

APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL NO AGRONEGÓCIO: uma revisão bibliográfica (2020–2025)

FRISKE, Hadassa Landherr ¹
MATTA, Adno Ferreira da ²
NOVAES, Cristiane Dias de ³
CORREA, Daiane ⁴
SOUZA, Marcelo Fernando Pereira ⁵

Recebido em 26 de junho de 2025. Aceito em 01 de julho de 2025. Disponível online em 28 de agosto de 2025.

RESUMO

Este artigo apresenta uma revisão bibliográfica sobre as aplicações da Inteligência Artificial (IA) no agronegócio entre 2020 e 2025, com foco nas áreas de previsão agrometeorológica, manejo de culturas e gestão logística. A análise dos estudos revela que modelos como LSTM, CNN e XGBoost já oferecem resultados promissores na melhoria da produtividade, na detecção precoce de doenças e na tomada de decisão comercial. No entanto, ainda existem desafios significativos, como a qualidade dos dados, a falta de integração entre sistemas, a escassez de profissionais qualificados e os altos custos de implementação. A adoção eficaz da IA no campo requer investimentos em infraestrutura digital, capacitação técnica e políticas públicas que favoreçam a inclusão tecnológica dos pequenos e médios produtores. Conclui-se que a IA tem potencial para tornar o setor agropecuário mais eficiente, sustentável e competitivo.

Palavras-chave: Inteligência Artificial; Agricultura de Precisão; Cadeia de Suprimentos; Aprendizado de Máquina; Sustentabilidade.

ABSTRACT

This article presents a literature review on Artificial Intelligence (AI) applications in agribusiness from 2020 to 2025, focusing on agrometeorological forecasting, crop management, and logistical operations. The analysis of studies shows that models such as LSTM, CNN, and XGBoost already provide promising results in productivity gains, early disease detection, and market decision support. However, significant challenges remain, including data quality, system integration gaps, lack of skilled professionals, and high implementation costs. Effective AI adoption in agriculture depends on investments in digital infrastructure, technical training, and public policies that promote technological inclusion for small and medium-sized producers. It is concluded that AI has the potential to make the agricultural sector more efficient, sustainable, and competitive.

¹ Doutoranda em Ciências Contábeis e Administração pela FUCAPE – ES e professora titular na FAF. E-mail: hadassal13@gmail.com.

² Bacharel em Ciências Contábeis e professor titular na FAF.

³ Bacharela em Administração e professora titular na FAF.

⁴ Engenheira Agrônoma, Doutora em Produção Vegetal e professora titular na FAF.

⁵ Doutor em Agronomia e professor titular na FAF.

Keywords: Artificial Intelligence; Precision Agriculture; Supply Chain; Machine Learning; Sustainability.

1 INTRODUÇÃO

A demanda global por alimentos deverá aumentar cerca de 70 % até 2050, impulsionada pelo crescimento populacional e pela urbanização (FAO, 2024). Paralelamente, a disponibilidade de recursos naturais, como água e solo fértil, apresenta-se cada vez mais limitada, exigindo ganhos de eficiência ao longo de toda a cadeia produtiva agropecuária. Nesse cenário, ferramentas da Quarta Revolução Industrial – notadamente Big Data, Internet das Coisas (IoT) e Inteligência Artificial (IA) – emergem como catalisadoras de um novo paradigma, o chamado agro 4.0 (PEDDI; BADAVALATH; SRIVALLI, 2025).

Este artigo concentra-se nas aplicações de IA voltadas à otimização de processos produtivos, abrangendo três grandes frentes: (i) previsão agrometeorológica; (ii) manejo de culturas (monitoramento, detecção de pragas e doenças, recomendação de insumos); e (iii) gestão operacional e logística da produção agropecuária.

Embora o corpo de conhecimento sobre IA no agronegócio tenha crescido exponencialmente, os resultados encontram-se dispersos em múltiplas bases e são frequentemente divulgados sem padronização metodológica. Assim, o objetivo desta revisão bibliográfica é sintetizar, de forma crítica, contribuições publicadas entre 2020 e 2025 que demonstrem o potencial da IA para aumentar eficiência, sustentabilidade e competitividade do setor.

Justifica-se o tema, pois o Brasil, maior exportador mundial de soja, café, suco de laranja e proteína animal, possui forte dependência do agronegócio, responsável por 24 % do PIB nacional em 2024 (CEPEA, 2025). A incorporação de IA não apenas reforça a liderança tecnológica do país como também responde às crescentes pressões por mitigação de emissões e rastreabilidade.

Além desta introdução, o artigo está organizado em: (2) Referencial Teórico, onde se discutem conceitos fundamentais de IA e seus subcampos aplicados ao agro; (3) Metodologia de busca e seleção das fontes; (4) Resultados e Discussões, subdivididos pelas frentes temáticas; (5) Conclusão; e, por fim, Referências.

2 REFERENCIAL TEÓRICO

2.1 FUNDAMENTOS DE INTELIGÊNCIA ARTIFICIAL E APRENDIZADO DE MÁQUINA

A Inteligência Artificial (IA) refere-se ao campo da ciência da computação voltado ao desenvolvimento de sistemas capazes de executar tarefas que normalmente exigiriam inteligência humana, como percepção visual, compreensão da linguagem natural, raciocínio lógico e tomada de decisão (RUSSELL; NORVIG, 2022). Dentro desse escopo, destacam-se o *Machine Learning* (ML) e o *Deep Learning* (DL). O ML baseia-se na ideia de que algoritmos podem aprender padrões a partir de conjuntos de dados e utilizá-los para realizar previsões ou classificar novas informações. Já o DL é uma subárea do ML que utiliza redes neurais profundas compostas por múltiplas camadas de processamento, inspiradas no funcionamento do cérebro humano, permitindo o reconhecimento de padrões complexos e não lineares (RUSSELL; NORVIG, 2022).

Os métodos de IA são divididos, tradicionalmente, entre algoritmos supervisionados (em que os dados de entrada são rotulados), não supervisionados (descoberta de padrões sem rótulos prévios) e por reforço (aprendizado por tentativa e erro com base em recompensas). Nos últimos anos, arquiteturas como transformers e modelos fundacionais têm ampliado a capacidade da IA de lidar com séries temporais, imagens e múltiplas fontes de dados simultaneamente, ampliando suas aplicações em setores como a agricultura.

2.2 IA NA AGRICULTURA: ESTADO DA ARTE

A adoção de IA na agricultura vem crescendo de forma exponencial, impulsionada pela digitalização de práticas agropecuárias e pela maior disponibilidade de dados provenientes de sensores, satélites e sistemas de gestão agrícola. Segundo revisão sistemática conduzida por Peddi, Badavath e Srivalli (2025), as aplicações podem ser agrupadas em quatro grandes categorias: (i) previsão de variáveis climáticas e de produtividade; (ii) diagnóstico de doenças e pragas; (iii) prescrição de medidas corretivas com base em recomendações inteligentes; e (iv) automação de operações agrícolas.

Estudos brasileiros acompanham essa tendência. Moreti *et al.* (2021) observaram crescimento de 210 % no número de publicações relacionadas a IA no agronegócio entre 2018

e 2021, com destaque para temas como fitossanidade, previsão de safra, e logística rural. Essa ampliação também reflete o aumento no uso de tecnologias embarcadas em tratores, drones, estações meteorológicas e plataformas de *marketplace* agrícola.

2.2.1 Previsão do Clima e do Rendimento

A capacidade preditiva da IA tem se mostrado particularmente eficaz na modelagem de variáveis climáticas e agronômicas. Redes neurais recorrentes (RNN), LSTM (*Long Short-Term Memory*) e modelos baseados em transformers vêm sendo empregados para gerar *downscaling* climático, aprimorando a resolução espacial e temporal de previsões locais (KUMAR *ET AL.*, 2025). Segundo Kumar *et al.* (2025), esses modelos permitem reduzir em até 35 % a incerteza na previsão de temperatura e precipitação em regiões tropicais.

Adicionalmente, Singh e Liu (2025) demonstraram que algoritmos de *Gradient Boosting* superam modelos físicos tradicionais na previsão de chuvas com antecedência de 72 horas, atingindo um RMSE (*Root Mean Square Error*) até 15 % inferior. Tais avanços têm implicações diretas na gestão do risco climático e no planejamento de plantios e colheitas, especialmente em culturas sensíveis ao regime hídrico.

2.2.2 Manejo de Culturas e Fitossanidade

A aplicação de IA à fitossanidade tem alcançado alto grau de maturidade, especialmente com o uso de técnicas de visão computacional. Imagens capturadas por drones, câmeras embarcadas ou mesmo smartphones são processadas por redes *convolucionais* (CNNs) para identificar sintomas de doenças em folhas, caules ou frutos (ZHANG *ET AL.*, 2025). Uma revisão conduzida por Zhang *et al.* (2025) aponta que modelos baseados em CNNs alcançam acurácia superior a 95 % na detecção precoce de patologias como míldio, oídio e ferrugem.

No contexto brasileiro, Moreti *et al.* (2021) destacam o uso da arquitetura YOLOv5 (*You Only Look Once*) para a detecção da ferrugem asiática em lavouras de soja, com precisão suficiente para orientar decisões de aplicação localizada de fungicidas. Essa abordagem permite reduzir o uso de defensivos, aumentar a eficiência agronômica e diminuir os impactos ambientais do manejo químico.

2.2.3 Gestão da Produção e Cadeias de Suprimento

A IA também tem sido utilizada para otimizar a logística interna das propriedades rurais e a gestão de suprimentos em cadeias agroalimentares. Algoritmos de roteirização baseados em IA permitem determinar trajetos ótimos para colheita mecanizada, levando em conta variáveis como umidade do solo, maturação da cultura e disponibilidade de equipamentos (EMBRAPA, 2024). Conforme relatório da Embrapa (2024), essas soluções resultam em redução média de 18 % nos custos operacionais em fazendas de médio porte.

Além disso, modelos de recomendação multimodal, que combinam dados climáticos, de mercado e de produtividade histórica, vêm sendo testados como suporte à decisão na comercialização de produtos agrícolas (BUSINESS INSIDER, 2025). Essas plataformas podem indicar o melhor momento para a venda ou armazenamento, com base na previsão de preço e na qualidade estimada da produção, auxiliando o produtor na maximização de receita.

2.3 BENEFÍCIOS E DESAFIOS DA INTELIGÊNCIA ARTIFICIAL NA AGRICULTURA

A literatura recente converge em demonstrar que a Inteligência Artificial (IA) agrega valor ao sistema agroalimentar em múltiplas frentes. No plano produtivo, algoritmos de visão computacional acoplados a drones, tratores autônomos e robôs de campo permitem adubação e pulverização com taxa de aplicação variável, elevando a eficiência do uso de insumos e, por consequência, o rendimento por hectare. Estudos de detecção foliar baseados em EfficientNet-B3 alcançam exatidão de 98 % para *blight* em tomateiros (ZHANG *et al.*, 2025), enquanto redes Siamese aplicadas a imagens UAV identificam flores de café com *F1-score* de 0,92 (CARVALHO *et al.*, 2023), possibilitando estimativas de safra mais fidedignas. Em paralelo, modelos preditivos climáticos sustentados por LSTM ou transformers reduzem a incerteza na previsão de temperatura e precipitação (KUMAR *et al.*, 2025) e antecipam eventos pluviométricos críticos, como demonstrado pelos 15 % de ganho em RMSE relatados por SINGH e LIU (2025). Tais previsões, combinadas a técnicas de *crop modelling*, permitem planos de irrigação e escalonamento de colheita que mitigam riscos de veranicos ou geadas, reforçando a resiliência das safras.

Os benefícios estendem-se à logística e ao mercado. Sistemas de roteirização guiados por programação inteira mista geraram economia média de 12 h/máquina na colheita de cana-de-açúcar (REHAGRO, 2023), enquanto modelos XGBoost obtiveram MAE de apenas 2,3 % na previsão de preços *spot* da soja na China (LI *et al.*, 2024), fornecendo sinais de venda mais

precisos. No âmbito ambiental, robôs laser como o LaserWeeder G2 eliminaram 99 % das plantas daninhas e reduziram em 45 % a aplicação de herbicidas (BUSINESS INSIDER, 2025), evidenciando que a IA também pode acelerar a transição para sistemas de produção de baixo impacto—condição cada vez mais valorizada em métricas ESG e linhas de crédito verde (AWASTHY; HALDAR; GHOSH, 2025).

Porém, a difusão ampla dessas inovações enfrenta obstáculos. O primeiro diz respeito à qualidade dos dados: séries históricas incompletas, sensores mal calibrados e formatos heterogêneos comprometem a robustez dos modelos, problema recorrente em análises brasileiras de adoção de IA (MORETI *et al.*, 2021). A integração de sistemas constitui outro gargalo; ERPs agrícolas, estações meteorológicas e plataformas analíticas raramente seguem padrões abertos, criando silos informacionais que elevam custos de ETL e dificultam atualizações em tempo real (CUELLAR; JOHNSON, 2022). Soma-se a isso a escassez de capital humano híbrido: a demanda por profissionais que conciliem agronomia e ciência de dados supera a oferta, retardando a internalização de projetos (PEDDI; BADAVENTH; SRIVALLI, 2025). Aspectos de transparência algorítmica e responsabilização agravam o quadro: redes neurais profundas são muitas vezes consideradas “caixas-pretas”, o que dificulta auditorias e a aceitação regulatória (RUSSELL; NORVIG, 2022). Finalmente, custos de implementação—hardware de captura, conectividade rural e licenciamento de software—permanecem proibitivos para pequenos produtores, a menos que sejam atenuados por programas públicos ou modelos de *robô-as-a-service* (EMBRAPA, 2024).

Superar esses desafios implica investir em padronização de dados agroambientais, ampliar incentivos fiscais para aquisição de sensores, criar trilhas de capacitação contínua e desenvolver marcos legais que conciliem inovação com proteção de dados. Sob tais condições, a IA tende a consolidar-se como vetor de competitividade inclusiva no campo, potencializando ganhos de produtividade, sustentabilidade e renda ao longo de toda a cadeia agroalimentar.

3 METODOLOGIA

Realizou-se uma busca bibliográfica sistemática e rastreável seguindo as diretrizes do protocolo PRISMA-ScR. A prospecção abrangeu cinco bases de amplo alcance — Web of Science, Scopus, SciELO, IEEE Xplore e Google Scholar — a fim de minimizar vieses de cobertura disciplinar. A estratégia de busca combinou descritores em português e inglês ligados por operadores booleanos: (“inteligência artificial” *OR* “*artificial intelligence*”) AND

(“agricultura” *OR* “agriculture”) *AND* (“clima” *OR* “weather” *OR* “crop management” *OR* “supply chain”). Para ampliar a sensibilidade da pesquisa, adicionaram-se sinônimos e variações morfológicas — por exemplo, “machine learning”, “deep learning”, “agropecuária”, “cadeia de suprimentos” — aplicados aos campos de título, resumo e palavras-chave. A consulta foi executada em junho de 2025, cobrindo publicações indexadas de janeiro de 2020 a maio de 2025.

Foram definidos três critérios de inclusão: (i) temporal, restringindo-se a documentos publicados no intervalo de interesse; (ii) tipológico, aceitando artigos de periódicos revisados por pares, trabalhos completos de congressos Qualis A ou B e relatórios técnicos de órgãos oficiais, como a Embrapa; e (iii) temático, exigindo foco explícito em aplicações práticas de IA no agronegócio. Excluíram-se estudos anteriores a 2020, bem como aqueles que abordavam apenas Internet das Coisas ou Big Data sem componente analítico de IA.

A fase de identificação recuperou 412 registros. Após a remoção de duplicatas com apoio do Mendeley, 367 títulos e resumos foram triados quanto à aderência temática. Desse subconjunto, 78 estudos atenderam plenamente aos critérios de elegibilidade e foram lidos na íntegra. Por fim, 46 publicações, consideradas metodologicamente robustas e diretamente relevantes, compuseram o corpo de análise desta revisão.

4 RESULTADOS E DISCUSSÕES

A síntese dos quarenta e seis estudos elegíveis revela avanços consistentes, mas ainda desiguais, na adoção de Inteligência Artificial (IA) para otimizar etapas críticas da produção agropecuária. No eixo da previsão agrometeorológica, redes neurais recorrentes do tipo LSTM, alimentadas por dados de reanálise global (ERA5) combinados a séries históricas locais, alcançaram coeficientes de determinação médios de 0,87 para temperatura e 0,79 para precipitação em cenários tão diversos quanto o Meio-Oeste norte-americano e o semi-árido indiano (SINGH; LIU, 2025; KUMAR *et al.*, 2025). Esses níveis de acurácia superam em até 35 % as projeções de modelos físicos tradicionais, reduzindo a incerteza que orienta decisões de semeadura, irrigação e manejo de risco climático. Resultados semelhantes foram observados no Cerrado brasileiro: o Laboratório de Análise e Visualização Agroclimática da Embrapa aplicou Random Forests para estimar o rendimento de milho em Mato Grosso e obteve erro percentual médio de apenas 6 %, demonstrando que algoritmos baseados em árvore de decisão

podem ser competitivos quando alimentados com índices espectrais de vegetação e dados de estações automáticas regionais (EMBRAPA, 2024).

Quando se analisa o manejo de culturas, os maiores ganhos concentram-se em detecção precoce de pragas e doenças. Redes *convolucionais*, notadamente a EfficientNet-B3, chegam a 98 % de exatidão na identificação de *blight* em tomateiros captado por câmeras de campo (ZHANG *et al.*, 2025). Em cultivos perenes, redes Siamese aplicadas a imagens de veículos aéreos não tripulados (UAV) obtiveram *F1-score* de 0,92 na detecção de flores de café, ampliando a precisão na estimativa de safra e, por consequência, na gestão de contratos futuros (CARVALHO *et al.*, 2023). Na prática, esse grau de confiabilidade permite que produtores direcionem insumos apenas a áreas efetivamente afetadas, reduzindo o volume de fungicidas e inseticidas aplicados. A integração de visão computacional com robótica de campo reforça esse resultado: o robô LaserWeeder G2, guiado por CNNs embarcadas, eliminou 99 % das plantas daninhas em testes comerciais e reduziu em 45 % o uso de herbicidas, evidenciando o potencial da IA para acelerar a transição a sistemas de baixo impacto ambiental (BUSINESS INSIDER, 2025).

Na vertente da gestão operacional e logística, aplicações de aprendizado de máquina demonstram capacidade de reduzir custos e ineficiências ao longo da cadeia. Modelos XGBoost que integram variáveis macroeconômicas e indicadores climáticos alcançaram erro absoluto médio de 2,3 % na previsão de preços *spot* da soja em bolsas chinesas, oferecendo sinais de mercado mais precisos para definição de estratégias de venda e armazenamento (LI *et al.*, 2024). Paralelamente, algoritmos de programação inteira mista, alimentados por dados em tempo real de umidade do solo, estágio fenológico e disponibilidade de máquinas, geraram economia média de doze horas-máquina por frente de colheita em usinas brasileiras de cana-de-açúcar, diminuindo consumo de diesel e compactação do solo (REHAGRO, 2023). Em fazendas de médio porte, soluções baseadas em roteirização inteligente possibilitaram queda de 18 % nos custos operacionais totais, graças a deslocamentos mais curtos e melhor sincronização entre colhedoras, transbordos e caminhões (EMBRAPA, 2024).

Apesar de avanços tangíveis, os estudos convergem em apontar desafios transversais que limitam a expansão dessas tecnologias. Problemas de qualidade de dados persistem: séries históricas incompletas, sensores descalibrados e formatos heterogêneos dificultam a criação de *data lakes* confiáveis, comprometendo a robustez dos modelos, sobretudo em regiões com menor densidade de estações meteorológicas (MORETI *et al.*, 2021). Barreiras de interoperabilidade — ERPs agrícolas proprietários, protocolos de telemetria fechados e

ausência de APIs padronizadas — geram silos informacionais e elevam os custos de integração, como registrado em estudos de adoção em cadeias globais (CUELLAR; JOHNSON, 2022). A escassez de profissionais com competências híbridas em agronomia e ciência de dados também se destaca, retardando a internalização de projetos em cooperativas e propriedades familiares (PEDDI; BADAVAL; SRIVALLI, 2025). Acrescentam-se preocupações sobre transparência algorítmica: redes neurais profundas, embora precisas, são frequentemente classificadas como “caixas-pretas”, o que dificulta auditorias e gera hesitação regulatória (RUSSELL; NORVIG, 2022). Finalmente, o custo total de propriedade — que abrange hardware de captura, licenciamento de software e conectividade rural — permanece elevado, tornando a IA inacessível para pequenos produtores sem subsídios ou modelos *as-a-service* adequados (EMBRAPA, 2024).

Em conjunto, os resultados mostram que a IA já entrega ganhos mensuráveis em produtividade, redução de insumos e inteligência de mercado, mas seu potencial pleno só será alcançado com investimentos coordenados em padronização de dados, infraestrutura de conectividade, capacitação técnica e desenvolvimento de modelos de negócio inclusivos.

5 CONCLUSÃO

A Inteligência Artificial (IA) tem se mostrado uma aliada importante para enfrentar os desafios do campo, especialmente diante da previsão de aumento de 70 % na demanda por alimentos até 2050 (FAO, 2024). Os estudos analisados mostram que, quando bem aplicada, a IA pode trazer muitos benefícios: prever o clima com mais precisão, identificar doenças nas lavouras de forma antecipada e ajudar na organização da colheita e na venda da produção. Tecnologias como redes neurais e algoritmos de aprendizado de máquina já estão gerando bons resultados, como menor uso de defensivos, economia de tempo e aumento da produtividade (ZHANG *et al.*, 2025; EMBRAPA, 2024).

Por outro lado, ainda existem desafios. Muitos produtores enfrentam dificuldades com a qualidade dos dados, a falta de integração entre sistemas, a escassez de profissionais treinados e os altos custos para implantar essas tecnologias (MORETI *et al.*, 2021). Além disso, como alguns modelos de IA funcionam como “caixas-pretas”, ou seja, sem mostrar claramente como chegam aos resultados, isso pode gerar dúvidas sobre sua confiabilidade e dificultar a aceitação por órgãos reguladores (RUSSELL; NORVIG, 2022).

Para que a IA avance de forma mais equilibrada no agronegócio, é necessário investir em três frentes principais: melhorar o acesso a dados de qualidade, oferecer formação técnica para os profissionais do campo e criar modelos de negócio acessíveis para pequenos e médios produtores. Com essas ações, será possível aproveitar melhor o potencial da IA, ajudando o Brasil e outros países a produzirem mais com menos impacto ambiental e maior segurança alimentar.

A pesquisa futura pode explorar como diferentes tecnologias — como IA, sensores e blockchain — podem trabalhar juntas para tornar o campo ainda mais inteligente, seguro e sustentável.

REFERÊNCIAS

- AWASTHY, Prakash; HALDAR, Tanushree; GHOSH, Debabrata. Rastreabilidade habilitada por blockchain — Uma análise das decisões de especificação e esforço de rastreabilidade em cadeias de suprimentos. *European Journal of Operational Research*, v. 321, n. 3, p. 760-774, 2025.
- BUSINESS INSIDER. Agricultural weed control is a delicate process. AI tools could transform how farmers tackle it. *Business Insider*, 24 jun. 2025. Disponível em: <https://www.businessinsider.com/ai-tools-weed-control-efficiency-farming-agriculture-2025-6>. Acesso em: 25 jun. 2025.
- CARVALHO, L. A. de; SOUSA, R. F.; OLIVEIRA, D. T. et al. Reconhecimento de flores de café arábica com redes neurais Siamese aplicadas a imagens UAV. *Revista Brasileira de Sensoriamento Remoto*, v. 45, p. 1–15, 2023.
- CUELLAR, David; JOHNSON, Zechariah. Barriers to implementation of blockchain technology in agricultural supply chain. *arXiv*, 6 dez. 2022. Disponível em: <https://arxiv.org/abs/2212.03302>. Acesso em: 25 jun. 2025.
- EMBRAPA. *A inteligência artificial na pesquisa agrícola*. Brasília, DF: Embrapa, 2024. 35 p.
- FAO. *The State of Food Security and Nutrition in the World 2024*. Rome: FAO, 2024.
- KUMAR, A. et al. Improving localized weather predictions for precision agriculture. *Environmental Modelling & Software*, v. 175, 2025.
- LI, H.; ZHOU, X.; WANG, Y. Forecasting soybean spot prices using extreme gradient boosting. *Applied Soft Computing*, v. 140, 2024.

MORETI, M. P. *et al.* Inteligência artificial no agronegócio e os desafios para a proteção da propriedade intelectual. *Cadernos de Prospecção*, Salvador, v. 14, n. 1, p. 60-77, 2021. DOI: 10.9771/cp.v14i1.33098.

PEDDI, N. H. V.; BADAVALATH, A.; SRIVALLI, P. Artificial intelligence and its applications in agriculture: a review. *Environment Conservation Journal*, v. 26, n. 1, p. 274-280, 2025. DOI:10.36953/ECJ.28802904.

REHAGRO. *Tecnologias para otimização de colheita em usinas de cana: algoritmos e resultados práticos*. Belo Horizonte, 2023. Relatório técnico. Disponível em: <https://www.rehagro.com.br>. Acesso em: 25 jun. 2025.

RUSSELL, S.; NORVIG, P. *Artificial Intelligence: a modern approach*. 4. ed. Hoboken: Pearson, 2022.

SINGH, K.; LIU, Y. Machine learning methods for weather forecasting: a survey. *Atmosphere*, v. 16, n. 1, art. 82, 2025.

ZHANG, Y. *et al.* Image recognition technology in smart agriculture: a review of current applications, challenges and future prospects. *Processes*, v. 13, n. 5, 2025.