação no mercado.

O avanço da maturidade tecnológica é crucial para a automação e eficiência na inspeção de grãos. Investimentos em pesquisa, desenvolvimento e parcerias são essenciais para superar limitações e viabilizar o uso prático das tecnologias identificadas na literatura. Para a modernização do setor agrícola, é necessário enfrentar os principais desafios como redução de custos, desenvolvimento de equipamentos mais acessíveis para pequenos e médios produtores, escalabilidade para condições não controladas e maior generalização para atender a diferentes culturas e variedades.

3. METODOLOGIA

Neste capítulo é apresentada a caracterização metodológica da pesquisa, incluindo síntese metodológica, os procedimentos empregados no levantamento bibliográfico, o instrumento de coleta de dados e as limitações da pesquisa


3.1 Caracterização metodológica da pesquisa

A metodologia utilizada neste trabalho é definida, com base em sua natureza, como pesquisa aplicada, uma vez que visa produzir conhecimento novo para um determinado campo da ciência (GIL, 2010; KUMAR, 2018). Especificamente, exploram-se tecnologias que possam ser implementadas na indústria agrícola para melhorar a eficiência e a qualidade do processo de inspeção de grãos.

Com relação ao objetivo, de acordo com Kumar (2011), a pesquisa pode ser caracterizada como pesquisa descritiva, exploratória e correlacional. A pesquisa é descritiva porque visa identificar, descrever e fornecer uma compreensão clara do estado da arte sobre as tecnologias propostas na literatura para inspeção visual de grãos (O1 e O2). De acordo com a definição de Yin (2015), a pesquisa também é exploratória, pois busca investigar os principais fatores que dificultam a transferência de tecnologia no contexto da inspeção visual automática de grãos – IVAGA (O3 e O4). Este objetivo envolve a exploração de novas perspectivas e insights sobre os desafios e barreiras enfrentados, uma característica típica da pesquisa exploratória. Por fim, a pesquisa também possui elementos correlacionais, como a análise da relação entre o volume de publicações científicas de um país sobre IVAGA e os volumes de produção ou consumo desses grãos (O2). Este aspecto correlacional busca entender se existe uma associação significativa entre essas variáveis, podendo fornecer insights sobre influências e tendências na produção científica e industrial.

No que diz respeito a abordagem esta pesquisa pode ser classificada combinada (mista), já que emprega abordagens qualitativa e quantitativa, de forma combinada, para responder as perguntas de pesquisa (CRESWELL, 2009). Como procedimentos, a pesquisa emprega: análise bibliométrica para quantificar aspectos da literatura, revisão sistemática da literatura (RSL) para sintetizar o estado da arte, e *survey* para coletar dados sobre conhecimento e uso de tecnologias para IVAGA na agroindústria, e sobre os desafios e barreiras para a transferência de tecnologia no setor agrícola. Esses métodos, combinados, permitem uma análise detalhada e completa da temática investigada, e estão alinhados com as questões, objetivo e resultados da pesquisa, como ilustrado na Figura 20.

Figura 20. Síntese metodológica



A Figura 20 ilustra uma síntese metodológica da pesquisa, que visa estabelecer uma ligação clara entre a problemática de pesquisa, as questões de pesquisa, os objetivos e os métodos utilizados. O problema de pesquisa definiu a lacuna de conhecimento, base para a formulação das questões de pesquisa que guiaram a investigação. Os objetivos da pesquisa foram então delineados para responder às questões. Para atingir os objetivos foram escolhidos os métodos de pesquisa revisão bibliométrica, RSL e *survey*, como já explicado.

3.2 Procedimentos para o levantamento bibliográfico

Para o levantamento bibliográfico as seguintes etapas foram executadas: definição das bases científicas; definição das palavras-chave e composição das expressões de busca nas bases; definição dos critérios de inclusão e exclusão (elegibilidade); análise das publicações elegíveis. Para essas duas últimas etapas utilizou-se a metodologia PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), proposto por Moher *et al.*, (2010).

3.2.1 Definição das bases científicas

A escolha de bases científicas de alta qualidade é fundamental para garantir a robustez e relevância de uma pesquisa científica. Dentre as principais bases disponíveis, Scopus, Compendex e Web of Science, escolhidas nesta pesquisa, se destacam pela abrangência, rigor e credibilidade das publicações indexadas. A seguir, são apresentadas as razões específicas para a escolha de cada uma dessas três bases:

Compendex¹: parte da Engineering Village, é uma das principais bases de dados voltadas especificamente para a engenharia e ciências aplicadas. Com mais de 20 milhões de registros indexados de periódicos, conferências e anais, Compendex oferece uma cobertura detalhada e especializada em áreas como engenharia mecânica, civil, elétrica, aeroespacial e materiais. Isso a torna uma escolha essencial para pesquisadores que buscam informações técnicas avançadas e soluções práticas aplicáveis à engenharia.

Scopus²: é uma das maiores bases de dados multidisciplinares de resumos e citações de literatura acadêmica, cobrindo mais de 70 milhões de registros de publicações de diversas áreas do conhecimento. Em ciências exatas, a plataforma oferece acesso a uma vasta quantidade de artigos, conferências e patentes, fornecendo uma visão abrangente e atualizada do estado da arte em temas como física, química, engenharia, ciência da computação e matemática. Além disso, a ferramenta de análise de citações da Scopus permite medir o impacto e a relevância dos trabalhos, o que é essencial para identificar as tendências e lacunas de pesquisa. No campo da ciência da computação, Scopus indexa periódicos essenciais, como: *IEEE Transactions on Computers*, *Journal of Artificial Intelligence Research (JAIR)*, *ACM Computing Surveys (CSUR)*, *Pattern Recognition* e *Neural Networks*. Além disso, Scopus inclui uma ampla gama de conferências renomadas, como *International Conference on Machine Learning (ICML)* e *Conference on Computer Vision and Pattern Recognition (CVPR)*, que são fundamentais para o avanço da ciência da computação.

Web of Science³: é amplamente reconhecida pela sua seleção rigorosa de periódicos e publicações, com foco na qualidade e impacto das pesquisas. A base é uma

¹ <https://www.engineeringvillage.com/search/quick.url>

² <https://www.scopus.com/search/form.uri?display=basic>

³ webofscience.com/wos/

referência para a análise de tendências científicas e tecnológicas em ciências exatas, pois oferece ferramentas avançadas de análise de citações e permite o acompanhamento da evolução de ideias e descobertas científicas ao longo do tempo. Além disso, sua cobertura global de periódicos de alto impacto proporciona uma visão internacional das pesquisas mais relevantes em áreas como física, matemática, química e ciências ambientais.

A combinação dessas três bases proporciona uma cobertura extensa e diversificada, garantindo que a pesquisa nas ciências exatas seja sustentada por dados precisos, completos e de alta qualidade. Ao utilizar Scopus, Compendex e Web of Science, é possível acessar as mais recentes inovações científicas e tecnológicas, identificar as principais referências acadêmicas e assegurar que a pesquisa esteja alinhada com o estado da arte em sua área de estudo.


3.2.2 Palavras-chave e composição das expressões de busca

Para a realização da pesquisa sobre o tema “inspeção visual automática de grãos agrícolas” foram definidas as palavras-chave apresentadas na Tabela 3, nos idiomas inglês e português, sendo cada grupo de palavras composto por termos cognatos.

Tabela 3. Palavras-chave e suas cognatas

	Grupo1	Grupo2	Grupo3	Grupo4
Inglês	agricultural food	grain seed	inspection classification selection grading	image processing image analysis computer vision machine vision machine learning
Português	agricultura alimento	grão semente	inspeção classificação seleção	processamento de imagens análise de imagens visão computacional visão de máquina aprendizagem de máquina

Para facilitar a composição das expressões de busca, apresentadas na Tabela 3, primeiramente as palavras-chave foram organizadas em forma de uma árvore, como ilustrado na Figura 21, a qual ilustra apenas as palavras-chave em inglês para facilitar o entendimento.

Figura 21. Organização das palavras-chave e suas cognatas na forma de árvore

A expressão de busca customizada para cada base considera, além das palavras-chave, estão na Tabela 4, os seguintes critérios de inclusão: apenas artigos em inglês ou português, publicados no período de 2015 a outubro de 2024, e que não sejam de revisão de literatura.


Tabela 4. Expressões de busca

Expressão base	("agricultural" OU "food" OU "agricultura" OU "alimento") E ("grain" OU "seed" OU "grão" OU "semente") E ("inspection" OU "classification" OU "selection" OU "grading" OU "inspeção" OU "classificação" OU "seleção") E ("image processing" OU "image analysis" OU "computer vision" OU "machine vision" OU "machine learning" OU "processamento de imagens" OU "análise de imagens" OU "visão computacional" OU "visão de máquina" OU "aprendizagem de máquina")
COMPENDEX	((("agricultural" or "food" or "agricultura" or "alimento") and ("grain" or "seed" or "grão" or "semente") and ("inspection" or "classification" or "selection" or "grading" or "inspeção" or "classificação" or "seleção") and ("image processing" or "image analysis" or "computer vision" or "machine vision" or "machine learning" or "processamento de imagens" or "análise de imagens" or "visão computacional" or "visão de máquina" or "aprendizagem de máquina")) WN KY) AND ((2015-2024)WN YR) AND (({english} OR {portuguese}) WN LA) AND ({ja} WN DT) not (((("review") OR ("survey") OR ("review") OR ("revision") OR ("bibliographic") OR ("literature")) WN TI))
SCOPUS	((TITLE-ABS-KEY ("agricultural" OR "agricultura" OR "food" OR "alimento") AND TITLE-ABS-KEY ("grain" OR "grão" OR "seed" OR "semente") AND TITLE-ABS-KEY ("inspection" OR "inspeção" OR "classification" OR "classificação" OR "selection" OR "seleção" OR "grading") AND TITLE-ABS-KEY ("image processing" or "image analysis" or "computer vision" or "machine vision" or "machine learning" or "processamento de imagens" or "análise de imagens" or "visão computacional" or "visão de máquina" or "aprendizagem de máquina") AND (PUBYEAR > 2014)) AND (LIMIT-TO (DOCTYPE,"ar")) AND (LIMIT-TO (LANGUAGE,"English") OR LIMIT-TO (LANGUAGE,"Portuguese")) AND NOT TITLE ("survey" OR "review" OR "revision" OR "bibliographic" OR "literature")
WEB OF SCIENCE	((((TS=("agricultural" OR "food" OR "agricultura" OR "alimento")) AND (TS=("grain" OR "seed" OR "grão" OR "semente")) AND (TS=("inspection" OR "classification" OR "selection" OR "grading" OR "inspeção" OR "classificação" OR "seleção")) AND (TS=("image processing" OR "image analysis" OR "computer vision" OR "machine vision" OR "machine learning" or "processamento de imagens" OR "análise de imagens" OR "visão computacional" OR "visão de máquina" OR "aprendizagem de máquina")) AND (PY=(2015-2024)) AND (LA==("ENGLISH") OR LA==("PORTUGUESE")) AND DT=("Article") NOT TI=("survey" OR "review" OR "revision" OR "bibliographic" OR "literature"))

3.2.3 Definição dos critérios de elegibilidade e análise das publicações elegíveis

O método PRISMA foi empregado para minerar os trabalhos científicos pertinentes. Ele contempla quatro etapas (identificação, triagem, elegibilidade e inclusão) estruturadas por meio de um diagrama, como o ilustrado na Figura 22

Figura 22. Fluxo de seleção dos artigos de acordo o método PRISMA



Fonte: Adaptado do modelo PRISMA (MOHER *et al.*, 2010).

Inicialmente, na etapa de identificação, as buscas nas bases escolhidas retornaram 792 artigos nos quais o título, resumo ou nas palavras-chave continham as palavras constantes na expressão de busca. Na etapa de triagem foi feita a exclusão de 312 artigos duplicados, restando 480 trabalhos únicos. Então, foram selecionados 137 artigos que atendiam aos critérios de elegibilidade, dos quais 9 propuseram algum tipo de hardware para IVAGA.

3.3. Instrumento de coleta de dados

O questionário apresentado APENDICE II foi aplicado para levantar dados sobre conhecimento e uso de tecnologias para IVAGA na agroindústria, e sobre os desafios e barreiras para a transferência de tecnologia no setor agrícola. Ele foi elaborado para alcançar o quarto objetivo específico (O4), apresentado na seção 1.3.2

3.3.1 Aplicação e público-alvo

Na elaboração do questionário foi empregado o *Google Forms*. Ele foi disponibilizado no link <https://forms.gle/2XVGxh9HCp3EHgiJ8>, e divulgado por e-mail. Ele foi aplicado no período de 20 de novembro a 20 de dezembro de 2024, a trabalhadores e gestores da agricultura e agroindústria, docentes e discentes de cursos de graduação e pós-graduação voltados para agricultura e agronegócios, além de pesquisadores e desenvolvedores de tecnologias para automatização de processos produtivos. Os seguintes critérios de inclusão e exclusão foram adotados:

Inclusão:

- Produtores, trabalhadores ou gestores do setor agrícola, incluindo indústria, comércio e serviços (independente da formação acadêmica);
- Docentes e discentes de cursos técnico, graduação ou pós-graduação voltados para agricultura;
- Docentes e discentes de cursos de pós-graduação em mecatrônica, engenharia elétrica, engenharia de produção, computação e informática, e outros que atuam com pesquisa e desenvolvimento de tecnologias para automatização de processos agrícolas.

Exclusão:

- Não aceitar o Termo de Consentimento Livre e Esclarecido;
- Não atender aos critérios de inclusão;
- Não responder completamente ao formulário.

Uma vez que a função do sujeito da pesquisa foi exclusivamente fornecer respostas ao instrumento de coleta de dados, adotou-se o termo “respondente” para qualificá-lo ao longo do texto.

3.3.2 Descrição das perguntas

O questionário está estruturado em seções sobre dados pessoais, atuação profissional, ramo de atividade, e percepção e conhecimento sobre tecnologias de inspeção visual automática na agroindústria, conforme apresentado na sequência. Na última seção as perguntas são fechadas, de múltipla escolha, e são baseadas na escala Likert. Em sua primeira página constam os objetivos e métodos da pesquisa, bem como os termos de confidencialidade. Basta o respondente aceitar os termos e clicar no botão “Próxima” para iniciar as respostas.

Dados pessoais

1. Você, livre e esclarecida(o), autoriza a utilização de suas respostas para a pesquisa de doutorado intitulada "INSPEÇÃO VISUAL AUTOMÁTICA DE GRÃOS AGRÍCOLAS: potenciais aplicações e principais desafios para transferência de tecnologia na agroindústria"?
2. Nome (opcional)
3. Grau de instrução?
4. Faixa etária?

Atuação profissional

5. Ramo de atividade?
6. Há quanto tempo atua neste ramo de atividade?
7. Nível do cargo/função que exerce atualmente?
8. Nome da instituição/empresa/organização onde você atua (opcional)
9. Localização (Estado) da instituição/empresa/organização onde você atua?
10. A sua atividade profissional está diretamente relacionada com produção, comercialização, armazenamento ou industrialização de produtos agrícolas?

Atividades profissionais diretamente relacionadas com produtos agrícolas

11. Tipo de produto?
12. Quais das tecnologias a seguir são utilizadas na instituição/empresa/organização onde você atua?

Tecnologias para inspeção visual automática de grãos

13. Você tem conhecimento da existência de trabalhos científicos propondo soluções tecnológicas (sistemas computacionais e equipamentos) para inspeção visual automática da qualidade de produtos agrícolas?
14. Você acha importante um sistema computacional ou equipamento para automatizar as tarefas de inspeção visual da qualidade de grãos (classificação por cor, textura, tamanho ou formato, identificação de defeitos etc.)?
15. Na sua opinião, qual o nível de contribuição das soluções tecnológicas de inspeção visual automática da qualidade de grãos para:
 - Redução de custo
 - Garantia da qualidade dos produtos
 - Padronização dos resultados da inspeção
 - Aumento da competitividade empresarial

- Maior eficiência de processos no setor agrícola
- Apoio à tomada de decisão

16. Na sua opinião, em que grau cada um dos fatores a seguir desfavorece o emprego de tecnologias para a inspeção visual automática de grãos?

- Custo das soluções tecnológicas
- Tempo de retorno do investimento nas soluções tecnológicas
- Necessidade de mudanças em processos/formas de trabalho
- Necessidade de mão-de-obra qualificada para operar as soluções tecnológicas
- Falta de confiança nos resultados produzidos pelas soluções tecnológicas
- Falta de alinhamento das soluções tecnológicas às demandas do setor agrícola

17. Selecione até 5 dos itens a seguir que, na sua opinião, são importantes para viabilizar o emprego em larga escala de tecnologias para inspeção visual automática de grãos:

- Diminuição da resistência cultural (devido à falta de conhecimento ou confiança nas novas tecnologias)
- Padronização dos resultados
- Vantagens econômicas
- Redução do custo para aquisição dessas tecnologias
- Desenvolvimento de tecnologias facilmente adaptáveis ao ambiente de trabalho
- Maior integração entre os campos acadêmico e empresarial (teoria e prática)
- Criação ou ampliação de linhas de crédito para aquisição dessas tecnologias
- Desenvolvimento de tecnologias que vão ao encontro das necessidades do setor agrícola
- Ampla divulgação das tecnologias existentes
- Capacitação de mão-de-obra para lidar com essas tecnologias

3.3.3 Validação e testagem

O questionário foi validado e testado com base nos procedimentos descritos em Forza (2002). Na fase de validação de conteúdo, ele foi revisado por 3 especialistas das áreas de Computação e Engenharia de Produção, para assegurar a cobertura dos aspectos relevantes ao tema estudado, enquanto na fase de teste piloto ele foi

aplicação a um grupo de 5 participantes representativos do público-alvo, com intuito identificar problemas de compreensão, ambiguidades ou dificuldades nas respostas.

3.3.4 Tratamento e análise dos dados

Após o período de aplicação do questionário, os dados coletados foram analisados utilizando estatística descritiva, que foi empregada para sumarizar as informações obtidas, por meio de medidas de dispersão e frequências absolutas e relativas.

Os dados foram organizados em tabelas e gráficos para facilitar a interpretação e visualização dos padrões. O processamento e a análise dos dados foram realizados por meio do software Excel.

3.4 Limitações da pesquisa

- A investigação acerca das barreiras que impedem a transferência de tecnologia para IVAGA é limitada ao cenário nacional.
- Todas as análises conduzidas nesta pesquisa são focadas nos 5 grãos mais produzidos/consumidos no Brasil (Arroz, Trigo, Milho, Soja e Feijão), sendo os quatro primeiros também mais consumidos/produzidos no mundo.
- Apesar da inspeção da qualidade de grãos envolver a avaliação de suas características físicas, químicas e biológicas, na presente pesquisa é considerada apenas a inspeção visual.
- Bases de patentes relacionadas à temática investigada não foram consideradas nesta pesquisa.

4. RESULTADOS E DISCUSSÕES

Os resultados apresentados neste capítulo têm como finalidade principal responder às questões norteadoras de pesquisa, as quais estão associadas aos 4 objetivos específicos. A seção 4.1 está alinhada aos objetivos O1 e O2, a seção 4.2 se alinha com os objetivos O3 e O4 e, por fim, a seção 4.3 complementa o atendimento ao objetivo O4 apresentando a análise dos dados coletados por meio do questionário.

4.1 Análise quantitativa de padrões e correlações identificados na produção científica e tecnológica de soluções para inspeção visual automática

De acordo com a revisão bibliométrica, os grãos mais beneficiados pelas tecnologias propostas na literatura para inspeção visual automática são o arroz, trigo, milho, feijão e soja. O arroz destaca-se com 41% das publicações (59 estudos), seguido pelo trigo com 27% (39 estudos) e milho com 18% (26 estudos). Apesar de sua relevância no Brasil, o feijão correspondeu a apenas 7% (10 estudos), e a soja, 4% (7 estudos). Esses dados evidenciam um maior foco em grãos amplamente produzidos e consumidos globalmente, o que pode indicar as prioridades de pesquisa em países com maior relevância no setor agrícola.

O arroz é o grão mais beneficiado pelas soluções tecnológicas de inspeção visual, provavelmente em virtude de uma combinação de fatores econômicos, sociais e técnicos. Primeiramente, o arroz é uma das culturas mais produzidas e consumidas globalmente, servindo como base alimentar para mais de metade da população mundial (SOKUDLOR *et al.*, 2023). Assim, a necessidade de melhoria da eficiência produtiva e a qualidade desse grão pode estar relacionada com a sua relevância econômica e social. Além disso, o arroz apresenta características que tornam viável a aplicação de tecnologias de inspeção visual, como uniformidade relativa no tamanho e formato dos grãos, permitindo a implementação de sistemas de visão computacional (Fan *et al.*, 2023). Por fim, a produção do arroz está concentrada em países com alto investimento em pesquisa agrícola, como China e Índia, que lideram a publicação de estudos sobre inspeção visual automática de grãos (IVAGA).

Esse contexto favorece o desenvolvimento e a adoção de soluções tecnológicas para inspeção visual, refletindo-se no maior número de estudos e inovações voltados para este grão em comparação a outros. Em resumo, a importância estratégica do arroz na segurança alimentar global e sua compatibilidade com tecnologias avançadas explicam por que ele é o grão mais beneficiado pelas soluções tecnológicas de inspeção visual.

Nota-se um expressivo crescimento no interesse em pesquisa na temática entre os anos de 2017 e 2022, mesmo durante a pandemia de COVID19, fato que pode estar relacionado com a difusão da Indústria 4.0 no período. O Brasil figura nesse cenário com 10 trabalhos, sendo a maioria voltada para o feijão. Na comparação de continentes, os dados de publicações mostram que os continentes com maior produção agrícola, como Ásia (49%) e América do Norte e Sul (12%), lideram em publicações, mas a baixa contribuição de outros continentes como África (1%) e Oceania (2%) sugere áreas para potencial desenvolvimento.

Não obstante, o volume de publicações científicas sobre a temática apresenta uma correlação significativa com os volumes de produção e consumo de grãos. O gráfico da Figura 8 revelou um coeficiente de correlação $R^2=0,5827$ entre a produção agrícola e o volume de publicações, enquanto o gráfico da Figura 10 revelou um coeficiente $R^2=0,7178$ entre volume de publicações e volume de consumo de grãos.

Esses dados indicam que países com alta produção e consumo, como Brasil, Índia e China, também lideram as contribuições científicas. Não à toa, 5 dos 9 trabalhos propondo produtos com maior maturidade tecnológica são oriundos de China e Brasil (LIU *et al.*, 2018; SHEN *et al.*, 2020; CHEN *et al.*, 2020; XU *et al.*, 2021; BELAN *et al.*, 2020). No entanto, o fato de países com menor produção e consumo agrícola, que tendem a enfrentar barreiras econômicas e climáticas, apresentarem baixo volume de publicações, como observado na Coreia do Sul e Arábia Saudita, podem distorcer as conclusões sobre o assunto. Soma-se à isso o exemplo dos EUA que, apesar da importância econômica e tecnológica, e do alto volume de produção e consumo de grãos, não apresenta alto número de trabalhos científicos sobre a temática.

Com base nos dados e gráficos apresentados na seção de revisão bibliométrica (seção 2.2), outras inferências podem ser feitas para contribuir na compreensão sobre a temática investigada, algumas das quais estão elencadas a seguir:

a) Liderança de pesquisa por país:

- China, Índia, Turquia e Brasil concentram maior parte da pesquisa no campo de IVAGA. China e Brasil, inclusive possuem a maior parte dos trabalhos propondo hardware (LIU *et al.*, 2018; SHEN *et al.*, 2020; CHEN *et al.*, 2020; XU *et al.*, 2021; BELAN *et al.*, 2020)
- Relação entre produção científica e contexto agrícola local: países com alta produção de grãos tendem a liderar em publicações, mas exceções podem indicar interesse acadêmico motivado por outros fatores.

b) Evolução temporal das publicações

- Aumento significativo no número de publicações sobre o assunto nos últimos 5 anos, refletindo interesse crescente por tecnologias sobre IVAGA.

c) Cooperação a universidade e a indústria

- A baixa representatividade de instituições não acadêmicas indicadas nas afiliações dos autores pode estar associada à baixa maturidade das soluções tecnológicas e à pouca transferência de tecnologia no campo de IVAGA. Esse cenário sugere que, apesar do volume significativo de pesquisas, há desafios na transição do conhecimento gerado nas universidades para a indústria, possivelmente dificultando o desenvolvimento de inovações tecnológicas no setor produtivo.

Essas inferências ajudam a contextualizar o estado da arte da pesquisa e identificar oportunidades para aprofundamento, parcerias e aplicações práticas no campo de IVAGA.

4.2 Potencial de aplicação, desafios e tendências das tecnologias propostas na literatura para inspeção visual automática de grãos agrícolas

A literatura sobre IVAGA, composta por 137 estudos publicados na última década, contou com a contribuição científica de 27 países, evidenciando o interesse global na temática. Esses estudos exploram diversas abordagens, técnicas de aprendizado de máquina, tipos de imagens e atributos extraídos para o reconhecimento de padrões.

As principais técnicas aplicadas nesses estudos incluem Métodos Estatísticos, Aprendizagem de Máquina e Aprendizagem Profunda, cujo uso tem mais constante nos trabalhos mais recentes. No que se refere às imagens utilizadas, o padrão RGB predomina (106 estudos), mas tem sido crescente o uso de imagens hiperespectrais, principalmente nas análises baseadas em assinaturas espectrais. Quanto aos atributos extraídos das imagens, destacam-se os estatísticos, geométricos e hierárquicos. Esse último tem sido amplamente utilizado por conta do crescente uso da Aprendizagem de Máquina.

As aplicações principais da IVAGA podem ser agrupadas em três segmentos: classificação e identificação de variedades, detecção de defeitos e análise de qualidade, e suporte à tomada de decisão nos processos produtivos. A classificação de variedades é essencial para garantir a pureza de sementes e grãos e para otimizar

o manejo agrícola, sendo amplamente explorada por meio de técnicas de aprendizado de máquina e redes neurais profundas, como em Qadri *et al.* (2021) e Belan *et al.* (2020). A detecção de defeitos e a análise da qualidade dos grãos são aplicações relevantes para o controle de qualidade, reduzindo a subjetividade e aumentando a consistência das avaliações, como evidenciado nos trabalhos de Fan *et al.* (2024) e Belan *et al.* (2020). Por fim, tecnologias voltadas ao suporte à tomada de decisão visam otimizar processos produtivos, como no estudo de Antonucci *et al.* (2017). Apesar dos avanços, poucos estudos discutem a aplicabilidade industrial dessas tecnologias, o que representa um desafio para a adoção das tecnologias em larga escala.

No contexto da literatura sobre produtos de maior maturidade tecnológica, apenas nove estudos propõem soluções completas de hardware e software para inspeção visual de grãos. Eles apresentam SVCs que foram classificados de acordo com o Nível de Maturidade Tecnológica (TRL), variando entre 3 e 7. Os sistemas com TRL 3 ou 4, como os de Payman *et al.* (2018) e Gao *et al.* (2021), encontram-se em estágios iniciais de validação laboratorial, apresentando desafios significativos para a aplicação prática devido à dependência de condições controladas. Estudos classificados com TRL 5 ou 6, como os de Antonucci *et al.* (2017) e Shen *et al.* (2020), foram validados em ambientes relevantes e demonstram desempenho promissor, mas ainda enfrentam dificuldades como necessidade de calibração específica e adaptação a condições industriais adversas. Já os trabalhos com TRL 6 ou 7, como os de Fan *et al.* (2024) e Belan *et al.* (2020), estão mais próximos da aplicação comercial, sendo testados em ambientes reais e apresentando maior viabilidade para adoção na indústria.

Apesar dos avanços observados, a literatura revela desafios significativos para a transição dessas tecnologias para o mercado. Entre os principais obstáculos, destacam-se a redução de custos, a escalabilidade dos sistemas para ambientes não controlados, a necessidade de maior generalização das soluções para diferentes culturas agrícolas e complexidade operacional de algumas tecnologias. Para que essas tecnologias possam ser utilizadas na prática investimentos em pesquisa e desenvolvimento são fundamentais, além do estabelecimento de parcerias com a indústria agrícola para validação e implementação em larga escala.

Dessa forma, os trabalhos analisados demonstram grande potencial para a modernização do setor agrícola, desde que os desafios associados ao aumento do TRL sejam adequadamente superados. Testes em escala comercial e estratégias que

aproximem ciência e prática também são cruciais para reduzir o descompasso entre o avanço acadêmico e a implementação prática no setor agrícola.

4.2.1 Contribuições e desafios identificados na literatura

Os trabalhos analisados indicam que há um esforço significativo para conceber tecnologias de inspeção visual ao setor agrícola. As principais contribuições incluem:

- Automação e precisão: o uso de sistemas de visão computacional como os de Antonucci *et al.* (2017) e Belan *et al.* (2020) têm proporcionado maior eficiência na identificação de defeitos e impurezas em grãos.
- Acessibilidade: equipamentos como o proposto por Belan *et al.* (2020) demonstram a viabilidade de soluções baixo custo para inspeção de grãos em laboratórios de análises e pequenos agricultores.
- Análises integradas: estudos como os de Gao *et al.* (2021) mostram que combinar inspeção visual com outras técnicas, como espectroscopia, pode oferecer uma análise mais detalhada e precisa.

Por outro lado, os desafios incluem:

- Condições de campo: muitas das tecnologias são projetadas para operar em condições muito controladas, não estando preparadas para enfrentar dificuldades em ambientes agrícolas adversos (por exemplo, baixa luminosidade ou presença de poeira).
- Custos: Equipamentos avançados como os propostos em Chen *et al.* (2020) e Fan *et al.* (2024) podem apresentar custos elevados, restringindo sua adoção em larga escala, principalmente por empresas de menor porte.

4.3 Demandas tecnológicas na inspeção visual da qualidade de grãos e os desafios para a transferência de tecnologia no setor agrícola brasileiro


As análises apresentadas nesta seção foram subsidiadas pelos dados coletados por meio do questionário apresentado no Apêndice II, e permitiram as seguintes compreensões sobre o setor agrícola brasileiro: perfil dos respondentes; a maneira como as novas tecnologias são aplicadas; o conhecimento sobre as tecnologias para inspeção visual automática; as necessidades tecnológicas; e os desafios e barreiras para a transferência de tecnologia.

4.3.1 Perfil socioeconômico e profissional dos respondentes

Foram coletadas 101 respostas, das quais um respondente não concordou com o termo de consentimento. Os 100 respondentes que concordaram, e que compõem a base de dados da pesquisa, são oriundos de nove estados brasileiros, com a seguinte distribuição: Acre (1), Bahia (21), Ceará (1) Goiás (2), Minas Gerais (8), Paraná (4), Pernambuco (1), Rio Grande do Sul (1) e São Paulo (61).


No que tange ao grau de instrução indagado na questão 3, conforme pode ser visto no gráfico da Figura 23, as pessoas com ensino superior completo representam (21%) ou seja, o maior grupo dos respondentes. Os que possuem pós-graduação (especialização) são 14%, com mestrado 16%, com doutorado incompleto 4%, e com doutorado completo 13%, mostrando que a maior parte das respostas foi de pessoas com alta qualificação acadêmica.

Figura 23. Distribuição dos respondentes por grau de instrução




Fonte: Autor

Com relação ao ramo de atividade (pergunta 5), cujos resultados são mostrados no gráfico da Figura 24, observa-se que um terço atua na agricultura e a maior parcela (44%) na área de educação. Contudo, entre os respondentes da área da educação, seis atuam diretamente com grãos. Além disso, dos quatro respondentes que atuam na indústria, três estão envolvidos diretamente com a produção, comercialização, armazenamento ou industrialização de produtos agrícolas. Ainda neste sentido, 47% dos respondentes afirmam atuar em atividade relacionada com produtos agrícolas. Esses dados reforçam a relevância das respostas para a análises apresentadas nesta seção.

Figura 24. Distribuição dos respondentes por ramo de atividade

Fonte: Autor


Figura 25. Respondentes cuja atividade está diretamente relacionada com produtos agrícolas

Fonte: Autor

Apenas para aqueles que afirmaram atuar em atividades diretamente relacionadas com produção, comercialização, armazenamento ou industrialização de produtos agrícolas, que representam 47% dos respondentes, foi perguntado sobre tempo de experiência no setor agrícola, o nível do cargo que ocupa, e tipo(s) de produto(s) agrícola(s) ao qual(is) sua atividade está relacionada. As distribuições das respostas para essas perguntas estão mostradas nos gráficos das figuras 26 a 28.

No que se refere à experiência dos respondentes, como ilustrado no gráfico da Figura 26, a maioria (63%) possui mais de 10 anos de experiência. Esse resultado pode apontar que esses profissionais já poderiam ter tido acesso às tecnologias de inspeção visual automática, assim como aos benefícios proporcionados por elas.

Figura 26. Distribuição dos respondentes por tempo de experiência no setor agrícola




Fonte: Autor

Do total de respostas, apenas 17% têm até 5 anos, ou seja, provavelmente já entraram no setor agrícola vendo o uso de tecnologias habilitadoras da indústria 4.0, podendo apresentar maior aceitação das novas tecnologias, em comparação com as pessoas com maior tempo de experiência, que totalizam 83% dos respondentes.

O gráfico da Figura 27 mostra que o maior volume de respondentes para a pergunta 7 atua em cargos de nível operacional ou administrativo (52%). Profissionais que atuam em cargos dos níveis gerencial e estratégico, que podem desempenhar um papel fundamental na implementação de tecnologias modernas de IVAGA somam apenas 28% dos respondentes. Considerando que uma das barreiras para a transferência de tecnologia (TT) é a falta de disseminação das soluções tecnológicas e de seus benefícios, este fato pode impactar negativamente a adoção em larga escala das tecnologias pelo setor agrícola.


Figura 27. Distribuição dos respondentes por nível do cargo que ocupam



Fonte: Autor

O gráfico da Figura 28 apresenta a distribuição das respostas dos participantes para a pergunta 11 e indicaram o tipo de produto agrícola relacionado à atividade profissional que atuam, abrangendo produção, colheita, beneficiamento e industrialização. A análise dos dados revela que a maioria dos participantes atua no setor de grãos agrícolas, representando 49% do total de respondentes. Esse resultado indica que a distribuição do questionário foi eficaz no atingimento do seu público-alvo, assegurando uma representatividade significativa de profissionais diretamente envolvidos com a temática investigada neste trabalho.

Figura 28. Distribuição dos respondentes por tipo de produto ao qual sua atividade está relacionada



Fonte: Autor


Embora o foco do estudo seja identificar demandas, potenciais aplicações e desafios para a transferência de tecnologia relacionada à inspeção da qualidade visual de grãos, observa-se que uma parcela dos respondentes atua com outros produtos agrícolas. No entanto, este fato não interfere no interesse pelas tecnologias de inspeção visual, visto que suas aplicações se estendem à diferentes segmentos agrícolas.

4.3.2 Conhecimentos e percepções sobre as tecnologias para inspeção visual automática de grãos e sobre as expectativas e demandas do setor agrícola

O gráfico da Figura 29, contemplando a distribuição dos respondentes de acordo com as tecnologias que utilizam no local de trabalho (pergunta 12), mostra que a grande maioria dos profissionais (89%) utilizam predominantemente tecnologias convencionais, enquanto apenas 11% adotam tecnologias modernas como IoT, Robótica e Inteligência Artificial em seus ambientes de trabalho. Dos que ocupam

cargos gerenciais ou estratégicos e atuam em atividades diretamente relacionadas com grãos agrícolas, apenas 18% (2 pessoas) utilizam tecnologias modernas no local de trabalho. Isso sugere que pessoas que poderiam disseminar as tecnologias modernas para inspeção automática de grãos não tem acesso à essas tecnologias. Esse fato pode contribuir para os desafios e barreiras para que as tecnologias modernas de inspeção agrícola sejam adotadas em larga escala.

Figura 29. Tipos de tecnologias utilizadas no local de trabalho do respondente



Fonte: Autor

Os respondentes foram indagados, na questão 13, sobre seu conhecimento a respeito da existência de trabalhos científicos que propõem soluções para a IVAGA. Essa questão é essencial para compreender um dos fatores que podem inviabilizar ou dificultar a adoção de soluções tecnológicas para IVAGA. O gráfico da Figura 30 apresenta a distribuição das respostas obtidas.

O padrão das respostas indica possíveis lacunas na disseminação das pesquisas na temática em questão. O desconhecimento de estudos científicos (41%) ou a falta de acesso às soluções tecnológicas (63%) pode impactar negativamente a aceitação e a implementação dessas soluções no setor agrícola. Apenas 3% dos respondentes indicaram que a empresa onde atuam já implementou alguma solução tecnológica para IVAGA, o que sinaliza baixa transferência de tecnologia (TT) para o setor agrícola. Esse conhecimento é essencial para nortear futuras iniciativas de capacitação e divulgação científica, visando favorecer a adoção de tecnologias inovadoras na agricultura.


Figura 30. Distribuição dos respondentes de acordo com seus conhecimentos sobre trabalhos propondo tecnologias para IVAGA



Fonte: Autor

Quando perguntado aos respondentes sobre a importância das tecnologias para IVAGA na questão 14, Entre os respondentes 89% disseram ser importante a adoção de tecnologias modernas para automatizar as tarefas de inspeção visual da qualidade de grãos, conforme ilustrado na Figura 31. Esses dados, quando combinados com o padrão observado na questão anterior, sugerem a necessidade de maior investimento em estratégias que facilitem a integração dessas tecnologias ao setor agrícola.

Figura 31. Percepção dos respondentes sobre a importância das tecnologias para IVAGA




Fonte: Autor

A baixa adoção de soluções científicas no setor agrícola pode estar associada também à falta de incentivos financeiros e políticas públicas que promovam a inovação. A intensificação de parcerias entre instituições de pesquisa e empresas também pode ser um fator determinante para a implementação das tecnologias de inspeção visual. Dessa forma, medidas que favoreçam o desenvolvimento de infraestrutura tecnológica, capacitação profissional e divulgação científica podem contribuir significativamente para a modernização do setor agrícola.

Buscou-se investigar, por meio da questão 15, a percepção dos participantes sobre os níveis de contribuição (ou vantagens) das tecnologias de IVAGA, sob diferentes pontos de vistas. A distribuição das respostas está apresentada no gráfico da Figura 32.

Figura 32. Percepção dos respondentes sobre a contribuição das tecnologias de IVAGA



Fonte: Autor


De acordo com o gráfico, os respondentes percebem maiores contribuições para eficiência de processos (62%), garantia da qualidade (61%) e padronização dos resultados. Mais de 57% dos respondentes indicaram altos níveis de contribuição das tecnologias para apoio à tomada de decisão, maior eficiência de processos, aumento da competitividade empresarial, padronização dos resultados e garantia da qualidade dos produtos. Sob o aspecto da maior eficiência de processos no setor agrícola, percebe-se que para os 47% dos que atuam em atividades diretamente relacionadas com produtos agrícolas, mais da metade, 51% acham que o nível de contribuição das soluções tecnológicas é alto. Não obstante, quase metade desses 47% acredita que as tecnologias têm alto nível de contribuição para garantia da

qualidade dos produtos. Esses resultados apontam um reconhecimento positivo da aplicação de tecnologias modernas para a inspeção visual automática e estão em plena consonância com a literatura científica, como pode ser visto nos trabalhos de Anami *et al.* (2015), Antonucci *et al.* (2017), Brelan *et al.* (2020) e Fan *et al.* (2024).

Entretanto, no que se refere à redução de custos, muito mencionada na literatura, verificou-se um índice expressivo de respondentes que não souberam responder ou apresentaram dúvidas (20%) sobre os impactos financeiros dessas tecnologias. Esse desconhecimento pode representar uma barreira para adoção das tecnologias, uma vez que o retorno financeiro é um fator determinante na decisão para suas implementações. Empresas, cooperativas e seus gestores podem enfrentar dificuldades em visualizar um retorno imediato sobre o investimento, em virtude dos custos de aquisição e manutenção das tecnologias, bem como os custos inerentes à integração delas com processos tradicionais já estabelecidos, e com treinamento de mão de obra.

Na questão 16, os respondentes foram indagados sobre o grau de influência de diferentes fatores que podem desfavorecer a adoção de tecnologias para IVAGA. A distribuição das respostas, apresentada no gráfico da Figura 33, permitiu identificar outros elementos que podem dificultar a implementação das tecnologias em questão, contribuindo para uma compreensão mais aprofundada dos desafios enfrentados no setor agrícola.

Figura 33. Percepção dos respondentes sobre fatores que desfavorecem o emprego de tecnologias para IVAGA



Fonte: Autor

A necessidade de mão de obra qualificada é apontada como sendo um dos fatores que desfavorecem a adoção de tecnologias modernas para a IVAGA. Do total

de respondentes, 41% reconheceram a necessidade de profissionais qualificados como um fator de grande impacto na limitação da implementação dessas tecnologias. Ressalta-se que entre os respondentes que atuam em atividades diretamente relacionadas com produtos agrícolas, 34% (16 pessoas) consideram esse fator como uma barreira significativa para a adoção de tecnologias voltadas à IVAGA.

A resistência cultural também representa uma barreira substancial, visto que 34% dos respondentes indicaram que a necessidade de mudanças em processos/formas de trabalho é um fator de alto impacto no desfavorecimento da adoção das tecnologias. Produtores acostumados com métodos tradicionais podem demonstrar resistência à mudança, especialmente aqueles que têm dúvidas sobre o custo/benefício das novas tecnologias, mencionados na questão anterior. Outro destaque é o fato de 12% dos respondentes não saberem se os fatores indicados favorecem ou desfavorecem o uso das tecnologias modernas de inspeção, o que corrobora a carência de conhecimento e contato com essas tecnologias.

As respostas para a questão 17, sobre os fatores mais importantes para viabilizar o emprego em larga escala de tecnologias IVAGA, apresentadas no gráfico Figura 34, evidenciam que os principais fatores apontados pelos respondentes que podem viabilizar a adoção em larga escala de tecnologias para a IVAGA são a capacitação de mão de obra para lidar com as novas tecnologias (65%) e ampla divulgação dessas tecnologias (53%), corroborando padrões encontrados em questões anteriores. Mesmo quando se considera apenas os respondentes que atuam em atividades diretamente relacionadas com produtos agrícolas, 69% (ou 32 pessoas) consideram a capacitação de mão-de-obra como fator importante para viabilizar o emprego das tecnologias.

Figura 34. Percepção dos respondentes sobre os fatores mais importantes para viabilizar o emprego de tecnologias de IVAGA



Fonte: Autor

Além disso, a capacitação adequada de mão de obra também pode contribuir para a redução de erros operacionais e para o aumento da confiabilidade dos processos de inspeção. A promoção de programas de qualificação técnica específicos para esse campo pode acelerar a adoção das novas tecnologias de inspeção para aumentar eficiência e competitividade do setor agrícola. Em outras palavras, a capacitação de mão de obra pode ser um fator-chave para reduzir as barreiras que dificultam a adoção das tecnologias modernas de inspeção no setor agrícola.

Ainda com relação à questão 17 (gráfico da Figura 34), destacam-se ainda os fatores “desenvolvimento de tecnologias que vão ao encontro das necessidades do setor agrícola” (49%), corroborando a lacuna apontada na seção 1.2 sobre possível descompasso entre as soluções propostas na literatura e suas aplicações efetivas na indústria agrícola; “criação ou ampliação de linhas de crédito para aquisição das tecnologias” (47%), “redução de custo para aquisição das tecnologias” (45%) e “vantagens econômicas” (38%), que corroboram o desconhecimento sobre custo/benefício das tecnologias; “maior integração entre os campos acadêmico e empresarial” (47%), que está alinhado ao fato de boa parte dos respondentes desconhecerem tanto os trabalhos científicos quanto as tecnologias modernas de inspeção produzidas a partir deles; e “desenvolvimento de tecnologias facilmente adaptáveis ao ambiente de trabalho” (46%), que está em consonância com as preocupações sobre a falta de mão de obra capacitada no país.

5. CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

A integração de métodos computacionais e hardware avançado vem revolucionando a agricultura, tornando os processos de inspeção visual mais sustentáveis, aumentando a qualidade dos produtos e a competitividade do setor agrícola. No entanto, apesar de inúmeras soluções tecnológicas de inspeção de grãos terem sido introduzidas na literatura, especialmente na última década, raros são os estudos que abordam de maneira explícita a aplicação dessas soluções no contexto industrial. Além disso, nenhum dos 137 trabalhos incluídos no levantamento bibliográfico realizado na presente pesquisa discutiu questões relacionadas à transferência de tecnologia. Neste contexto, foram formuladas as seguintes questões de pesquisa: Q1 – O volume de pesquisa científica sobre inspeção visual automática dos principais grãos reflete suas relevâncias no mercado global? e Q2 – Qual é a maturidade tecnológica das soluções para inspeção visual automática de grãos e quais barreiras impedem sua adoção na indústria agrícola? Para responder essas questões foram estabelecidos quatro objetivos específicos (O1 a O4), os quais foram plenamente alcançados por meio da aplicação dos métodos revisão bibliométrica, RSL, e *survey*, como segue:

O1 – Sintetizar o estado atual do conhecimento sobre a temática para identificar os grãos mais beneficiados pelas tecnologias de inspeção visual agrícola, a evolução ao longo do tempo, a distribuição geográfica da pesquisa e as tendências: esse objetivo foi atingido por meio da revisão bibliométrica, que permitiu identificar que o arroz se destaca com 41% das publicações (59 estudos), seguido pelo trigo (27%; 39 estudos) e milho (18%; 26 estudos). Apesar de sua relevância no Brasil, o feijão correspondeu a apenas 7% (10 estudos) e a soja, 4% (7 estudos). Os estudos foram conduzidos em 27 países, com um aumento expressivo de publicações entre 2017 e 2022, provavelmente impulsionado pelo avanço da Indústria 4.0 e pela demanda por automação na agricultura. As pesquisas empregam majoritariamente Aprendizagem de Máquina e Aprendizagem Profunda, sendo a primeira técnica utilizada em 68 estudos e a segunda em 41. As imagens RGB predominam (106 estudos). Quanto aos descritores extraídos das imagens, os mais comuns são estatísticos (51 estudos), representações hierárquicas e abstratas (43) e geométricos (12).

O2 – Investigar possíveis correlações entre a produção e/ou consumo de grãos e a quantidade de publicações científicas sobre inspeção visual automática nos países mais ativos nesse campo de pesquisa: esse objetivo foi atendido por meio da análise quantitativa que indicou uma correlação significativa entre o volume de produção e

consumo de grãos e o número de publicações científicas sobre inspeção visual automática. Foi identificado um coeficiente de correlação $R^2 = 0,5827$ entre produção agrícola e volume de publicações e $R^2 = 0,7178$ entre consumo de grãos e publicações científicas. Apesar dos resultados indicarem que países com grande produção e consumo de grãos, como Brasil, China e Índia, lideram as contribuições científicas na temática, casos como o dos EUA levaram a conclusão de que outros fatores como avanços tecnológicos, exigências regulatórias, incentivos financeiros e desafios específicos, também podem ser fatores motivados de pesquisas na temática.

O3 – Conduzir uma análise abrangente da literatura científica para mapear as principais aplicações de inspeção visual automática de grãos agrícolas e classificá-las conforme seu grau de maturidade tecnológica: esse objetivo foi alcançado por meio da RSL, a partir da qual verificou-se as principais aplicações das tecnologias de inspeção visual automática – classificação e identificação de variedades, detecção de defeitos e análise da qualidade dos grãos, e suporte à tomada de decisão nos processos produtivos) – e que o nível de maturidade tecnológica (TRL) da maioria das tecnologias ainda está em fase laboratorial (TRL 3 ou 4) ou de validação em ambientes controlados (TRL 5 ou 6).

O4 – Investigar os desafios e limitações para a implementação em larga escala tecnologias propostas para inspeção visual automática de grãos agrícolas: esse objetivo foi atendido pela análise dos desafios apontados na RSL e pelos dados coletados via questionário. Os principais desafios identificados incluem a baixa disseminação da tecnologia – 63% dos respondentes não conhecem as soluções científicas para inspeção visual automática de grãos; a falta de mão de obra qualificada – 41% indicaram que a ausência de profissionais capacitados dificulta a implementação dessas tecnologias; custos elevados e falta de incentivos financeiros – a necessidade de crédito e a percepção de altos custos foram apontadas como barreiras à adoção; resistência cultural e adaptação ao ambiente agrícola – muitos produtores ainda utilizam tecnologias convencionais (89%) e mostram resistência a mudanças.

O alcance dos objetivos específicos e, conseqüentemente, do objetivo geral proporcionou as seguintes respostas às questões de pesquisa:

Q1 – Apesar de os grãos mais produzidos e consumidos no mundo figurarem entre os mais beneficiados pelas tecnologias da literatura para inspeção visual automática de grãos e de haver uma correlação significativa entre os volumes de produção/consumo de grãos e o volume de artigos publicados por boa parte dos

países com relevância na temática investigada, outros fatores também podem estar associados às motivações das pesquisas na temática. Aspectos como avanços tecnológicos, exigências regulatórias, incentivos financeiros e desafios específicos, também influenciam a pesquisa. Um exemplo disso são os EUA, que, apesar de sua importância econômica e tecnológica e do alto volume de produção e consumo de grãos, não contribuem proporcionalmente para a literatura científica sobre a temática.

Q2 – As tecnologias de inspeção visual automática de grãos ainda se encontram em estágios variados de maturidade, com a maioria das soluções identificadas na literatura situadas entre TRL 3 e TRL 6, indicando que elas ainda estão em fase laboratorial ou de validação em ambientes controlados. Apenas alguns poucos estudos apresentam tecnologias mais avançadas (TRL 6 ou 7), com testes próximos da aplicação comercial, como nos estudos de Antonucci et al. (2017), Belan et al. (2020) e Fan et al. (2024). As principais barreiras para adoção dessas tecnologias na indústria agrícola incluem a adaptação ao ambiente agrícola – muitos SVCs são projetados para ambientes controlados e enfrentam dificuldades operacionais em condições reais de campo, falta de disseminação do conhecimento, necessidade de mão de obra qualificada, custo de algumas tecnologias e viabilidade econômica incerta, resistência cultural e baixa integração entre pesquisa e indústria.

A partir dos resultados obtidos na pesquisa, foi possível identificar demandas e desafios para a transferência de tecnologia no setor agrícola. As principais demandas identificadas foram:

Capacitação de mão de obra – os achados da pesquisa revelaram que 41% dos respondentes apontaram a falta de profissionais qualificados como um dos principais obstáculos à adoção de tecnologias de IVAGA, demonstrando a necessidade de treinamento técnico especializado para facilitar a implementação dessas soluções.

Maior disseminação das tecnologias – de acordo com os resultados, a baixa adoção das soluções tecnológicas de IVAGA no setor agrícola pode ser atribuída, em partes, à falta de conhecimento sobre suas vantagens e aplicações. Foi observada baixa representatividade de instituições não acadêmicas indicadas nas afiliações dos autores dos trabalhos da literatura, podendo ser indicativo de pouca cooperação entre universidade e indústria no campo de IVAGA. Cerca de 63% dos respondentes indicaram desconhecimento sobre a existência de soluções científicas para IVAGA, sugerindo a necessidade de mais divulgação, tanto pela academia quanto pela indústria. Em adição, a RSL revelou que, embora existam avanços tecnológicos

significativos, a maioria dos trabalhos não aborda explicitamente a transferência de tecnologia para a indústria. A falta de divulgação e demonstração prática dessas soluções pode estar limitando sua adoção. Contudo, um contraponto pode ser notado: apesar do desconhecimento, 89% das pessoas que responderam ao questionário acreditam que tecnologias de inspeção visual são importantes para aumentar a eficiência e automatizar tarefas agrícolas, o que vai ao encontro da literatura que relata altas taxas de acurácia (acima de 95%) em diversas aplicações, como as de Fan et al. (2024) e Belan et al. (2020).

Apoio financeiro e incentivos – os resultados apontam que 47% dos respondentes acreditam que a criação ou ampliação de linhas de crédito é fundamental para viabilizar a adoção dessas tecnologias. O custo de aquisição e manutenção pode ser uma barreira significativa para pequenos e médios produtores.

Os principais desafios para a transferência de tecnologia identificados na pesquisa foram:

Adaptação às condições de campo – é possível observar um descompasso entre as pesquisas científicas e a demanda do setor agrícola por produtos inovadores. Isso ocorre, em parte, devido à baixa maturidade das soluções tecnológicas propostas na literatura, que ainda não conseguem atender completamente às necessidades do mercado. muitas dessas soluções foram desenvolvidas em ambientes laboratoriais controlados e enfrentam dificuldades para operar em condições reais de produção agrícola, como variações climáticas e presença de poeira. Isso foi verificado também nas soluções tecnológicas com maior maturidade (TRL 5 e 6), como as propostas em Shen et al. (2020), Chen et al. (2020), Liu et al. (2018), Antonucci et al. (2017), Belan et al. (2020) e Fan et al. (2024). Isso está alinhado com as percepções detectadas por meio do questionário, que evidenciaram que apenas 3% dos respondentes atuam em empresas que implementaram soluções para inspeção visual automática. Os respondentes podem ter expectativas superestimadas quanto ao nível de prontidão das tecnologias. Como a maioria das soluções ainda está em fase de desenvolvimento e validação, há uma lacuna entre as expectativas do setor agrícola e o real estágio de evolução dessas tecnologias.

Resistência cultural e falta de aceitação tecnológica – os resultados mostram que 34% dos entrevistados apontaram a resistência a mudanças nos processos produtivos como um fator de alto impacto na adoção dessas tecnologias. Muitos produtores ainda utilizam métodos tradicionais e hesitam em investir em soluções automatizadas.

Alto custo e viabilidade econômica – a implementação de parte das tecnologias modernas exige investimentos iniciais elevados, o que pode desestimular pequenos e médios produtores. Além disso, a falta de clareza sobre o retorno financeiro dificulta a adoção em larga escala. É importante destacar que alguns sistemas, como o de Belan et al. (2020), foram desenvolvidos com baixo custo e projetados para pequenas empresas e laboratórios. No entanto, equipamentos avançados como os de Chen et al. (2020) e Fan et al. (2024) ainda apresentam custos elevados, limitando sua implementação comercial. Ressalta-se que os respondentes do questionário provavelmente não têm acesso a dados claros sobre os benefícios econômicos dessas tecnologias, o que reduz a confiança na adoção. A literatura também não aborda suficientemente os custos de implementação, contribuindo para essa incerteza.

A pesquisa evidenciou que, apesar do grande potencial da inspeção visual automática para modernizar a agroindústria, sua adoção ainda enfrenta desafios estruturais e culturais. A superação dessas barreiras requer um esforço conjunto entre instituições de pesquisa, indústria agrícola e governo para desenvolver estratégias que promovam a capacitação profissional, viabilizem o financiamento e incentivem a transferência de tecnologia para o setor produtivo.

Nesse contexto, incentivos governamentais podem representar um caminho promissor para reduzir esse descompasso entre a academia e o setor produtivo.

A principal contribuição desta pesquisa para a teoria foi fornecer uma análise abrangente e sistemática sobre a evolução das tecnologias de IVAGA, identificando potenciais aplicações, padrões de produção científica, maturidade tecnológica das soluções propostas e desafios para sua adoção. Além disso, a pesquisa ampliou o conhecimento evidenciando que embora existam relações entre o desenvolvimento de pesquisa e a produção/consumo de grãos, fatores econômicos e estruturais também influenciam o desenvolvimento das tecnologias de IVAGA. Para a prática, a pesquisa revelou um descompasso entre as demandas do setor agrícola e a literatura científica, apontando que, apesar dos avanços tecnológicos, os estudos não abordam aplicabilidade industrial e transferência de tecnologia. Além disso, revelou os principais desafios para viabilizar a adoção das tecnologias de IVAGA na agroindústria.

A ausência de um levantamento sobre tecnologias de IVAGA em bases de patentes representa uma limitação deste estudo. Países reconhecidos por investimentos expressivos em ciência, tecnologia e inovação, como Japão, Coreia do

Sul e Alemanha, possuem um histórico consolidado de colaboração entre universidades e a indústria. Nessas nações, a transferência de conhecimento frequentemente ocorre por meio do registro de patentes em vez da publicação de trabalhos científicos da forma convencional. Dessa maneira, a aparente baixa representatividade desses países no número de publicações científicas sobre IVAGA pode não refletir a real magnitude das pesquisas desenvolvidas neste campo, mas sim uma estratégia de proteção intelectual voltada para aplicações industriais.

Visando aumentar o impacto e a robustez da pesquisa sugere-se, como trabalhos futuros, ampliar a abrangência da *survey* levando em conta maior número de pessoas que atuam em atividades diretamente relacionadas com grãos agrícolas, bem como combinar o levantamento bibliográfico com levantamento em bases de patentes visando fornecer um panorama mais abrangente das inovações tecnológicas existentes e mitigar possíveis vieses na caracterização do estado da arte. Outra frente de pesquisa, é a ampliação do campo de inspeção levando em conta outros produtos agrícolas.

REFERÊNCIAS

- AGGARWAL, S; SUCHITHRA, M.; CHANDRAMOULI, N.; SARADA, M.; VERMA, A.; VETRITHANGAM, D.; AMBACHEW ADUGNA, B. Rice Disease Detection Using Artificial Intelligence and Machine Learning Techniques to Improve Agro-Business. **Scientific Programming**, v. 2022, n. 1, p. 1757888, 2022.
- ALI, M. M.; HASHIM, N.; ABD AZIZ, S.; LASEKAN, O. Quality Inspection of Food and Agricultural Products using Artificial Intelligence. **Advances in Agricultural and Food Research Journal**, v. 2, n. 2, 2021. DOI: <https://doi.org/10.36877/aafjr.a0000237>
- ALVES, V.; AMARANTE SEGUNDO, G. S.; SAMPAIO, R. R. **Reflexões sobre as competências dos núcleos de inovação tecnológica**. 2015.
- ANTONUCCI, F.; FIGORILLI, S.; COSTA, C.; PALLOTTINO, F.; SPANU, A.; MENESATTI, P. An open source conveyor belt prototype for image analysis-based rice yield determination. *Food and Bioprocess Technology*, v. 10, n. 6, p. 1257–1264, 2017. DOI: 10.1007/s11947-017-1895-2.
- ARAÚJO, S. A.; ALVES, W. A. L.; BELAN, P. A.; ANSELMO K. P. A Computer Vision System for Automatic Classification of Most Consumed Brazilian Beans. **Lecture Notes in Computer Science** (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), v. 9475, p. 45-53, 2015.
- AUDU, J.; AREMU, A. K. Development, evaluation, and optimization of an automated device for quality detection and separation of cowpea seeds. **Artificial Intelligence in Agriculture**, v. 5, p. 240-251, 2021.
- AYAZ, M.; AMMAD-UDDIN, M.; SHARIF, Z.; MANSOUR, A.; AGGOUNE, E. M.; Internet-of-Things (IoT)-based smart agriculture: Toward making the fields talk. **IEEE access**, v. 7, p. 129551-129583, 2019. DOI 10.1109/ACCESS.2019.2932609
- BALINGBING, C. B.; KIRCHNER, S.; SIEBALD, H.; KAUFMANN, H. H.; GUMMERT, M.; VAN HUNG, N.; HENSEL, O Application of a multi-layer convolutional neural network model to classify major insect pests in stored rice detected by an acoustic device. **Computers and Electronics in Agriculture**, v. 225, p. 109297, 2024.

BASSOI, L. H. **Agricultura de Precisão e agricultura digital**. EMBRPA, 2019. Disponível em: <http://www.alice.cnptia.embrapa.br/alice/handle/doc/1121544> Acesso em: 01 dez 2024.

BELAN, P. A., ARAÚJO, S. A.; SANTANA, J. C. C. Um Sistema De Análise De Imagens Para Classificação Automática De Grãos De Feijão Brasileiro. In: **CILAMCE-Ibero-Latin American Congress on Computational Methods in Engineering**. 2015. p. 1-7.

BELAN, P. A.; MACEDO, R. A. G.; ALVES, W. A. L.; SANTANA, J. C. C.; ARAÚJO, S. A. Machine vision system for quality inspection of beans. **The International Journal of Advanced Manufacturing Technology**, v. 112, n. 1-2, p. 271-282, 2020. DOI: 10.1007/s00170-020-06226-5.

BELAN, P. A.; DE MACEDO, R. A.G.; DE ARAÚJO, SIDNEI A. Computer Vision Approaches to Detect Bean Defects. In: **Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 24th Iberoamerican Congress, CIARP 2019, Havana, Cuba, October 28-31, 2019, Proceedings 24**. Springer International Publishing, 2019. p. 336-345.

BNDES. Definições de termos relacionados à inovação. Banco Nacional de Desenvolvimento Econômico e Social, 2023. Disponível em: <https://www.bndes.gov.br/wps/portal/site/home/onde-atuamos/inovacao/politica-apoio-inovacao/Definicoes-de-termos-relacionados-a-inovacao>. Acesso em: 15 fev. 2025.

BROSNAN, T.; SUN, D.-W. Quality inspection and grading of agricultural and food products by computer vision systems - A review. **Computers and Electronics in Agriculture**, v. 36, n. 2-3, p. 193-213, 2002.

BUAINAIN, A. M.; CAVALCANTE, P.; CONSOLINE, L. **Estado atual da agricultura digital no Brasil**: inclusão dos agricultores familiares e pequenos produtores rurais. 2021.

BUAINAIN, A. M.; SANTANA, C. A.; SILVA, F. P.; GARCIA, J. R.; LOYOLA, P. **O tripé da política agrícola brasileira**. Cp.02 págs. 829 - 864

CARVALHO, M. DA S. **Contribuições da prospecção tecnológica e fatores influenciadores da transferência de tecnologia pela ótica dos pesquisadores-inventores**. 2019. 73f. Dissertação (Mestrado Profissional em Gestão e Estratégia) - Instituto de Ciências Sociais Aplicadas, Departamento de Ciências Administrativas e Contábeis, Universidade Federal Rural do Rio de Janeiro, Seropédica, Rio de Janeiro, 2019.

CATANEO, J. V.; CAVICHIOLO, F. A. AGRICULTURA DE PRECISÃO: o uso da agricultura digital no campo. **Revista Interface Tecnológica**, [S. l.], v. 20, n. 1, p. 435–446, 2023. DOI: 10.31510/inf.v20i1.1575. Disponível em: <https://revista.fatectq.edu.br/interfacetecnologica/article/view/1575>. Acesso em: 1 dez. 2024.

CHAPARRO-BANEGAS, N.; SÁNCHEZ-GARCIA, M.; CALAFAT-MARZAL, C.; ROIG-TIERNO, N. Transforming the agri-food sector through eco-innovation: A path to sustainability and technological progress. **Business Strategy and the Environment**, 2024.

CHEN, J.; LIAN, Y.; LI, Y. Real-time grain impurity sensing for rice combine harvesters using image processing and decision-tree algorithm. **Computers and Electronics in Agriculture**, v. 175, p. 105591, 2020. DOI: 10.1016/j.compag.2020.105591.

CLOSS, L. Q; FERREIRA, G. C. A transferência de tecnologia universidade-empresa no contexto brasileiro: uma revisão de estudos científicos publicados entre os anos 2005 e 2009 - PPGAd, **Faculdade de Administração Contabilidade e Economia. FACE, Pontifícia Universidade Católica do Rio Grande do Sul. PUCRS**, 2012.

COHEN, J. **Statistical power analysis for the behavioral sciences**. Routledge, 2013.

CONAB. COMPANHIA NACIONAL DE ABASTECIMENTO **Mercado Nacional: Feijão comum**. Disponível em: <https://portaldeinformacoes.conab.gov.br/produtos-360.html>. Acesso em: 01 dez. 2024.

CRESWELL, J.W. Research design. qualitative, quantitative and mixed methods approaches. 3 ed. New York: Sage, 2009.

DA FONSECA, L. T. M.; VENUTO, P. B.; DE ANDRADE, V. S. B.; FERREIRA, R. N. AS TRANSFORMAÇÕES DO AGRONEGÓCIO ANALISADAS MATEMATICAMENTE POR MEIO DE CONCEITOS DA PESQUISA OPERACIONAL. **Revista Tópicos**, v. 2, n. 11, p. 1-15, 2024.

DE ARAÚJO, S. A.; PESSOTA, J. H.; KIM, H. Y. Beans quality inspection using correlation-based granulometry. **Engineering Applications of Artificial Intelligence**, v. 40, p. 84-94, 2015.

DE SOUSA, D. N.; NIEDERLE, P. A. A produção científica brasileira sobre o que se entende por inclusão produtiva: um recorte temporal entre 2005 a 2016. **Revista Desenvolvimento Social**, v. 23, n. 1, p. 15-32, 2018. ISSN 2179-6807

DIAS, F. X.; VENTURA, R.; BUENO, M. P. Transferência de tecnologia na Agricultura 4.0. **REVISTA OBSERVATORIO DE LA ECONOMIA LATINOAMERICANA** Curitiba, v.21, n.11, p. 21865-21887. 2023.

DIN, N. M. U.; ASSAD, A.; DAR, R. A.; RASOOL, M.; SABHA, S. U.; MAJEED, T.; YASEEN, A. RiceNet: A deep convolutional neural network approach for classification of rice varieties. **Expert Systems with Applications**, v. 235, p. 121214, 2024.

DING, Y. Scientific collaboration and endorsement: Network analysis of coauthorship and citation networks. **Journal of Informetrics**, v. 5, n. 1, p. 187-203, 2011.

EMBRAPA. LORINI, I.; KRZYZANOWSKI, F. C.; FRANÇA-NETO, J. D. B.; HENNING, A. A.; HENNING, F. A. **Manejo Integrado de Pragas de Grãos e Sementes Armazenadas**, 2015. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1022859/1/Livropragas.pdf> Acesso em: 1 dez. 2024

EMBRAPA. **Manual De Classificação Do Feijão**, Instrução Normativa N° 12, de 28 de março de 2008. Disponível em: http://www.felgran.com.br/images/Classificacao_Feijao_Embrapa.pdf. Acesso em: 1 de nov. 2022.

FAN, L.; FAN, D.; DING, Y.; WU, Y.; CHU, H.; PAGNUCCO, M.; SONG, Y. AV4GAIInsp: an efficient dual-camera system for identifying defective kernels of cereal grains. **IEEE Robotics and Automation Letters**, v. 9, n. 1, p. 851–859, 2024. DOI: 10.1109/LRA.2023.3338517.

FERREIRA, A. S.; ALMEIDA, A. N. A relação inversa entre o tamanho das propriedades agrícolas e a produtividade no Brasil: uma análise não paramétrica usando regressões kernel. **Revista de Economia e Sociologia Rural**, 59 (3), e224128. 2021. DOI <https://doi.org/10.1590/1806-9479.2021.224128>.

FORZA, C. Survey research in operations management: a process-based perspective. **International journal of operations & production management**, v. 22, n. 2, p. 152-194, 2002.

GAO, T.; CHANDRAN, A. K. N.; PAUL, P.; WALIA, H.; YU, H. HyperSeed: an end-to-end method to process hyperspectral images of seeds. **Sensors**, v. 21, n. 24, p. 8184, 2021. DOI: 10.3390/s21248184.

GIL, A. C. **Como elaborar projetos de pesquisa. 5 ed.** São Paulo: Atlas, 2010.

GIUSTI, L. L.; RIBEIRO, S. P. H. C.; DE SÁ, C. D.; GILIO, L. TEMPOS DE CRISE: UMA ANÁLISE DAS MANIFESTAÇÕES AGRÍCOLAS NA EUROPA. **agro.insper.edu.br**

HUANG, Y.; JIANG, X.; FANG, Y. A Novel Method for Filled/Unfilled Grain Classification Based on Structured Light Imaging and Improved PointNet++. **Computers in Industry**, v. 133, p. 103958, 2023. DOI: 10.1016/j.compind.2022.103958

KILIÇARSLAN, S.; KILIÇARSLAN, S. A comparative study of bread wheat varieties identification on feature extraction, feature selection and machine learning algorithms. **Journal of Food Engineering**, v. 12, p. 56-78, 2024.

KUMAR, R. **Research methodology. a step-by-step guide for beginners.** 3 ed. London: Sage, 2011.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing.** 1. Ed. Massachusetts: Addison-Wesley, 2002.

GROVES, R. M.; FOWLER Jr, F. J.; COUPER, M. P.; LEPKOWSKI, J. M.; SINGER, E.; TOURANGEAU, R. **Survey methodology.** John Wiley & Sons, 2009.

HÉDER, M. From NASA to EU: The evolution of the TRL scale in Public Sector Innovation. **The Innovation Journal**, v. 22, n. 2, p. 1-23, 2017.

LIKERT, RENSIS (1932), **A Technique for the Measurement of Attitudes**, Archives of Psychology, 140: 1-55

LIN, P.; LI, X. L.; CHEN, Y. M.; HE, Y. A Deep Convolutional Neural Network Architecture for Boosting Image Discrimination Accuracy of Rice Species. **Journal of Agricultural Informatics**, v. 14, n. 4, p. 34-49, 2018. DOI: 10.1007/s10694-018-9077-2.

LIU, S.; ZHANG, H.; WANG, Z.; ZHANG, C.; LI, Y.; WANG, J. Determination of maize seed purity based on multi-step clustering. **Applied Engineering in Agriculture**, v. 34, n. 4, p. 659–665, 2018. DOI: 10.13031/aea.12421.

LIU, S.; ZHANG, H.; WANG, Z.; ZHANG, C.; LI, Y.; WANG, J. Determination of maize seed purity based on multi-step clustering. *Applied Engineering in Agriculture*, v. 34, n.

NAYAK, J.; DASH, P. B.; NAIK, B. An Advance Boosting Approach for Multiclass Dry Bean Classification. **Computers and Electronics in Agriculture**, v. 189, p. 106351, 2023.

MACUÁCUA, JAIME CARLOS; CENTENO, JORGE ANTÓNIO SILVA; AMISSE, CAÍSSE. Data mining approach for dry bean seeds classification. **Smart Agricultural Technology**, v. 5, p. 100240, 2023. DOI: <https://doi.org/10.1016/j.atech.2023.100240>

BELAN, P. A.; DE MACEDO, R. A. G.; ALVES, W. A. L.; SANTANA, J. C. C.; ARAUJO, S. A. Machine vision system for quality inspection of beans. **The International Journal of Advanced Manufacturing Technology**, v. 111, p. 3421-3435, 2020.

MANKINS, J. C. **Technology Readiness Levels. A White Paper**. Advanced Concepts Office. Office of Space Access and Technology. NASA. abril, 1995 Disponível em: <http://www.artemisinnovation.com/images/TRL_White_Paper_2004-Edited.pdf> Acessado em: 01 dez 2024.

MAPA - MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO, **Regras para Análise de Sementes**, 2009 disponível em: https://www.gov.br/agricultura/pt-br/assuntos/insumos-agropecuarios/arquivos-publicacoes-insumos/2946_regras_analise__sementes.pdf. Acesso em 24 dez 2024.

MASSRUHÁ, S. M. F. S.; LEITE, M. D. A. Agro 4.0-rumo à agricultura digital. **Livro JC na Escola Ciência, Tecnologia e Sociedade**: Centro Paula Souza. Págs. 30-37, 2017.

MOHER, D.; LIBERATI, A.; TETZLAFF, J.; ALTMAN, D. G.; PRISMA GROUP*, T. Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement. **International Journal of Surgery**, v. 8, n. 5, p. 336–341, 2010.

DE OLIVEIRA NETO, G. C., PINTO, L. F. R.; AMORIM, M. P. C.; GIANNETTI, B. F.; DE ALMEIDA, C. M. V. B. A framework of actions for strong sustainability. **Journal of Cleaner Production**, v. 196, p. 1629–1643, 2018.

DE SOUSA, M. N.A.; DE OLIVEIRA ALMEIDA, ELZENIR P.; BEZERRA, ANDRÉ LUIZ D. Bibliometria: O que é? Para que serve? E como se faz? **Cuadernos de Educación y Desarrollo**, 2024. DOI: 10.55905/cuadv16n2-021

PATIL, N. K.; YADAHALLI, R. M.; PUJARI, J. Comparison between HSV and YCbCr Color Model Color-Texture based Classification of the Food Grains. **International Journal of Computer Applications**, v. 34, n. 4, p. 51-57, 2011.

PAYMAN, S. H.; BAKHSHIPOUR, A.; ZAREIFOROUGH, H. Development of an expert vision-based system for inspecting rice quality indices. **Quality Assurance and Safety of Crops & Foods**, v. 10, n. 1, p. 103–114, 2018. DOI: 10.3920/QAS2017.1109.

QADRI, S.; ASLAM, T.; NAWAZ, S. A.; SAHER, N.; RAZZAQ, A.; UR REHMAN, M.; FURQAN QADRI, S A Machine vision approach for classification the rice varieties using statistical features. **International Journal of Food Properties**, v. 23, p. 123-139, 2021.

RATHNAYAKE, N.; MIYAZAKI, A.; DANG, T. L.; HOSHINO, Y Age Classification of Rice Seeds in Japan Using Gradient-Boosting and ANFIS Algorithms. **Agricultural Research**, v. 16, p. 401–414, 2023.

REISMAN, ARNOLD. **Transfer of technologies: a cross-disciplinary taxonomy**. *Omega*, v. 33, n. 3, p. 189-202, 2005. DOI:i:10.1016/j.omega.2004.04.004

RÉVILLION, J. P. P.; PADULA, A. D.; FEDERIZZI, L. C.; MARTINELLI JÚNIOR, O.; MANGEMATIN, V. Estudo do processo de inovação tecnológica no setor agroindustrial: estudos de caso na cadeia produtiva de leite fluido no sistema setorial de inovação da França. **Revista de Administração Contemporânea**, v. 8, p. 75-98, 2004.

RODRIGUES, L. S.; CAPANEMA, L. X. D. L.; GUIMARÃES, D. D.; CARNEIRO, J. V. A. Inovação na indústria de alimentos: importância e dinâmica no complexo agroindustrial brasileiro. **BNDES Setorial**, n. 37, mar. 2013, p. 333-370, 2013.

SALISH, K.; GAMBOA, J. A.; AMBROSE, K. Analysis of Broken Rice Kernels Using an Android Application. **Applied Engineering in Agriculture**, v. 38, n. 2, p. 401-408, 2022.

SANTOS, K. L. D.; PANIZZON, J.; CENCI, M. M.; GRABOWSKI, G.; JAHNO, V. D. Perdas e desperdícios de alimentos: reflexões sobre o atual cenário brasileiro. **Brazilian Journal of Food Technology**, v. 23, p. e2019134, 2020.

SCHWAB, K. **The fourth industrial revolution**. *Nature Nanotechnology*, 10(12), 1005–1006, 2015. DOI <https://doi.org/10.1038/nnano.2015.286>.

SHEN, F.; HUANG, Y.; JIANG, X.; FANG, Y.; LI, P.; LIU, Q.; HU, Q.; LIU, X. On-line prediction of hazardous fungal contamination in stored maize by integrating Vis/NIR spectroscopy and computer vision. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, v. 229, p. 118012, 2020. DOI: 10.1016/j.saa.2019.118012

SILVA, L. C. S.; TEN CATEN, C. S.; GAIA, S. Conceptual framework of green technology transfer at public university scope Brazilian. **Innovation and Green Development**, v. 2, n. 4, p. 100076, 2023.

SINGH, AJAY KUMAR. Technology transfer and commercialization models and policies in India, USA, China and Malaysia: A conceptual review. **Asian Journal of Sociological Research**, p. 19-45, 2020.

SOKUDLOR, N.; LALOON, K.; JUNSIRI, C.; SUDAJAN, S. Enhancing milled rice qualitative classification with machine learning techniques using morphological features of binary images. **International Journal of Food Properties**, v. 26, n. 2, p. 2978-2992, 2023.

SOTT, M. K.; NASCIMENTO, L. DA S.; FOGUESATTO, C. R.; FURSTENAU, L. B; FACCIN, K.; ZAWISLAK, P. A; MELLADO, B.; KONG, J. D. e BRAGAZZI N. L. A Bibliometric Network Analysis of Recent Publications on Digital Agriculture to Depict Strategic Themes and Evolution Structure, **Sensors**, v. 21, n. 23, p. 7889, 2021. DOI [https:// doi.org/10.3390/s21237889](https://doi.org/10.3390/s21237889).

SRIVASTAVA, S.; MISHRA, G.I.; MISHRA, H. N. Application of an expert system of X-ray micro computed tomography imaging for identification of *Sitophilus oryzae* infestation in stored rice grains. **Pest management science**, v. 76, n. 3, p. 952-960, 2020.

TARACATAC, A.; RICARDO, C. (2019). Rice Insect Classification and Quantification (RICQ) Using Portable Neural Network Model with EFPV-Image Processing Algorithm. **Journal of Advanced Research in Dynamical and Control Systems**. 11. 979-985. DOI: 10.5373/JARDCS/V11SP11/20193124.

UNITED NATIONS, **Department of Economic and Social Concil** - Commission on Population and Development - Fifty-fifth session. 25–29 April 2022. Disponível em: <https://documents-dds-ny.un.org/doc/UNDOC/GEN/N22/240/68/PDF/N2224068.pdf?> Acesso em 4 de nov 2022.

USDA. World Agricultural Production, 2024 - Foreign Agricultural Service Circular Series - WAP 10-24 October 2024.

VERAS, C. A. G.; PEREIRA, F. D. *Escala de Maturidade Tecnológica (TRL)*. **Parque Científico e Tecnológico da Universidade de Brasília (PCTec/UnB)**, 2022. Disponível em: <[https://pctec.unb.br/documentos/ 179-documentos/142-trl](https://pctec.unb.br/documentos/179-documentos/142-trl)>. Acesso em: 1 dez 2024.

WERKEMA, C. Perguntas e Respostas Sobre o Lean Seis Sigma. 2ª. ed. Rio de Janeiro: GEN Atlas, 2011. Disponível em: <<https://integrada.minhabiblioteca.com.br/#!/books/9788595158207>>. Acesso em: out. 2022.

XING, L.; WANG, Y., LUO, R.; ZOU, L. Application of computer vision technology in agricultural products and food inspection. In: **Journal of Physics: Conference Series**. IOP Publishing, 2021. p. 032045.

XU, P.; YANG, R.; ZENG, T.; ZHANG, J.; ZHANG, Y.; TAN, Q. Varietal classification of maize seeds using computer vision and machine learning techniques. **Journal of Food Process Engineering**, v. 44, p. e13846, 2021. DOI: 10.1111/jfpe.13846.

WOLFERT S; GOENSE, D.; SØRENSEN C. A. G A, Future Internet Collaboration Platform for Safe and Healthy Food from Farm to Fork, in **SRII Global Conference**, 2014. DOI 10.1109/SRII.2014.47

YASAR, M. Analysis of selected deep features with CNN-SVM-based for bread wheat seed classification. **Computers and Electronics in Agriculture**, v. 193, p. 106716, 2024.

YIN, Robert K. **Case study research: Design and methods**. (Vol. 5) sage, 2015.

ZAPAROLLI, Domingos. **Agricultura 4.0. Revista Pesquisa** _1806 RJLB, Ano 7 (2021), nº 6 FAPESP, edição 287, p. 13-20, 2020.

APÊNDICE I. Artigos elegíveis identificados na literatura

Num	Autor(es)	Título	País	Grão(s)	Proposta	Técnica(s)	Tipo(s) imagens	Tipo(s) de atributos
1	Anami <i>et al.</i> (2015)	A colour features-based methodology for variety recognition from bulk paddy images	ÍNDIA	ARROZ	MET	AM	RGB	COR
2	Araújo <i>et al.</i> (2015)	Beans quality inspection using correlation-based granulometry	BRASIL	FEIJÃO	MET	AM	RGB	EST/COR
3	Barbedo <i>et al.</i> (2015)	Detecting Fusarium head blight in wheat kernels using hyperspectral imaging	BRASIL	TRIGO	MET	EST	HYP	EST
4	Fang <i>et al.</i> (2015)	Simultaneous Determination of Multi Rice Quality Parameters Using Image Analysis Method	CHINA	ARROZ	MET	EST	RGB	GEO
5	Lo Bianco <i>et al.</i> (2015)	Characterisation of Italian bean landraces (<i>Phaseolus vulgaris</i> L.) using seed image analysis and texture descriptors	ITÁLIA	FEIJÃO	MET	AM	RGB	EST
6	Wang <i>et al.</i> (2015)	Feasibility of Detecting Aflatoxin B1 on Inoculated Maize Kernels Surface using Vis/NIR Hyperspectral Imaging	ESTADOS UNIDOS	MILHO	MET	EST	HYP	EST
7	Ambrose <i>et al.</i> (2016)	High speed measurement of corn seed viability using hyperspectral imaging	COREIA DO SUL	MILHO	MET	EST	HYP	EST
8	Huang <i>et al.</i> (2016)	Classification of maize seeds of different years based on hyperspectral imaging and model updating	CHINA	MILHO	MET	AM	HYP	EST
9	Kuo <i>et al.</i> (2016)	Identifying rice grains using image analysis and sparse-representation-based classification	TAIWAN	ARROZ	MET	AM	RGB	EST
10	Liu <i>et al.</i> (2016)	Visual Perception-Based Statistical Modeling of Complex Grain Image for Product Quality Monitoring and Supervision on Assembly Production Line	CHINA	ARROZ	MET	AM	RGB	EST
11	Olgun <i>et al.</i> (2016)	Wheat grain classification by using dense SIFT features with SVM classifier	TURQUIA	TRIGO	MET	AM	RGB	EST
12	Piramli <i>et al.</i> (2016)	Rice grain grading classification based on perimeter using Moore-Neighbor Tracing method	MALÁSIA	ARROZ	MET	AM	RGB	EST/COR
13	Ravikanth <i>et al.</i> (2019)	Performance evaluation of a model for the classification of contaminants from wheat using near-infrared hyperspectral imaging	CANADÁ	TRIGO	MET	AM	HYP	EST
14	Tuates <i>et al.</i> (2016)	Development of PHilMech computer vision system (CVS) for quality analysis of rice and corn	FILIPINAS	ARROZ, MILHO	MET	AM	RGB	EST/COR
15	Lin <i>et al.</i> (2018)	A Deep Convolutional Neural Network Architecture for Boosting Image Discrimination Accuracy of Rice Species	CHINA	ARROZ	MET	AP	RGB	RHA
16	Mahajan <i>et al.</i> (2018)	Machine vision based alternative testing approach for physical purity, viability and vigour testing of soybean seeds (<i>Glycine max</i>)	ÍNDIA	SOJA	MET	AM	RGB	EST
17	Sendin <i>et al.</i> (2018)	Classification of white maize defects with multispectral imaging	ÁFRICA DO SUL	MILHO	MET	AM	HYP	EST
18	Alotaibi (2019)	A Rice Quality Analysis with Image Classification using Sobel Filter	ARÁBIA SAUDITA	ARROZ	MET	AM	RGB	GEO

19	Anami <i>et al.</i> (2019)	Automated recognition and classification of adulteration levels from bulk paddy grain samples	ÍNDIA	ARROZ	MET	AM	RGB	EST
20	Itsarawisut <i>et al.</i> (2019)	Neural Network-based Classification of Germinated Hang Rice Using Image Processing	TAILÂNDIA	ARROZ	MET	AM	RGB	EST/COR
21	Lin <i>et al.</i> (2019)	Rapidly and exactly determining postharvest dry soybean seed quality based on machine vision technology	CHINA	SOJA	MET	AM	RGB	EST
22	Mittal <i>et al.</i> (2019)	Non-destructive image processing based system for assessment of rice quality and defects for classification according to inferred commercial value	ÍNDIA	ARROZ	MET	AM	RGB	EST
23	Özkan <i>et al.</i> (2019)	Identification of wheat kernels by fusion of RGB, SWIR, and VNIR samples	TURQUIA	TRIGO	MET	AP	HYP	RHA
24	Protsenko <i>et al.</i> (2019)	Construction of a Classification Model for Bulk Cereal Grains from Diffuse Reflectance Spectra in the Near Infrared Region, Using Logistic Regression as an Example	BELARUS	TRIGO	MET	AM	HYP	EST
25	Ropelewska (2019)	Evaluation of wheat kernels infected by fungi of the genus <i>Fusarium</i> based on morphological features	POLÔNIA	TRIGO	MET	AM/AP	RGB	EST
26	Senthil <i>et al.</i> (2019)	An efficient rice variety identification scheme using shape, harlick & color feature extraction and multiclass SVM	ÍNDIA	ARROZ	MET	AM	RGB	EST/GEO
27	Abbaspour-Gilandeh <i>et al.</i> (2020)	Discriminating Healthy Wheat Grains from Grains Infected with <i>Fusarium graminearum</i> Using Texture Characteristics of Image-Processing Technique, Discriminant Analysis, and Support Vector Machine Methods	IRÃ	TRIGO	MET	AM	RGB	EST
28	Ali <i>et al.</i> (2020)	Machine learning approach for the classification of corn seed using hybrid features	TAILÂNDIA	MILHO	MET	AM	RGB	EST
29	Aukkapinyo <i>et al.</i> (2020)	Localization and Classification of Rice-grain Images Using Region Proposals-based Convolutional Neural Network	TAILÂNDIA	ARROZ	MET	AP	RGB	RHA
30	Boniecki <i>et al.</i> (2020)	Neural Visual Detection of Grain Weevil (<i>Sitophilus granarius</i> L.)	POLÔNIA	TRIGO	MET	AM	RGB	GEO
31	Cisneros-Carrillo <i>et al.</i> (2020)	Thermal analysis and artificial vision of laser irradiation on corn	MÉXICO	MILHO	MET	EST	RGB/TER	COR/GEO
32	Fan <i>et al.</i> (2020)	Individual wheat kernels vigor assessment based on NIR spectroscopy coupled with machine learning methodologies	CHINA	TRIGO	MET	AM	HYP	EST
33	Hu <i>et al.</i> (2020)	Nondestructive 3D image analysis pipeline to extract rice grain traits using X-ray computed tomography	CHINA	ARROZ	MET	AM	3D	GEO/EST
34	Kiratiratanapruk <i>et al.</i> (2020)	Development of Paddy Rice Seed Classification Process using Machine Learning Techniques for Automatic Grading Machine	TAILÂNDIA	ARROZ	MET	AM/AP	RGB	EST
35	Srivastava <i>et al.</i> (2020)	Application of an expert system of X- ray micro computed tomography imaging for identification of <i>Sitophilus oryzae</i> infestation in stored rice grains	ÍNDIA	ARROZ	MET	EST	3D	EST
36	Zhang <i>et al.</i> (2020)	Integration of spectroscopy and image for identifying fusarium damage in wheat kernels	CHINA	TRIGO	MET	AM	HYP	EST
37	Zhang <i>et al.</i> (2020)	Non-destructive identification of slightly sprouted wheat kernels using hyperspectral data on both sides of wheat kernels	CHINA	TRIGO	MET	AM	HYP	EST

38	AgaAzizi <i>et al.</i> (2021)	Identification of impurity in wheat mass based on video processing using artificial neural network and PSO algorithm	IRÃ	TRIGO	MET	AM	RGB	EST
39	Aznan <i>et al.</i> (2021)	Computer vision and machine learning analysis of commercial rice grains: A potential digital approach for consumer perception studies	AUSTRÁLIA	ARROZ	MET	AM	RGB	EST
40	Bhattacharyya <i>et al.</i> (2021)	Classification and quality analysis of rice grain based on dimensional measurement during hydrothermal treatment	ÍNDIA	ARROZ	MET	AM	RGB	GEO
41	Lingwal <i>et al.</i> (2021)	Image-based wheat grain classification using convolutional neural network	ÍNDIA	TRIGO	MET	AP	RGB	RHA
42	Nga <i>et al.</i> (2021)	Combining Binary Particle Swarm Optimization with Support Vector Machine for Enhancing Rice Varieties Classification Accuracy	VIETNÃ	ARROZ	MET	AM	RGB	EST
43	Qadri <i>et al.</i> (2021)	A machine vision approach for classification the rice varieties using statistical features	PAQUISTÃO	ARROZ	MET	AM	RGB	EST
44	Sharma <i>et al.</i> (2021)	Image processing techniques to estimate weight and morphological parameters for selected wheat refractions	ÍNDIA	TRIGO	MET	AM	RGB	EST
45	Zhou <i>et al.</i> (2021)	Identification of the variety of maize seeds based on hyperspectral images coupled with convolutional neural networks and subregional voting	CHINA	MILHO	MET	AP	RGB	RHA
46	Zhou <i>et al.</i> (2021)	Recognizing black point in wheat kernels and determining its extent using multidimensional feature extraction and a naive Bayes classifier	CHINA	TRIGO	MET	AM	RGB	EST
47	Abana <i>et al.</i> (2022)	ISO/IEC 25010 based evaluation of rice seed analyzer: A machine vision application using image processing technique	FILIPINAS	ARROZ	MET	AM	RGB	EST
48	Assadzadeh <i>et al.</i> (2022)	Prediction of milling yield in wheat with the use of spectral, colour, shape, and morphological features	AUSTRÁLIA	TRIGO	MET	AM/AP	HYP	EST/COR/GEO
49	Bhupendra <i>et al.</i> (2022)	Deep CNN-based damage classification of milled rice grains using a high-magnification image dataset	ÍNDIA	ARROZ	MET	AP	RGB	RHA
50	Cesar Flores (2022)	Rot Corn Grain Classification by Color and Texture Analysis	BRASIL	MILHO	MET	AM	RGB	EST
51	Dönmez (2022)	Enhancing classification capacity of CNN models with deep feature selection and fusion: A case study on maize seed classification	TURQUIA	MILHO	MET	AP	RGB	RHA
52	Gierz <i>et al.</i> (2022)	Texture analysis and artificial neural networks for identification of cereals—case study: wheat, barley and rape seeds	POLÔNIA	TRIGO, CEVADA, COLZA	MET	AM	RGB	EST
53	Hossen <i>et al.</i> (2022)	Wheat Diseases Detection and Classification using Convolutional Neural Network (CNN)	BANGLADESH	TRIGO	MET	AP	RGB	RHA
54	Huang <i>et al.</i> (2022)	Fast location and segmentation of high-throughput damaged soybean seeds with invertible neural networks	CHINA	SOJA	MET	AP	RGB	RHA
55	Işık Ş. <i>et al.</i> (2022)	Consensus rule for wheat cultivar classification on VL, VNIR and SWIR imaging	TURQUIA	TRIGO	MET	AM/AP	RGB	RHA
56	Jin <i>et al.</i> (2022)	Identification of Rice Seed Varieties Based on Near-Infrared Hyperspectral Imaging Technology Combined with Deep Learning	CHINA	ARROZ	MET	AM/AP	RGB	EST

57	Palacios-Cabrera <i>et al.</i> (2022)	Determination of Moisture in Rice Grains Based on Visible Spectrum Analysis	EQUADOR	ARROZ	MET	AM	RGB	EST/COR
58	Priya <i>et al.</i> (2022)	Evaluation of segmentation methods for RGB colour image-based detection of Fusarium infection in corn grains using support vector machine (SVM) and pretrained convolution neural network (CNN)	CANADÁ	MILHO	MET	AM/AP	RGB	RHA
59	Ravichandran <i>et al.</i> (2022)	Estimation of grain quality parameters in rice for high-throughput screening with near-infrared spectroscopy and deep learning	CANADÁ	ARROZ	MET	AP	RGB	RHA
60	Singh <i>et al.</i> (2022)	Gray level size zone matrix for rice grain classification using back propagation neural network: a comparative study	ÍNDIA	ARROZ	MET	AM	RGB	EST
61	Unlarsen <i>et al.</i> (2022)	CNN-SVM hybrid model for varietal classification of wheat based on bulk samples	POLÔNIA	TRIGO	MET	AM/AP	RGB	EST/RHA
62	Wang C. <i>et al.</i> (2022)	Deep learning based high-throughput phenotyping of chalkiness in rice exposed to high night temperature	ESTADOS UNIDOS	ARROZ	MET	AP	RGB	RHA
63	Yaman <i>et al.</i> (2022)	Classification of viable/non-viable seeds of specialty maize genotypes using spectral and image data plus morphological features	TURQUIA	MILHO	MET	AM	HYP	COR/GEO
64	Zhao <i>et al.</i> (2022)	Fast and accurate wheat grain quality detection based on improved YOLOv5	CHINA	TRIGO	MET	AP	RGB	RHA
65	Zhao <i>et al.</i> (2022)	Hybrid convolutional network based on hyperspectral imaging for wheat seed varieties classification	CHINA	TRIGO	MET	AP	HYP	RHA
66	Alshahrani <i>et al.</i> (2023)	Quantum-Inspired Moth Flame Optimizer Enhanced Deep Learning for Automated Rice Variety Classification	ARÁBIA SAUDITA	ARROZ	MET	AP	RGB	RHA
67	de Jesus Dantas <i>et al.</i> (2023)	Phaseolus lunatus L.: pulse seeds phenotype image analysis	BRASIL	FEIJÃO	MET	EST	RGB	GEO
68	Hidayat <i>et al.</i> (2023)	Determining the Rice Seeds Quality Using Convolutional Neural Network	INDONÉSIA	ARROZ	MET	AP	RGB	RHA
69	Islam <i>et al.</i> (2023)	Germinative paddy seed identification using deep convolutional neural network	BANGLADESH	ARROZ	MET	AP	RGB	RHA
70	Jollet <i>et al.</i> (2023)	A new computer vision workflow to assess yield quality traits in bush bean (<i>Phaseolus vulgaris</i> L.)	ALEMANHA	FEIJÃO	MET	AP	RGB	RHA
71	Li <i>et al.</i> (2023)	A lightweight method for maize seed defects identification based on Convolutional Block Attention Module	CHINA	MILHO	MET	AP	RGB	RHA
72	Matsuda <i>et al.</i> (2023)	Last-percent improvement in eligibility rates of crop seeds based on quality evaluation using near-infrared imaging spectrometry	JAPÃO	MILHO	MET	EST	HYP	EST
73	Qiao <i>et al.</i> (2023)	Vigour testing for the rice seed with computer vision-based techniques	VIETNÃ	ARROZ	MET	AP	HYP	RHA
74	Shen <i>et al.</i> (2023)	Segmentation of Unsound Wheat Kernels Based on Improved Mask RCNN	CHINA	TRIGO	MET	AP	RGB	RHA
75	Sokudlor <i>et al.</i> (2023)	Enhancing milled rice qualitative classification with machine learning techniques using morphological features of binary images	TAILÂNDIA	ARROZ	MET	AM/AP	RGB	Morfológicos

76	Suárez <i>et al.</i> (2023)	Corn kernel classification from few training samples	EQUADOR	MILHO	MET	AP	RGB	RHA
77	Wang <i>et al.</i> (2023)	Crack Detection of Brown Rice Kernel Based on Optimized ResNet-18 Network	CHINA	ARROZ	MET	AP	RGB	RHA
78	Yang <i>et al.</i> (2023)	FCBTYOLO: A Lightweight and High-Performance Fine Grain Detection Strategy for Rice Pests	CHINA	ARROZ	MET	AP	RGB	RHA
79	Zhang <i>et al.</i> (2023)	Real-Time Wheat Unsound Kernel Classification Detection Based on Improved YOLOv5	CHINA	TRIGO	MET	AP	RGB	RHA
80	Balingbing <i>et al.</i> (2024)	Application of a multi-layer convolutional neural network model to classify major insect pests in stored rice detected by an acoustic device	ALEMANHA	ARROZ	MET	AM	RGB	EST
81	Din <i>et al.</i> (2024)	RiceNet: A deep convolutional neural network approach for classification of rice varieties[Formula presented]	ÍNDIA	ARROZ	MET	AP	RGB	RHA
82	Dönmez <i>et al.</i> (2024)	Multiple deep learning by majority-vote to classify haploid and diploid maize seeds	TURQUIA	MILHO	MET	AP	RGB	RHA
83	Jeong <i>et al.</i> (2024)	SUnSeT: spectral unmixing of hyperspectral images for phenotyping soybean seed traits	COREIA DO SUL	SOJA	MET	EST	RGB	EST/COR
84	Kim <i>et al.</i> (2024)	Predicting early mycotoxin contamination in stored wheat using machine learning	COREIA DO SUL	TRIGO	MET	AM	RGB	GEO
85	Li <i>et al.</i> (2024)	A maize seed variety identification method based on improving deep residual convolutional network	CHINA	MILHO	MET	AM	RGB	EST
86	Razavi <i>et al.</i> (2024)	ResNet deep models and transfer learning technique for classification and quality detection of rice cultivars	IRÃ	ARROZ	MET	AP	RGB	RHA
87	Samanta <i>et al.</i> (2024)	Fast and robust monitoring of broken rice kernels in the course of milling	ÍNDIA	ARROZ	MET	AP	RGB	EST
88	Siripatrawan <i>et al.</i> (2024)	Assessment of food safety risk using machine learning-assisted hyperspectral imaging: Classification of fungal contamination levels in rice grain	TAILÂNDIA	ARROZ	MET	AM	HYP	EST
89	Van Puyenbroeck <i>et al.</i> (2024)	Detection of kernels in maize forage using hyperspectral imaging	BÉLGICA	MILHO	MET	AP	HYP	RHA
90	Yang <i>et al.</i> (2024)	Classification of soybean seeds based on RGB reconstruction of hyperspectral images	CHINA	SOJA	MET	AP	HYP	RHA
91	Yasar <i>et al.</i> (2024)	Classification of bread wheat varieties with a combination of deep learning approach	TURQUIA	TRIGO	MET	AP	RGB	RHA
92	Zhang <i>et al.</i> (2024)	Characterization and Detection Classification of Moldy Corn Kernels Based on X-CT and Deep Learning	CHINA	MILHO	MET	AP	3D	RHA
93	Zareiforoush <i>et al.</i> (2016)	Qualitative classification of milled rice grains using computer vision and metaheuristic techniques	IRÃ	ARROZ	CMP_MET	AM	RGB	EST
94	Basati <i>et al.</i> (2018)	Using different classification models in wheat grading utilizing visual features	IRÃ	TRIGO	CMP_MET	AM	RGB	EST/GEO
95	Mavaddati (2018)	Rice classification and quality detection based on sparse coding technique	IRÃ	ARROZ	CMP_MET	AM	RGB	EST
96	Koklu <i>et al.</i> (2020)	Multiclass classification of dry beans using computer vision and machine learning techniques	TURQUIA	FEIJÃO	CMP_MET	AM	RGB	EST

97	Barboza da Silva <i>et al.</i> (2021)	Autofluorescence-spectral imaging as an innovative method for rapid, non-destructive and reliable assessing of soybean seed quality	BRASIL	SOJA	CMP_MET	AM	HYP	GEO
98	Koklu <i>et al.</i> (2021)	Classification of rice varieties with deep learning methods	TURQUIA	ARROZ	CMP_MET	AM/AP	RGB	EST/GEO
99	Özkan <i>et al.</i> (2021)	Wheat kernels classification using visible-near infrared camera based on deep learning	TURQUIA	TRIGO	CMP_MET	AM/AP	RGB	EST
100	Castro <i>et al.</i> (2022)	CLASSIFICATION OF Phaseolus lunatus L. USING IMAGE ANALYSIS AND MACHINE LEARNING MODELS; [CLASSIFICAÇÃO DE Phaseolus lunatus L. USANDO TÉCNICA DE ANÁLISE DE IMAGEM E MODELOS DE APRENDIZAGEM DE MÁQUINA]	BRASIL	FEIJÃO	CMP_MET	AM	RGB	COR/GEO
101	Gao <i>et al.</i> (2022)	Detection of Wheat Unsound Kernels Based on Improved ResNet	CHINA	TRIGO	CMP_MET	AP	RGB	RHA
102	Khatri <i>et al.</i> (2022)	Wheat Seed Classification: Utilizing Ensemble Machine Learning Approach	ÍNDIA	TRIGO	CMP_MET	AM	RGB	GEO
103	Qin <i>et al.</i> (2022)	Cereal grain 3D point cloud analysis method for shape extraction and filled/unfilled grain identification based on structured light imaging	CHINA	ARROZ, TRIGO, MILHO	CMP_MET	AM	RGB	EST/GEO
104	Uddin <i>et al.</i> (2022)	Paddy seed variety identification using T20-HOG and Haralick textural features	BANGLADESH	ARROZ	CMP_MET	AM	RGB	EST
105	Wang <i>et al.</i> (2022)	Vision-Based Defect Classification and Weight Estimation of Rice Kernels	CHINA	ARROZ	CMP_MET	AP	RGB	RHA
106	Xu <i>et al.</i> (2022)	Research on Maize Seed Classification and Recognition Based on Machine Vision and Deep Learning	CHINA	MILHO	CMP_MET	AP	RGB	RHA
107	Xu <i>et al.</i> (2022)	Vigor identification of maize seeds by using hyperspectral imaging combined with multivariate data analysis	CHINA	MILHO	CMP_MET	AM	HYP	EST
108	Zia <i>et al.</i> (2022)	Rapid Testing System for Rice Quality Control through Comprehensive Feature and Kernel-Type Detection	PAQUISTÃO	ARROZ	CMP_MET	AM	RGB	GEO
109	Agarwal <i>et al.</i> (2023)	Machine learning approach for the classification of wheat grains	ÍNDIA	TRIGO	CMP_MET	AM	RGB	EST
110	Dhawal <i>et al.</i> (2023)	Machine Learning Analysis of Hyperspectral Images of Damaged Wheat Kernels	ESTADOS UNIDOS	TRIGO	CMP_MET	AP	HYP	RHA
111	Golcuk <i>et al.</i> (2023)	Classification of bread wheat genotypes by machine learning algorithms	TURQUIA	TRIGO	CMP_MET	AM	RGB	EST/COR
112	He <i>et al.</i> (2023)	Multi-Modal Late Fusion Rice Seed Variety Classification Based on an Improved Voting Method	CHINA	ARROZ	CMP_MET	AM/AP	3D / 2D	RHA
113	Huang <i>et al.</i> (2023)	A Novel Method for Filled/Unfilled Grain Classification Based on Structured Light Imaging and Improved PointNet++	CHINA	ARROZ	CMP_MET	AM/AP	3D	EST/GEO
114	Kini <i>et al.</i> (2023)	Quality Assessment of Seed Using Supervised Machine Learning Technique	ÍNDIA	TRIGO	CMP_MET	AM	RGB	GEO
115	Macuácuá <i>et al.</i> (2023)	Data mining approach for dry bean seeds classification	BRASIL	FEIJÃO	CMP_MET	AM	RGB	EST/GEO
116	Nayak <i>et al.</i> (2023)	An Advance Boosting Approach for Multiclass Dry Bean Classification	ÍNDIA	FEIJÃO	CMP_MET	AM	RGB	EST

117	Rathnayake <i>et al.</i> (2023)	Age Classification of Rice Seeds in Japan Using Gradient-Boosting and ANFIS Algorithms	JAPÃO	ARROZ	CMP_MET	AM	RGB	EST/COR/GEO
118	Salauddin <i>et al.</i> (2023)	Comparison of multiclass classification techniques using dry bean dataset	BANGLADESH	FEIJÃO	CMP_MET	AM	RGB	EST
119	Setiawan A. <i>et al.</i> (2023)	Rice Foreign Object Classification Based on Integrated Color and Textural Feature Using Machine Learning	INDONÉSIA	ARROZ	CMP_MET	AM	RGB	EST/GEO
120	Xu <i>et al.</i> (2023)	Identification of Defective Maize Seeds Using Hyperspectral Imaging Combined with Deep Learning	CHINA	MILHO	CMP_MET	AM/AP	HYP	GEO
121	Yasar (2023)	Benchmarking analysis of CNN models for bread wheat varieties	TURQUIA	TRIGO	CMP_MET	AP	RGB	RHA
122	Bhattacharyya <i>et al.</i> (2024)	Design and performance analysis of decision tree learning model for classification of dry and cooked rice samples	ÍNDIA	ARROZ	CMP_MET	AM	RGB	EST
123	Kılıçarslan <i>et al.</i> (2024)	A comparative study of bread wheat varieties identification on feature extraction, feature selection and machine learning algorithms	TURQUIA	TRIGO	CMP_MET	AM	RGB	EST/COR
124	Koppad <i>et al.</i> (2024)	Automated Seed Classification Using State-of-the-Art Techniques	ÍNDIA	SOJA	CMP_MET	AP	RGB	RHA
125	Rajalakshmi <i>et al.</i> (2024)	RiceSeedNet: Rice seed variety identification using deep neural network	ÍNDIA	ARROZ	CMP_MET	AP	RGB	RHA
126	Setiawan <i>et al.</i> (2024)	Comparative Analysis of Deep Convolutional Neural Network for Accurate Identification of Foreign Objects in Rice Grains	INDONÉSIA	ARROZ	CMP_MET	AP	RGB	RHA
127	Shivamurthaiah <i>et al.</i> (2024)	Non-destructive Machine Vision System based Rice Classification using Ensemble Machine Learning Algorithms	ÍNDIA	ARROZ	CMP_MET	AM	RGB	EST
128	Yasar (2024)	Analysis of selected deep features with CNN-SVM-based for bread wheat seed classification	TURQUIA	TRIGO	CMP_MET	AM/AP	RGB	EST/GEO
129	Antonucci <i>et al.</i> (2017)	An Open Source Conveyor Belt Prototype for Image Analysis-Based Rice Yield Determination	ITÁLIA	ARROZ	MET + HDW	EST	RGB	EST/COR/GEO
130	Liu <i>et al.</i> (2018)	Determination of maize seed purity based on multi-step clustering	CHINA	MILHO	MET + HDW	AM	RGB	EST/COR
131	Payman <i>et al.</i> (2018)	Development of an expert vision-based system for inspecting rice quality indices	IRÃ	ARROZ	MET + HDW	EST	RGB	COR/GEO
132	Belan <i>et al.</i> (2020)	Machine vision system for quality inspection of beans	BRASIL	FEIJÃO	MET + HDW	AM/AP	RGB	COR/GEO
133	Chen <i>et al.</i> (2020)	Real-time grain impurity sensing for rice combine harvesters using image processing and decision-tree algorithm	CHINA	ARROZ	MET + HDW	AM	RGB	GEO
134	Shen <i>et al.</i> (2020)	On-line prediction of hazardous fungal contamination in stored maize by integrating Vis/NIR spectroscopy and computer vision	CHINA	MILHO	MET + HDW	EST	HYP/RGB	EST/COR
135	Gao <i>et al.</i> (2021)	HyperSeed: An End-to-End Method to Process Hyperspectral Images of Seeds	ESTADOS UNIDOS	ARROZ	MET + HDW	AM/AP	HYP/3D	EST
136	Fan <i>et al.</i> (2024)	AV4GAIInsp: An Efficient Dual-Camera System for Identifying Defective Kernels of Cereal Grains	AUSTRÁLIA	ARROZ, TRIGO, SORGO	MET + HDW	AP	RGB	RHA
137	Xu <i>et al.</i> (2021)	Varietal classification of maize seeds using computer vision and machine learning techniques	CHINA	MILHO	CMP_MET+HDW	AM	RGB	EST/COR/GEO

Legendas

Proposta do trabalho

HDW : proposição de hardware(s) para análise/classificação/identificação de defeitos em grãos

MET : proposição de método(s) para análise/classificação/identificação de defeitos em grãos

CMP_MET : comparação de métodos para análise/classificação/identificação de defeitos em grãos

Técnica(s) empregada(s) na implementação do(s) método(s)

AM : Aprendizagem de Máquina

AP : Aprendizagem profunda

EST : Estatística

Tipo(s) das imagens utilizadas nos experimentos

2D : imagens bidimensionais

3D : imagens tridimensionais adquiridas por meio de scanners, raio-X ou tomografia

HIP : imagens hiperespectrais (com muitas bandas espectrais [4+])

RGB: imagens 2D padrão red, green, blue

TER: imagens termais

Tipo(s) dos atributos extraídos das imagens

COR: Cor

EST : Estatísticos (histograma, textura, assinatura espectral, etc)

GEO: Geométricos (área, perímetro, diâmetro, outros atributos morfológicos, etc)

QUI : Químicos (humidade)

RHA: Representações hierárquicas e abstratas

APÊNDICE II. Instrumento de coleta de dados

Tecnologias para inspeção visual automática de grãos agrícolas

Olá,

Agradecemos seu interesse em contribuir para a pesquisa.

Sobre o que é esta pesquisa?

Trata-se de uma *pesquisa de doutorado*, intitulada "INSPEÇÃO VISUAL AUTOMÁTICA DE GRÃOS AGRÍCOLAS: potenciais aplicações e principais desafios para transferência de tecnologia na agroindústria", que tem como objetivo principal compreender as necessidades do setor agrícola no que tange a inspeção visual da qualidade de grãos, as formas de alinhar as inovações tecnológicas para inspeção visual automática às demandas do setor agrícola, além de investigar os fatores que dificultam a transferência dessas inovações para a agroindústria.

Qual o método utilizado? O que é exatamente este questionário e como será o meu envolvimento nesta pesquisa?

Para atingir o objetivo da pesquisa, estão sendo empregados, de forma combinada, os seguintes métodos qualitativos e quantitativos: revisão sistemática da literatura, análise bibliométrica, além deste questionário para a coleta de dados.

A sua participação é muito importante para subsidiar a pesquisa, principalmente no que tange à compreensão das necessidades do setor agrícola e dos fatores que dificultam a transferência de tecnologias de inspeção visual automática para a agroindústria.

O tempo estimado para responder este questionário é de 10 a 15 minutos. As questões que abordam dados pessoais são opcionais. Portanto, não é necessário você se identificar. Sua participação nesta pesquisa é voluntária, ou seja, não haverá qualquer tipo de remuneração ou custo, exceto o tempo dedicado.

Quem é o pesquisador responsável?

Robson Aparecido Gomes - aluno de doutorado do Programa de Pós-Graduação em Informática e Gestão do Conhecimento (PPGI) da Universidade Nove de Julho (UNINOVE), sob orientação do Prof. Dr. Sidnei Alves de Araújo.

E sobre a privacidade, o uso dos dados e a publicidade da participação?

Todos os dados coletados a partir deste questionário serão tratados de forma sigilosa e anônima, bem como serão usados exclusivamente para fins acadêmicos.

Muito obrigado,

Robson Ap. Gomes
robsonapgomes@gmail.com

* Indica uma pergunta obrigatória

1. Você, livre e esclarecida(o), autoriza a utilização de suas respostas para a pesquisa de doutorado intitulada "INSPEÇÃO VISUAL AUTOMÁTICA DE GRÃOS AGRÍCOLAS: potenciais aplicações e principais desafios para transferência de tecnologia na agroindústria"? *

Marcar apenas uma oval.

☐ Sim

☐ Não *Pular para a seção 6 (Fim da pesquisa)*

DADOS PESSOAIS

2. Nome (não obrigatório)

3. Grau de instrução *

Marcar apenas uma oval.

- ☐ Ensino fundamental (1º grau) incompleto
- ☐ Ensino fundamental (1º grau) completo
- ☐ Ensino médio (2º grau) incompleto
- ☐ Ensino médio (2º grau) completo
- ☐ Ensino superior incompleto
- ☐ Ensino superior completo
- ☐ Pós-graduação (especialização) incompleto
- ☐ Pós-graduação (especialização) completo
- ☐ Mestrado incompleto
- ☐ Mestrado completo
- ☐ Doutorado incompleto
- ☐ Doutorado completo
- ☐ Pós-doutorado

4. Faixa etária

Marcar apenas uma oval.

- ☐ Até 20 anos
- ☐ De 21 a 30 anos
- ☐ De 31 a 40 anos
- ☐ De 41 a 50 anos
- ☐ De 51 a 60 anos
- ☐ Acima de 60 anos

ATUAÇÃO PROFISSIONAL

5. Ramo de atividade *

Marcar apenas uma oval.

- ☐ Agricultura
- ☐ Comércio
- ☐ Educação
- ☐ Indústria
- ☐ Pesquisa
- ☐ Serviços
- ☐ Outros

6. Há quanto tempo atua neste ramo de atividade? *

Marcar apenas uma oval.

- ☐ Até 5 anos
☐ Mais que 5 até 10 anos
☐ Mais que 10 até 20 anos
☐ Acima de 20 anos

7. Nível do cargo/função que exerce atualmente: *

Marcar apenas uma oval.

- ☐ Administrativo
☐ Estratégico
☐ Gerencial
☐ Operacional
☐ Não sei dizer/outro

8. Nome da instituição/empresa/organização onde você atua (opcional)

9. Localização (Estado) da instituição/empresa/organização onde você atua *

Marcar apenas uma oval.

- ☐ Acre
- ☐ Alagoas
- ☐ Amapá
- ☐ Amazonas
- ☐ Bahia
- ☐ Ceará
- ☐ Distrito Federal
- ☐ Espírito Santo
- ☐ Goiás
- ☐ Maranhão
- ☐ Mato Grosso
- ☐ Mato Grosso do Sul
- ☐ Minas Gerais
- ☐ Pará
- ☐ Paraíba
- ☐ Paraná
- ☐ Pernambuco
- ☐ Piauí
- ☐ Rio de Janeiro
- ☐ Rio Grande do Norte
- ☐ Rio Grande do Sul
- ☐ Rondônia
- ☐ Roraima
- ☐ Santa Catarina
- ☐ São Paulo
- ☐ Sergipe
- ☐ Tocantins

10. A sua atividade profissional está diretamente relacionada com produção, comercialização, armazenamento ou industrialização de produtos agrícolas? *

Marcar apenas uma oval.

- ☐ Sim
- ☐ Não Pular para a pergunta 13

ATIVIDADES PROFISSIONAIS DIRETAMENTE RELACIONADAS COM PRODUTOS AGRÍCOLAS

11. Tipo de produto *

Marcar apenas uma oval.

- ☐ Frutas
- ☐ Grãos
- ☐ Hortaliças e legumes
- ☐ Outros

12. Quais das tecnologias a seguir são utilizadas na instituição/empresa/organização onde você atua? *

Marque todas que se aplicam.

- ☐ Tecnologias convencionais (computadores/tablets; esteiras; máquinas de inspeção, controle, processamento e empacotamento; balanças; autoclaves; trator, pulverizador, colheitadeira; etc.)
- ☐ Tecnologias modernas (IoT, Robótica, Inteligência Artificial, Sensoriamento remoto, Drones, etc.)
- ☐ Outro: _____

TECNOLOGIAS PARA INSPEÇÃO VISUAL AUTOMÁTICA DA QUALIDADE DE GRÃOS

13. Você tem conhecimento da existência de trabalhos científicos propondo soluções tecnológicas (sistemas computacionais e equipamentos) para inspeção visual automática da qualidade de produtos agrícolas? *

Marcar apenas uma oval.

- ☐ Não, e não conheço empresas que empregam essas soluções tecnológicas
- ☐ Não, mas conheço empresas que empregam essas soluções tecnológicas
- ☐ Sim, mas não conheço empresas que empregam essas soluções tecnológicas
- ☐ Sim, e conheço empresas que empregam essas soluções tecnológicas
- ☐ Sim, a empresa onde atuo emprega uma ou mais dessas soluções tecnológicas

14. Você acha importante um sistema computacional ou equipamento para automatizar as tarefas de inspeção visual da qualidade de grãos (classificação por cor, textura, tamanho ou formato, identificação de defeitos, etc.)? *

Marcar apenas uma oval.

- ☐ Não
- ☐ Não sei/tenho dúvida
- ☐ Sim

15. Na sua opinião, qual o nível de contribuição das soluções tecnológicas de inspeção visual automática da qualidade de grãos para: *

Marcar apenas uma oval por linha.

	Não sei/tenho dúvida	Nulo	Baixo	Médio	Alto
Redução de custo	☐	☐	☐	☐	☐
Garantia da qualidade dos produtos	☐	☐	☐	☐	☐
Padronização dos resultados da inspeção	☐	☐	☐	☐	☐
Aumento da competitividade empresarial	☐	☐	☐	☐	☐
Maior eficiência de processos no setor agrícola	☐	☐	☐	☐	☐
Apoio à tomada de decisão	☐	☐	☐	☐	☐

16. Na sua opinião, em que grau cada um dos fatores a seguir **desfavorece** o emprego de tecnologias para a inspeção visual automática de grãos? *

Marcar apenas uma oval por linha.

	Não sei	Nulo	Baixo	Médio	Alto
Custo das soluções tecnológicas	☐	☐	☐	☐	☐
Tempo de retorno do investimento nas soluções tecnológicas	☐	☐	☐	☐	☐
Necessidade de mudanças em processos/formas de trabalho	☐	☐	☐	☐	☐
Necessidade de mão-de-obra qualificada para operar as soluções tecnológicas	☐	☐	☐	☐	☐
Falta de confiança nos resultados produzidos pelas soluções tecnológicas	☐	☐	☐	☐	☐
Falta de alinhamento das soluções tecnológicas às demandas do setor agrícola	☐	☐	☐	☐	☐

17. Selecione até 5 dos itens a seguir que, na sua opinião, são importantes para viabilizar o emprego em larga escala de tecnologias para inspeção visual automática de grãos *

Marque todas que se aplicam.

- ☐ Ampla divulgação das tecnologias existentes
- ☐ Criação ou ampliação de linhas de crédito para aquisição dessas tecnologias
- ☐ Capacitação de mão-de-obra para lidar com essas tecnologias
- ☐ Maior integração entre os campos acadêmico e empresarial (teoria e prática)
- ☐ Redução do custo para aquisição dessas tecnologias
- ☐ Diminuição da resistência cultural (devido à falta de conhecimento ou confiança nas novas tecnologias)
- ☐ Desenvolvimento de tecnologias facilmente adaptáveis ao ambiente de trabalho
- ☐ Desenvolvimento de tecnologias que vão ao encontro das necessidades do setor agrícola
- ☐ Vantagens econômicas
- ☐ Padronização dos resultados

Fim da pesquisa

Obrigado!