


UNIVERSIDADE FEDERAL DO PARANÁ

LUCAS RODRIGUES DE SOUZA

USO DA INTELIGÊNCIA ARTIFICIAL NA CLASSIFICAÇÃO DE GRÃOS

CURITIBA

2025



LUCAS RODRIGUES DE SOUZA

USO DA INTELIGÊNCIA ARTIFICIAL NA CLASSIFICAÇÃO DE GRÃOS

Trabalho de Conclusão de Curso apresentado à Universidade Federal do Paraná, Setor de Ciências Agrárias, como requisito parcial para a obtenção do título de Engenheiro Agrônomo.

Orientadora: Profa. Dra. Adriana Martinelli Seneme

CURITIBA

2025

TERMO DE APROVAÇÃO

LUCAS RODRIGUES DE SOUZA

USO DA INTELIGÊNCIA ARTIFICIAL NA CLASSIFICAÇÃO DE GRÃOS

Trabalho apresentado como requisito parcial à obtenção do grau de Engenheiro Agrônomo no Curso de Graduação em Agronomia, pela seguinte banca examinadora:

Documento assinado digitalmente
 **ADRIANA MARTINELLI SENEME**
Data: 08/07/2025 16:07:51-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Adriana Martinelli Seneme

Orientadora – Departamento de Fitotecnia e Fitossanidade, UFPR

Documento assinado digitalmente
 **ALESSANDRA KEIKO NAKASONE**
Data: 08/07/2025 16:51:51-0300
Verifique em <https://validar.iti.gov.br>

Dra. Alessandra Keiko Nakasone

Pesquisadora A – Embrapa Florestas

Documento assinado digitalmente
 **MARILEIA REGINA FERREIRA**
Data: 08/07/2025 16:18:28-0300
Verifique em <https://validar.iti.gov.br>

Dra. Mariléia Regina Ferreira

Especialista Agropecuário da Defesa Agropecuária, SAA, SP

Curitiba, 04 de julho de 2025

AGRADECIMENTOS

A Deus, por sua imensurável misericórdia e bondade, por ter me guardado de baixo de suas asas, me consolado nos momentos de angústia e aflição, e me guiado com suas poderosas mãos.

A Professora Dra. Adriana Martinelli Seneme, por sua orientação, carinho, paciência e conhecimentos compartilhados, que foram fundamentais.

Ao Professor Dr. Ricardo Augusto de Oliveira, por sua ajuda e ensinamentos que serviram como inspiração.

Ao meu pai, Ailton de Souza e minha mãe, Carolina Rodrigues, que foram meus primeiros apoiadores e amigos.

Ao meu irmão, Ailton de Souza Júnior, por sempre se alegrar por minhas conquistas e acreditar em mim.

Aos meus familiares, que sempre me aconselharam e desejaram o melhor pra mim.

Ao meu amigo, Leonardo Santana, meu amigo mais antigo, que compartilha das mesmas raízes que eu.

Aos meus amigos, Christian Augusto Nieland Muller, Davi Krieger da Silva, João Pedro Nóbrega Gomes Stencel, Leandro Cassou Erthal, Otávio Raul Speltz, Pedro Henrique Souza Andilossi e William Santiago de Mendonça, que compartilharam comigo as vivências de Curitiba e fizeram a experiência da faculdade muito melhor.

A minha amiga Jessica Harmatiuk, que durante a faculdade me ajudou a carregar o fardo das provas e trabalhos.

Ao meu amigo Guilherme Ribeiro Sabetzki, por sua influência positiva durante meu caminho na universidade.

Ao meu amigo Luiz Alberto Boni, por todos os conselhos e por acreditar e investir em mim e na minha carreira.

Aos amigos que a vida me apresentou, por todas as risadas, conversas e aprendizados compartilhados.

“Os que confiam no Senhor são como os montes de Sião,
que não se abalam, mas permanecem para sempre.”
Salmos 125:1

RESUMO

A classificação de grãos é fundamental para garantir a qualidade e a padronização dos produtos agrícolas, refletindo diretamente em sua comercialização e em seu valor agregado. Neste contexto, o uso da Inteligência Artificial (IA) surge como uma ferramenta inovadora e eficiente, capaz de automatizar processos, reduzir erros humanos e aumentar a precisão na identificação de características físicas dos grãos, como tamanho, cor e textura. A aplicação de algoritmos de aprendizado de máquina permite uma análise mais rápida e criteriosa, contribuindo para a uniformidade dos lotes e para a rastreabilidade da produção. Este trabalho apresenta um estudo sobre a aplicação da inteligência artificial (IA) na classificação de grãos, com o objetivo de aprimorar os processos de padronização e controle de qualidade na cadeia pós-colheita. Fatores que dificultam a separação precisa por métodos manuais e visuais tradicionais são abordados por meio de técnicas de *machine learning* e *deep learning*, capazes de processar características visuais complexas dos grãos. Um conjunto de artigos científicos foi analisado para avaliar a efetividade dessas abordagens, considerando diferentes algoritmos, tipos de cultura e parâmetros avaliados. Os resultados obtidos demonstram que os modelos baseados em IA apresentam elevada acurácia e potencial de automação, sendo promissores para aplicação prática em larga escala. Além disso, destaca-se a possibilidade de expansão das soluções com o uso de redes neurais profundas em estudos futuros, visando sistemas cada vez mais robustos e eficientes na classificação automatizada de grãos.

Palavras-chave: Aprendizado de máquina. Aprendizado profundo. Visão computacional. Classificação automática de grãos.

ABSTRACT

Grain classification is essential to ensure the quality and standardization of agricultural products, directly impacting their commercialization and added value. In this context, the use of Artificial Intelligence (AI) emerges as an innovative and efficient tool, capable of automating processes, reducing human error, and increasing accuracy in identifying physical characteristics of grains, such as size, color, and texture. The application of machine learning algorithms enables faster and more rigorous analysis, contributing to batch uniformity and production traceability. This work presents a study on the application of artificial intelligence (AI) in grain classification, with the objective of improving standardization and quality control processes in the post-harvest chain. Factors that hinder precise separation through traditional manual and visual methods are addressed by means of machine learning and deep learning techniques, capable of processing complex visual characteristics of grains. A set of scientific articles was analyzed to evaluate the effectiveness of these approaches, considering different algorithms, crop types, and evaluated parameters. The results obtained demonstrate that AI-based models present high accuracy and automation potential, being promising for large-scale practical application. In addition, the possibility of expanding the solutions through the use of deep neural networks in future studies is highlighted, aiming at increasingly robust and efficient systems for automated grain classification.

Key-words: Machine learning, deep learning, computer vision, and automatic grain classification.

LISTA DE SIGLAS

CONAB - Companhia Nacional de Abastecimento

FAO - Food and Agriculture Organization

IGC - International Grains Council

MAPA - Ministério da Agricultura e Pecuária

SENAR - Serviço Nacional de Aprendizagem Rural

UFPR – Universidade Federal do Paraná

LISTA DE ABREVIATURAS

CNN - Convolutional Neural Network

DL - Deep Learning

HSI - Hue, Saturation, Intensity

IA - Inteligência Artificial

IN - Instrução Normativa

LD - Linear Discriminant

LSVM - Least Squares Support Vector Machine

ML - Machine Learning

MLP - Multi-Layer Perceptron

MSRCR - Multi-Scale Retinex with Color Restoration

RGB - Red, Green, Blue

RMSE - Root Mean Square Error

RSLD - Random Subspace Linear Discriminant

SVM - Support Vector Machine

VGG - Visual Geometry Group

SUMÁRIO

1	INTRODUÇÃO	10
1.1	OBJETIVO.....	10
2	REVISÃO BIBLIOGRÁFICA.....	11
2.1	CENÁRIO MUNDIAL DA PRODUÇÃO DE GRÃOS	11
2.2	CENÁRIO BRASILEIRO DA PRODUÇÃO DE GRÃOS	12
2.3	PÓS-COLHEITA DE GRÃOS.....	12
2.4	CLASSIFICAÇÃO DE GRÃOS.....	13
2.5	INTÉLIGENCIA ARTIFICIAL NA CLASSIFICAÇÃO DE GRÃOS.....	15
3	METODOLOGIA.....	19
4	RESULTADOS	19
4.1	VISÃO GERAL	19
4.2	FICHAMENTO BIBLIOGRÁFICO	20
4.3	DISCUSSÕES	23
5	CONCLUSÕES	22
6	REFERÊNCIAS.....	23

1 INTRODUÇÃO

A classificação de grãos é um processo técnico utilizado para verificar a qualidade dos produtos comercializados pelos produtores, tomando como referência as exigências contratuais e a legislação vigente (De Oliveira, 2021).

A crescente demanda por eficiência e precisão na cadeia de produção agrícola tem impulsionado a adoção de tecnologias inovadoras, entre elas a inteligência artificial (IA) (Saraiva, 2024). No contexto da agricultura moderna, a classificação de grãos desempenha papel fundamental na padronização de produtos, garantindo a conformidade com padrões de qualidade e facilitando a comercialização tanto no mercado nacional quanto internacional (Gonçalo, 2023). A utilização de algoritmos de IA na classificação de grãos oferece vantagens significativas, como maior acurácia, agilidade e redução de erros humanos, contribuindo para a otimização dos processos de inspeção e controle de qualidade (Tadesse, 2024). Exemplos de programas que empregam inteligência artificial para essa finalidade incluem o SoyNet, que utiliza sensores e algoritmos de aprendizado de máquina para avaliar a qualidade dos grãos em tempo real (Lin et al., 2023). Além disso, plataformas como o U-Net, utilizam redes neurais convolucionais para análise de imagens de grãos, promovendo uma classificação automatizada e padronizada (Assadzadeh et al., 2022). Essas tecnologias promovem maior padronização dos critérios de classificação, essenciais para assegurar a uniformidade dos produtos e fortalecer a competitividade do setor agrícola globalmente.

Assim, o estudo do uso de inteligência artificial na classificação de grãos representa uma inovação estratégica que pode transformar práticas tradicionais, promovendo maior eficiência, confiabilidade e sustentabilidade na cadeia produtiva agrícola (Gonçalves Silva e Germano, 2024).

1.1 OBJETIVO

Investigar as contribuições da inteligência artificial na classificação de grãos, com foco na aplicação de técnicas como visão computacional, aprendizado de

máquina (*machine learning*) e *deep learning*, a fim de compreender seus impactos na padronização, eficiência e automação dos processos pós-colheita.

2 REVISÃO BIBLIOGRÁFICA

2.1 CENÁRIO MUNDIAL DA PRODUÇÃO DE GRÃOS

A área mundial de cultivo de grãos totaliza, segundo a FAO (2024), 771.652.378 hectares, sendo 220.407.070 hectares de trigo, 208.234.140 hectares de milho, 168.356.566 hectares de arroz, 136.903.849 hectares de soja e 37.750.753 hectares de feijão.

O Brasil é líder na produção mundial de soja, com produção de 152.144.238 toneladas, seguido por Estados Unidos da América com 113.343.420 toneladas do grão produzidas. O terceiro lugar do ranking pertence a Argentina com uma produção de 25.044.978 toneladas (FAO, 2024).

A produção de milho é liderada pelos Estados Unidos da América, com uma produção de 389.694.460 toneladas, seguido da China, que apresentou uma produção de 288.842.300 toneladas. Em terceiro lugar, aparece o Brasil com uma produção total de 131.950.246 toneladas de grãos de milho produzidas (FAO, 2024). Segundo a FAO (2024), os altos níveis de fome são persistentes e juntamente com a falta de segurança alimentar e a desnutrição, são responsáveis por afastar o mundo dos objetivos de desenvolvimento sustentável.

No contexto mundial, no tocante a alimentação, nota-se a grande importância dos grãos, que são responsáveis por 66% da alimentação (WDAROS, 2013). Cerca de metade das calorias consumidas diariamente no mundo tem origem nos cereais, sendo que, entre eles, o arroz representa aproximadamente 20% da ingestão calórica em países de baixa e média renda (Laskowski, 2019).

Referente a produção mundial de grãos de trigo, a FAO (2024) traz a China como maior país produtor, com uma produção de 136.590.100 toneladas, seguida pela Índia, com 110.553.675,31 toneladas e Rússia com 91.500.000 toneladas. O Conselho Internacional de Grãos (IGC), estima a produção mundial de grãos de 2368 milhões de toneladas para a safra 25/26 IGC (2025), que representa um aumento em relação a produção da safra 23/24, que foi de 2310 milhões de toneladas.

O mercado mundial de grãos cresce de maneira rápida e significativa, fato que é indicado pelo total de 391,32 bilhões de dólares movimentados em 2024, com previsão para 2025 de 417,49 bilhões de dólares, representando crescimento de 6,7% de um ano para o outro. Esse crescimento é atribuído a fatores, como o crescimento populacional, mudanças de hábitos dos consumidores, subsídios e políticas governamentais, além do comércio global e suas dinâmicas.

2.2 CENÁRIO BRASILEIRO DA PRODUÇÃO DE GRÃOS

Para Carvalho et al. (2023), a produção de grãos vem aumentando em conjunto com a modernização da agricultura brasileira, com destaque para a soja, que contribui de forma relevante para a economia nacional. Segundo o Boletim da Safra de Grãos da CONAB (2024), a produção de grãos de milho no Brasil na safra 2023/2024 foi de 115.722,8 mil toneladas, a de soja foi de 147.382,0 mil toneladas e trigo de 8.807,3 mil toneladas.

Além de suprir a demanda de soja e milho para cadeia de produção de carnes, a produção de milho e soja do Brasil, devido a sua escala, supre também a demanda externa dos grãos, principalmente no que se refere a exportação de grãos de soja, quesito onde o Brasil se estabelece como líder mundial (Hirakuri et al. 2018). Dados da Companhia Nacional de Abastecimento (CONAB, 2024) também afirmam que a área total destinada a produção de grãos (trigo, soja, milho, feijão e arroz) no Brasil é de 74.620,3 mil hectares.

Da Silva et al. (2024), afirma que o Brasil figura entre os maiores produtores de grãos em relação aos outros países do mundo, no ano de 2020, produzindo mais grãos do que grandes potências mundiais.

2.3 PÓS-COLHEITA DE GRÃOS

A pós-colheita de grãos é uma etapa de muita importância para o mercado mundial, pois visa a manutenção da qualidade dos grãos desde a colheita até o consumidor final (Pimentel et al., 2024). Visto que a população mundial vem crescendo em altas taxas e, conseqüentemente, elevando a demanda mundial por alimentos, destaca-se a importância de aumentar a eficiência das etapas relacionadas a pós-colheita, com objetivo de reduzir as perdas (Nathet al., 2024).

Outra importância da pós-colheita de grãos é a garantia da disponibilidade de alimento na entressafra, permitindo que os grãos de maneira geral possam ser consumidos, processados e industrializados em qualquer época (Tadesse et al., 2024).

É importante ressaltar que existem alguns processos definidos que são essenciais para a composição da etapa de pós-colheita, sendo eles o transporte, recepção, pré-limpeza, limpeza, secagem, armazenamento, classificação e comercialização (Marques, 2006). De maneira geral, existem dificuldades em todas as etapas da pós-colheita. Os processos mais problemáticos no quesito perdas, por exemplo, são o transporte e armazenamento, considerando tanto perdas quantitativas como qualitativas (Deliberador, 2019).

A secagem é um processo muito importante da pós-colheita pois visa reduzir a umidade dos grãos com o objetivo de evitar perdas futuras, entretanto tem baixa eficiência energética, além de ser uma fonte de perdas qualitativas (Portella et al., 2001).

A etapa de armazenamento tem importância estratégica muito grande, pois além de preservar a qualidade do grão, também traz maior segurança financeira ao produtor e proteção do mercado nacional (Ramos & Ramos, 2022). Outro processo que apresenta gargalos é o processo de classificação, que na maioria dos casos é feito de forma manual por pessoas treinadas, o que faz com que o resultado esteja sujeito a erros do classificador (Almeida et al., 2024).

2.4 CLASSIFICAÇÃO DE GRÃOS

A classificação de grãos consiste em um procedimento operacional destinado a avaliar a qualidade dos produtos comercializados pelo produtor, com base nas especificações contratuais e nas normas legais em vigor. Essa prática contribui para tornar o processo de comercialização mais transparente, minimizando divergências entre o que foi negociado e o que é efetivamente entregue ao comprador. Dessa forma, a classificação está diretamente relacionada ao cumprimento dos padrões definidos para cada cultura, levando em consideração um conjunto de critérios que avaliam tanto as características extrínsecas quanto intrínsecas dos grãos (De Oliveira, 2021).

Os parâmetros para a classificação de grãos são instituídos pela Lei n° 9.972, de 25 de maio de 2000 e regulamentados pelo decreto n° 3.664, de 17 de novembro de 2000 (BRASIL, 2000). No que se refere a cada cultura de maneira específica, existem Instruções Normativas (IN) do Ministério da Agricultura e Pecuária (MAPA), que estabelecem os critérios específicos dos grãos dentro do lote.

Para grãos de soja, a IN n° 11, de 15 de maio de 2007, define padrões oficiais de classificação, trazendo os aspectos a serem avaliados e suas definições, sendo eles grãos avariados (queimados, ardidos, mofados, fermentados, germinados, danificados, imaturos e chochos), amassados, partidos, esverdeados, com mancha púrpura, mancha café, matérias estranhas e umidade (BRASIL, 2007).

Nesse mesmo contexto, a IN n° 60, de 22 de dezembro de 2011 trata de definir os padrões de classificação de grãos de milho, sendo os principais aspectos a serem avaliados os grãos carunchados, grãos avariados (ardidos, chochos, fermentados, germinados, gessados e mofados), grãos quebrados, impurezas, matérias estranhas e umidade (BRASIL, 2011).

Em grãos de trigo, os padrões de classificação são definidos pela IN n° 38, de 30 de novembro de 2010, que traz como principais aspectos a serem avaliados os grãos ardidos, grãos chochos, grãos danificados por insetos, grãos esverdeados, grãos germinados, grãos mofados, grãos giberelados, grãos com ponta preta, impurezas e matérias estranhas (BRASIL, 2010).

Na atualidade, a atividade de classificação pode ser realizada por dois profissionais, sendo eles o classificador oficial, que precisa ter formação técnica ou superior na área agrícola e estar registrado no MAPA (Ministério da Agricultura e Pecuária), e o classificador treinador ou prático, que, independentemente de possuir graduação, deve possuir conhecimento técnico e experiência comprovada na área de classificação (SENAR, 2017). Delwiche & Miskelly (2017), consideram que essa classificação realizada por classificadores treinados está sujeita a subjetividade da visão de cada classificador.

2.5 INTELIGÊNCIA ARTIFICIAL NA CLASSIFICAÇÃO DE GRÃOS

A inteligência artificial (IA) teve sua popularização na padronização e controle de qualidade dos grãos por volta de 2010 e atualmente, está trazendo soluções rápidas, precisas e mais inteligentes para a classificação grãos. Essa

tecnologia permite uma análise baseada em características como cor, tamanho, formato e defeitos, sempre em conformidade com padrões oficiais. A IA é baseada em três pilares a saber: dados, algoritmos e poder da computação. Traz como benefícios padronização, precisão, agilidade, redução de custos e transparência nas negociações comerciais.

Os principais parâmetros que devem ser avaliados em um lote de grãos para seu controle de qualidade são: umidade, temperatura, impureza, peso específico, cor e aparência e contaminantes. Os recursos que são frequentemente usados na aplicação da IA em controle de qualidade dos grãos são sensores, para medição de umidade e temperatura; visão computacional que usam câmeras e algoritmos para captar imagens dos grãos; drones, uso eventual em áreas de armazenagem ou campos de cultivo; sistema de gerenciamento de dados, como plataformas que coletam e analisam dados sobre os grãos; *machine learning* (ML) e *deep learning* (DL).

O aprendizado de máquina (ML) é atualmente o ramo principal da I.A., integrando teoria da probabilidade, estatística e otimização convexa para resolver os problemas de visão computacional, reconhecimento de fala, processamento de linguagem natural, controle de robôs, etc. (Jordan & Michell, 2015). O ML dá às máquinas a capacidade de aprender sem serem estritamente programadas (Liakos et al, 2018). Já DL, é um ramo do aprendizado de máquina que utiliza redes neurais artificiais compostas por várias camadas ocultas entre a entrada e a saída, permitindo a modelagem de padrões complexos nos dados (LeCun et al., 2015).

O estudo de Farahnakian et al. (2024) comparou diferentes arquiteturas de *deep learning* para classificar cinco variedades de grãos de arroz, sendo elas Arborio, Basmati, Ipsala, Jasmine e Karacadag. A classificação foi baseada em imagens RGB de alta resolução, sendo os modelos avaliados em termos de acurácia, F1-score, precisão e *recall*. As tecnologias testadas incluíram redes VGG, ResNet, MobileNet e EfficientNet. O modelo EfficientNet teve o melhor desempenho geral, com acurácia de 99,67%, enquanto o MobileNet foi o mais rápido. O estudo demonstrou que redes profundas são altamente escaláveis e eficazes para lidar com grandes volumes de dados e tarefas de classificação complexas, superando métodos tradicionais de aprendizado de máquina que requerem extração manual de características.

Já a pesquisa realizada por Assadzadeh et al. (2022) teve como foco a classificação de grãos de lentilha e grão-de-bico, das variedades Kabuli e Desi, respectivamente, com base em sua qualidade visual, classificando entre grãos sãos e defeituosos. Os parâmetros para classificação incluíram defeitos visuais como grãos partidos, escurecidos, deformados e contaminantes, identificados por segmentação semântica. A tecnologia aplicada foi uma rede neural convolucional do tipo U-Net, usada para treinar máscaras de segmentação com base em imagens de grãos a granel. O modelo conseguiu prever a proporção de grãos sãos com alta precisão, atingindo um RMSE de 3,1% e R^2 de 0,99, destacando-se como uma solução eficaz e automatizada para avaliação da qualidade de grãos no mercado.

Na pesquisa realizada por Gonçalves Silva & Germano (2024) foi apresentado um sistema automatizado de baixo custo para a separação de grãos de feijão preto e carioca. A classificação considerou parâmetros visuais capturados por câmera, sendo processados por redes neurais convolucionais integradas a plataformas acessíveis como Teachable Machine e Pictoblox. A tecnologia usada inclui Arduino para a atuação física na separação dos grãos e interfaces educacionais para programação visual. O sistema alcançou 94,5% de acurácia, demonstrando eficácia para aplicações agrícolas práticas e também valor como ferramenta didática para ensino de inteligência artificial e automação agrícola.

Por sua vez, o estudo realizado por Sabanci et al. (2017), focou na classificação de grãos de trigo em duas categorias: trigo para pão e trigo durum. Foram utilizados como parâmetros para a classificação características visuais por meio de imagens dos grãos, abrangendo dimensões, como comprimento, largura, perímetro e área, além de cor em níveis de RGB e variações derivadas, e por último, textura; também abrangendo contraste, correlação, energia, homogeneidade e entropia. A tecnologia empregada foi um sistema de visão computacional aliado a uma rede neural artificial do tipo Perceptron Multicamadas (MLP), treinada e testada com um conjunto de 200 imagens. Os resultados mostraram que a rede neural simplificada com apenas sete parâmetros de entrada obteve alta precisão, com erro médio absoluto de apenas $9,8 \times 10^{-6}$, indicando a viabilidade do sistema como ferramenta precisa e automática para a classificação de grãos de trigo.

Na pesquisa de Lingwal et al. (2021) foi abordada a classificação de 15 variedades diferentes de trigo cultivadas na Índia, utilizando 15.000 imagens coletadas com smartphones. Os parâmetros para classificação basearam-se em

características visuais como forma, cor e textura dos grãos. A tecnologia aplicada foi uma Rede Neural Convolucional (CNN), construída do zero, com variações de hiperparâmetros como taxa de aprendizado, *dropout* e número de camadas ocultas. O melhor modelo alcançou 97,53% de acurácia no conjunto de teste, demonstrando que redes profundas podem identificar com alta precisão diferentes variedades de trigo mesmo com diferenças visuais sutis.

Santos Júnior et al. (2023), em um estudo com soja, desenvolveu um sistema completo de aquisição de imagens utilizando câmera DSLR e caixa de luz com fundo azul, otimizando o contraste para facilitar a segmentação. Os parâmetros analisados incluíram cor, formato, presença de impurezas e danos, obtidos por meio de separação de canais RGB e CMYK, limiarização de Otsu e detecção de bordas com o algoritmo de Canny. As técnicas clássicas de processamento de imagem forneceram um conjunto de dados rotulado usado para treinar modelos de aprendizado de máquina. Os resultados indicaram que esse método melhora significativamente a confiabilidade da classificação automatizada de grãos de soja.

Vlasov & Fadeev (2017) pesquisaram a classificação de sementes de cinco culturas importantes na Rússia (trigo, colza, *Phacelia*, linho e mostarda branca) em relação a pureza. Os parâmetros utilizados envolveram a extração de características visuais com técnicas como HOG, SURF, LBP e histogramas de cor. A tecnologia foi baseada em aprendizado de máquina tradicional, com classificação por "bag of features", palavras visuais, além do uso de redes neurais convolucionais para melhorar a acurácia. Os resultados mostraram que é possível alcançar boa precisão com baixo custo computacional e rápida resposta, sendo viável para sistemas de separação de sementes na indústria agrícola.

Um sistema de classificação online de sementes de soja com base em redes neurais convolucionais, foi proposto por Lin et al. (2023). As sementes foram categorizadas em quatro classes: normais, danificadas, anormais e não classificáveis. Os parâmetros considerados incluíram características visuais como cor, textura e integridade da casca. A tecnologia usada envolveu segmentação de imagem com MSRCR e uma CNN leve chamada SoyNet, implantada em uma plataforma NVIDIA Jetson TX2. O sistema alcançou precisão de 95,63% e tempo médio de classificação de 4,92 ms por semente, tornando-o adequado para aplicação em tempo real na indústria agrícola.

De forma similar Jitanan e Chimlek (2019) propuseram a classificação de sementes de soja em cinco categorias, que foram nomeadas normais, roxas, verdes, enrugadas e outras. Os parâmetros extraídos incluíram características de cor, usando o componente H do modelo HSI e textura com estatísticas da matriz de coocorrência. A tecnologia empregada foi um classificador SVM (máquina de vetor de suporte), com imagens processadas sob diferentes níveis de iluminação. Os resultados demonstraram excelente precisão, com valores de acurácia entre 97,9% e 100% para as diferentes classes, validando o modelo como altamente robusto e eficiente para classificação de sementes mesmo sob variações de luz e formato.

No contexto da classificação de variedades de sementes de soja, Wei et al. (2020) propuseram essa classificação em seu trabalho usando imagens hiperespectrais e algoritmos de aprendizado de máquina em conjunto. Os parâmetros utilizados foram espectros refletidos das sementes em 462 bandas espectrais, processados com técnicas de pré-processamento, extração de características e seleção de bandas. A tecnologia principal empregada foi o algoritmo Random Subspace Linear Discriminant (RSLD), um classificador robusto baseado em subespaços aleatórios. Os resultados mostraram precisão de 99,2% na classificação de 15 variedades diferentes, superando os métodos tradicionais como LD (98,6%) e LSVM (69,7%), que apresentaram precisões de 98,6 e 69,7 por cento, respectivamente, de forma que evidenciou a eficácia do uso de algoritmos de ensemble com imagens hiperespectrais para classificação de sementes de soja.

Outro aspecto importante da classificação de grãos é deterioração por mofo, que foi justamente o que foi estudado no trabalho de Hu et al. (2022). A pesquisa teve como foco a detecção de diferentes níveis de mofo em sementes de milho, classificando-as entre saudáveis, levemente mofadas, moderadamente mofadas, mofo intenso e mofo severo, utilizando imagens hiperespectrais e aprendizado de máquina. A tecnologia aplicada envolveu o uso de Random Forest (RF) otimizado por um algoritmo de enxame chamado JYSSA (elite inverse-strategy-enhanced sparrow search algorithm). Os resultados alcançaram 96% de acurácia, demonstrando que o modelo proposto é altamente eficaz na detecção não destrutiva de sementes de milho com diferentes níveis de deterioração por mofo.

No que se refere a qualidade física de grãos, Zhang et al. (2023) estudou a classificação de sementes de soja, que foram separadas em duas categorias, nomeadas intactas e danificadas, incluindo sementes quebradas, com defeitos ou

danificadas por insetos. A tecnologia aplicada envolveu redes neurais convolucionais (CNNs), como AlexNet, VGG, ResNet e DenseNet, combinadas com técnicas de balanceamento de dados. O melhor resultado foi obtido com DenseNet, alcançando 98,48% de acurácia na classificação de sementes de soja, mesmo em um cenário de dados inicialmente desbalanceado.

3 METODOLOGIA

Para a realização do presente trabalho, foram empregados aspectos de revisão narrativa, para mapear conceitos pertinentes em relação à classificação de grãos e inteligência artificial, além do emprego de aspectos da revisão integrativa, para conciliar os parâmetros legais para a classificação de grãos de milho com o desempenho das tecnologias levantadas.

As bases de dados utilizadas como fonte de informação para a presente revisão foram Google Acadêmico, Periódicos da CAPES e Science Direct. Também foram utilizados legislações e normas pertinentes, além de artigos acadêmicos em inglês e português publicados nos últimos oito anos. Os artigos escolhidos, foram lidos na íntegra buscando dados relevantes sobre os aspectos técnicos, sociais, legais e econômicos.

Após a leitura dos artigos selecionados, realizou-se um fichamento bibliográfico de 13 artigos relacionados ao tema, sendo esse fichamento uma adaptação do método de fichamento bibliográfico de Malheiros (2011), que oferece uma fácil e rápida interpretação do conteúdo, proporciona uma visão geral do tema, além de facilitar estudos comparativos.

4 RESULTADOS

4.1 VISÃO GERAL

A crescente demanda por eficiência e qualidade na cadeia produtiva agrícola tem impulsionado o desenvolvimento de soluções tecnológicas voltadas à classificação de sementes e grãos. Entre essas tecnologias, destacam-se os sistemas baseados em visão computacional, aprendizado de máquina e, mais

recentemente, *deep learning*. Tais abordagens permitem uma análise mais precisa, rápida e objetiva das características físicas e fisiológicas dos grãos, contribuindo significativamente para a automação de processos, a padronização de lotes e a redução de perdas pós-colheita.

4.2 FICHAMENTO BIBLIOGRÁFICO

O fichamento bibliográfico proposto por Malheiros (2011), reúne e organiza informações extraídas de diversos artigos científicos nacionais e internacionais que tratam da classificação automatizada de sementes e grãos utilizando técnicas modernas de inteligência artificial. Cada referência apresenta diferentes abordagens metodológicas, culturas analisadas, tipos de algoritmos empregados, sistemas de aquisição de imagens e resultados obtidos.

A reunião deste material pretende oferecer uma visão geral do estado da arte nessa área de pesquisa, servindo como base para estudos comparativos, fundamentação teórica ou definição de metodologias para novos projetos. A tabela contempla autores, países de origem, objetivos dos estudos, tipos e quantidades de amostras analisadas, além dos principais resultados alcançados em cada investigação.

A ficha bibliográfica referente aos artigos relacionados ao tema “A inteligência artificial”, é apresentada na TABELA 1.

TABELA 1 – FICHA BIBLIOGRÁFICA DE ARTIGOS SOBRE INTELIGÊNCIA ARTIFICIAL NA CLASSIFICAÇÃO DE GRÃOS

Autor	País	Título	Data	Tipo	Objetivo	Principais Resultados
Jitanan & Chimlek	Tailândia	Quality grading of soybean seeds using image analysis	2019	Artigo científico	Desenvolver modelo de classificação de soja por imagem e ML, com foco em ruídos de sombra e iluminação.	Precisão de até 100% para sementes verdes, enrugadas e outras; SVM com HSI+GLCM obteve >97% para todas as classes.
Júnior et al.	Brasil	Proposed Approach for Creating Soybean Grain Image Dataset	2024	Artigo científico	Criar um sistema de aquisição de imagens e base de dados para classificação de grãos de soja.	Base robusta gerada com segmentações RGB, CMYK, Otsu, e Canny para uso em redes neurais.
Lin et al.	China	Online classification of soybean seeds based on deep learning	2023	Artigo científico	Classificar sementes de soja em tempo real usando CNN leve e segmentação MSRCR.	Precisão global de 95,63%; F-score >95% nas 4 classes; 4,92ms/classificação em Jetson TX2.
Lingwal et al.	Índia	Image-based wheat grain classification using CNN	2021	Artigo científico	Classificar 15 variedades de trigo com CNN ajustada para alta precisão e baixo erro.	Acurácia de 97,53% no teste e perda de 8%; modelo robusto via tuning de hiperparâmetros.
Ni et al.	EUA	Corn Kernel Breakage Classification by Machine Vision	1993	Artigo científico	Classificar grãos de milho quebrados via visão computacional e rede neural.	Alta precisão em distinguir níveis de quebra; viabilidade comprovada com redes neurais.
Assadzadeh et al.	Austrália	Deep Learning Segmentation in Bulk Grain Images	2022	Artigo científico	Prever porcentagem de grãos são em amostras de lentilha e grão-de-bico usando segmentação por deep learning.	RMSE de 3,1% e R ² de 0,99 na predição de grãos são por imagem em massa.
Farahnakian et al.	Finlândia	Comparative study of DL architectures for rice grain classification	2023	Artigo científico	Comparar arquiteturas DL para classificação de arroz (ResNet, VGG, EfficientNet, MobileNet).	EfficientNet teve acurácia de 99,67%; MobileNet foi o mais rápido.
Gadotti et al.	Brasil	Machine learning for soybean seeds lots classification	2022	Artigo científico	Classificar lotes de sementes de soja por qualidade fisiológica com ML.	Random Forest teve melhor acurácia entre os modelos testados.
Gonçalves Silva & Germano	Brasil	Separação de grãos com Deep Learning e Arduino	2024	Artigo científico	Desenvolver protótipo de baixo custo para separar feijões preto e carioca via CNN e Arduino.	Acurácia de 94,5%; viável para automação e ensino de IA.
Hu et al.	China	Classification of Maize Moldy Seeds by Hyperspectral Imaging	2022	Artigo científico	Classificar sementes de milho mofadas via imagem hiperespectral e RF otimizado.	Acurácia de 96%, precisão 100%, recall 93% com JYSSA-RF.
Velesaca et al.	Equador e Espanha	Deep Learning based Corn Kernel Classification	2020	Artigo científico	Desenvolver uma abordagem robusta para segmentação e classificação de grãos de milho (bons, defeituosos, impurezas) usando Mask R-CNN e uma CNN leve (CK-CNN).	O sistema superou modelos padrão (ResNet, VGG) e mostrou alta precisão na segmentação e classificação, mesmo com grãos tocando-se.
Sabanci et al.	Turquia	Computer vision-based method for classification of wheat grains using artificial neural network	2017	Artigo científico	Classificar trigo em duas categorias (bread e durum) usando visão computacional e rede neural artificial (MLP-ANN).	Obteve erro absoluto médio de $9,8 \times 10^{-6}$ com sete atributos visuais mais relevantes; classificou com alta precisão e simplicidade.
Zhang et al.	China	A Soybean Classification Method Based on Data Balance and Deep Learning	2023	Artigo científico	Melhorar a classificação de soja intacta vs. Danificada com redes profundas e métodos de balanceamento de dados (loss function e data augmentation).	DenseNet com nova função de perda (focal loss + label smoothing) obteve 98,48% de acurácia. Data augmentation excessiva reduziu desempenho em redes mais profundas.
Vlasov, A. V.; Fadeev, A. S.	Rússia	A machine learning approach for grain crop's seed classification in purifying separation	2017	Artigo científico	Avaliar a aplicação de machine learning para classificar sementes de grãos na etapa de purificação.	Classificadores baseados em machine learning alcançaram até 86% de acurácia. Com deep learning, a acurácia teórica pode chegar a 95–100%, dependendo da quantidade de imagens.

FONTE: O AUTOR.

4.3 DISCUSSÕES

Os estudos reunidos nesse fichamento evidenciam o avanço significativo das tecnologias aplicadas à classificação de sementes e grãos, com destaque para a integração entre visão computacional, aprendizado de máquina e redes neurais profundas, conforme abordado no trabalho de Gonçalves Silva & Germano (2024). Os resultados alcançados por diferentes autores demonstraram que tais abordagens são capazes de atingir altos índices de acurácia, muitas vezes superiores a 95%, superando os métodos manuais tradicionais em precisão, velocidade e reprodutibilidade, como Jitanan & Chimlek (2019) retrataram.

Os artigos abordaram várias culturas agrícolas, como soja, trigo, milho, arroz, lentilha, feijão e grão-de-bico, revelando a versatilidade das técnicas de inteligência artificial na avaliação de diferentes padrões de qualidade. Além disso, as pesquisas mostraram crescente interesse em soluções acessíveis e aplicáveis em tempo real, com potencial para uso direto em ambientes industriais e rurais, temática abordada também no trabalho de Lin et al. (2023).

Constatou-se também a preocupação com a criação de bases de dados robustas e a escolha criteriosa dos algoritmos e características extraídas, aspectos fundamentais para o sucesso dos modelos de classificação, preocupação abordada por Wei et al. (2020), em seu trabalho. Diante disso, os estudos analisados contribuem substancialmente para a consolidação do uso de inteligência artificial na agricultura, oferecendo caminhos promissores para o desenvolvimento de sistemas automatizados mais eficientes, acessíveis e confiáveis.

5 CONCLUSÕES

Conclui-se que as contribuições da inteligência artificial para a classificação de grãos através da aplicação das técnicas de visão computacional, aprendizado de máquina e deep learning são promissoras.

Além disso, destaca-se a possibilidade de expansão das soluções com o uso de redes neurais profundas em estudos futuros, visando sistemas cada vez mais robustos e eficientes na classificação automatizada de grãos.

6 REFERÊNCIAS

ALMEIDA, Jacqueline Marques Lara de et al. Sistema para classificação automática de grãos de soja baseado em visão computacional. 2024. Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná.

ARAGÃO, Adalberto; CONTINI, Elisio. O agro no Brasil e no Mundo: uma síntese do período de 2000 a 2020. Embrapa SIRE, 2021.

ASSADZADEH, Sahand; WALKER, Cassandra K.; PANOZZO, Joe F. Deep learning segmentation in bulk grain images for prediction of grain market quality. Food and Bioprocess Technology, v. 15, n. 7, p. 1615-1628, 2022.

BRASIL. IN nº 11, de 15 de maio de 2007. Estabelece o Regulamento Técnico da Soja, definindo o seu padrão oficial de classificação, com os requisitos de identidade e qualidade intrínseca e extrínseca, a amostragem e a marcação ou rotulagem. Diário Oficial da República Federativa do Brasil. Brasília, DF, 2007.

BRASIL. IN nº 60, de 22 de dezembro de 2011. Estabelece o Regulamento Técnico do Milho. Diário Oficial da República Federativa do Brasil. Brasília, DF, 2011.

BRASIL. Decreto nº 3.664, de 17 de novembro de 2000. Regulamenta a Lei nº 9.972/2000. Diário Oficial da União, 20 nov. 2000.

BRASIL. Lei nº 9.972, de 25 de maio de 2000. Dispõe sobre a classificação e a quantidade de produtos agrícolas.

CARVALHO, N. S. et al. Revisão: A importância da soja para o agronegócio brasileiro. Fitotecnia, sistemas agrícolas ambientais e solo. Ponta Grossa: Atena, v. 6, p. 52-60, 2023.

DA SILVA, Naiele Lurdes Oliveira et al. Déficit De Armazenagem de grãos no Brasil. Revista Multidisciplinar do Nordeste Mineiro, v. 2, n. 1, 2024.

DE OLIVEIRA, Dionatan Pontes et al. Análise e modelagem gradual de um aplicativo para classificação de grãos soja, milho, feijão e sorgo. Research, Society and Development, v. 10, n. 5, 2021.

DELWICHE, Stephen; MISKELLY, Diane. Analysis of grain quality at receival. In: Cereal grains. Woodhead Publishing, 2017. p. 513-570.

FAO; IFAD; UNICEF; WFP; WHO. The State of Food Security and Nutrition in the World 2024. Rome: FAO, 2024.

FARAHNAKIAN, Farshad et al. A comparative study of state-of-the-art deep learning architectures for rice grain classification. Journal of Agriculture and Food Research, v. 15, p. 100890, 2024.

GONÇALO, Roberto de Sousa. Avaliação da Qualidade dos Grãos de Milhos de Pipoca Comercializados na Região de Carajás, Sudeste do Pará. 2023. 47 f. Trabalho de Conclusão de Curso (Graduação em Agronomia) – Universidade Federal Rural da Amazônia, Parauapebas, 2023.

GONÇALVES SILVA, Elizângela Maria; GERMANO, Renato. Utilização de visão computacional e deep learning para separação de grãos. In: Tecnologias educacionais. Editora Científica Digital, 2024.

HIRAKURI, Marcelo Hiroshi et al. Análise de aspectos econômicos sobre a qualidade de grãos de soja no Brasil. Circular Técnica, v. 145, p. 1-22, 2018.

HU, Yating et al. Nondestructive classification of maize moldy seeds by hyperspectral imaging and optimal machine learning algorithms. Sensors, v. 22, n. 16, p. 6064, 2022.

INTERNATIONAL GRAINS COUNCIL – IGC. Grains Market Report – Summary. Londres, 2025.

JITANAN, Sutasinee; CHIMLEK, Pawat. Quality grading of soybean seeds using image analysis. Int. J. Electr. Comput. Eng, v. 9, n. 5, p. 3495-3503, 2019.

JORDAN, Michael I.; MITCHELL, Tom M. Machine learning: Trends, perspectives, and prospects. Science, v. 349, n. 6245, p. 255-260, 2015.

JÚNIOR, Gesmar de Paula Santos et al. Proposed Approach for Creating Soybean Grain Image Dataset. In: Latinoware, 2024.

LASKOWSKI, Wacław et al. How important are cereals and cereal products in the average Polish diet? Nutrients, v. 11, n. 3, p. 679, 2019.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. Nature, v. 521, p. 436-444, 2015.

LIAKOS, Konstantinos G. et al. Machine learning in agriculture: A review. Sensors, v. 18, n. 8, p. 2674, 2018.

LIN, Wei et al. Online classification of soybean seeds based on deep learning. Engineering Applications of AI, v. 123, p. 106434, 2023.

LINGWAL, Surabhi; BHATIA, Komal Kumar; TOMER, Manjeet Singh. Image-based wheat grain classification using CNN. Multimedia Tools and Applications, v. 80, n. 28, 2021.

MALHEIROS, B. T. Metodologia da pesquisa em educação. Rio de Janeiro: LTC, 2011.

MARQUES, B. D. A. Considerações ambientais e energéticas na fase de pós-colheita de grãos. UFPR, 2006.

NATH, Bidhan et al. Research and technologies to reduce grain postharvest losses: a review. *Foods*, v. 13, n. 12, 2024.

PIMENTEL, Fernando Campos et al. Perdas nas etapas pós-colheita do pré-processamento. *Observatório da Economia Latinoamericana*, v. 22, n. 4, 2024.

PORTELLA, José Antonio et al. *Secagem de grãos*, 2001.

RAMOS, Milena Yumi; RAMOS, Simone Yuri. Armazenagem agrícola no Brasil. *Revista de Política Agrícola*, v. 31, n. 3, p. 7, 2022.

SABANCI, Kadir; KAYABASI, Ahmet; TOKTAS, Abdurrahim. Computer vision-based method for classification of wheat grains using ANN. *JSFA*, v. 97, n. 8, 2017.

SARAIVA, António Mauro et al. A inteligência artificial na pesquisa agrícola. *Revista USP*, n. 141, p. 91-106, 2024.

SENAR. Grãos: classificação de soja e milho. Serviço Nacional de Aprendizagem Rural, 2017.

TADESSE, Kebede Tedila et al. The role of post-harvest management in ensuring food security. *JCRC Studies*, v. 2, n. 3, 2024.

THE BUSINESS RESEARCH COMPANY. Relatório de mercado global de produtos de grãos 2025.

VLASOV, Aleksey Viktorovich; FADEEV, Aleksandr Sergeevich. A machine learning approach for grain crop's seed classification. *JPCS*, 2017.

WDAROS, TENDÊNCIAS MUNDIAIS DA DEMANDA ALIMENTAR. [S.l.], 2013. Disponível em: trabalhosgratuitos.com. Acesso em: 10 jul. 2025.

WEI, Yanlin et al. Nondestructive classification of soybean seed varieties by hyperspectral imaging. *Sensors*, v. 20, n. 23, p. 6980, 2020.

ZHANG, Ning; ZHANG, Enxu; LI, Fei. A soybean classification method based on data balance and deep learning. *Applied Sciences*, v. 13, n. 11, 2023.