



ANAIS

LIMITES E RESPONSABILIDADES DA INTELIGÊNCIA ARTIFICIAL NO AGRONEGÓCIO: PROPOSTA DE UM FRAMEWORK DE ÉTICA EM DADOS PARA PREVISÃO DA PRODUTIVIDADE DA SOJA

SUZANE DOS SANTOS
suzane.santos@ufpr.br
UFPR

EGON WALTER WILDAUER
egon0910@gmail.com
UFPR

MARCELO MAIA
maiamarcelomaia@hotmail.com
UNIVERSIDADE FEDERAL DO PARANÁ

RESUMO: A crescente adoção de modelos de Machine Learning (ML) na agricultura de precisão tem ampliado a capacidade de previsão da produtividade da soja, contribuindo para a otimização da tomada de decisão no agronegócio. Entretanto, a utilização dessas tecnologias ainda enfrenta desafios relacionados à opacidade dos modelos preditivos, à qualidade e à governança dos dados, aos vieses algorítmicos e à definição de responsabilidades diante de falhas nas previsões. Nesse contexto, este trabalho tem como objetivo propor um Framework de Ética em Dados para orientar a aplicação de modelos de Machine Learning na estimativa da produtividade da soja. Para alcançar esse objetivo, desenvolveu-se uma pesquisa teórico-conceitual, de abordagem qualitativa, fundamentada em revisão bibliográfica estruturada e análise temática, que subsidiou a proposição do framework. Como resultado, foi proposto um framework composto por cinco dimensões complementares: governança e aquisição ética de dados; integridade e mitigação de vieses algorítmicos; explicabilidade dos modelos por meio da Inteligência Artificial Explicável (XAI), como o método SHAP; accountability e limites da Inteligência Artificial; e segurança e confiabilidade dos dados. O framework estabelece diretrizes para promover transparência, responsabilidade, proteção de dados e apoio qualificado à tomada de decisão, compreendendo a Inteligência Artificial como ferramenta de suporte à decisão humana, e não como substituta da validação agrônoma. Conclui-se que a incorporação de princípios éticos e de explicabilidade aos sistemas preditivos pode fortalecer a confiabilidade, reduzir riscos operacionais e financeiros e favorecer a geração de valor e a sustentabilidade na gestão do agronegócio.

PALAVRAS CHAVE: Ética em Dados; Inteligência Artificial; Machine Learning; Governança de Dados; Produtividade da Soja.

ABSTRACT: The growing adoption of Machine Learning (ML) models in precision agriculture has enhanced the ability to predict soybean yield, contributing to improved decision-making in agribusiness. However, the use of these technologies still faces challenges related to the opacity of predictive models, data quality and governance, algorithmic bias, and the definition of responsibilities in the event of prediction failures. In this context, this study aims to propose a Data Ethics Framework to guide the application of Machine Learning models for soybean yield prediction. To achieve this objective, a theoretical-conceptual study with a qualitative approach was conducted, based on a structured literature review and thematic analysis, which supported the development of the proposed framework. As a result, a framework composed of five complementary dimensions was developed: data governance and ethical data acquisition; integrity and algorithmic bias mitigation; model explainability through Explainable Artificial Intelligence (XAI), such as the SHAP method; accountability and the limits of Artificial Intelligence; and data security and reliability. The framework establishes guidelines to promote transparency, accountability, data protection, and qualified support for decision-making, positioning Artificial Intelligence as a tool to support human decision-making rather than a substitute for agronomic validation. It is concluded that incorporating ethical principles and explainability into predictive systems can strengthen reliability, reduce operational and financial risks, and foster value creation and sustainability in agribusiness management.

KEY WORDS: Data Ethics; Artificial Intelligence; Machine Learning; Data Governance; Soybean Yield.



1. INTRODUÇÃO

A soja ocupa posição central no agronegócio brasileiro, exercendo forte influência sobre o Produto Interno Bruto (PIB) e sobre a balança comercial nacional. Com a crescente complexidade do setor produtivo, a competitividade do agronegócio moderno depende cada vez mais de uma gestão baseada em dados e de ferramentas tecnológicas que ampliem a produtividade e reduzam riscos. Nesse cenário, a aplicação de técnicas de *Machine Learning* (ML) tem se consolidado como uma abordagem promissora na agricultura de precisão, permitindo modelar relações complexas entre variáveis climáticas, edáficas e de manejo para gerar previsões de safra consistentes (PEREIRA; BEKER; SCHMOELLER, 2024). Ao analisar grandes volumes de dados, o uso de inteligência artificial capacita agricultores e gestores a tomarem decisões bem fundamentadas em toda a cadeia de suprimentos agrícola.

Apesar do notável avanço preditivo, a integração dessas tecnologias na gestão do agronegócio enfrenta desafios práticos e éticos significativos. Muitas soluções baseadas em *Machine Learning* operam como "caixas pretas", dificultando a tradução dos processamentos matemáticos em recomendações de manejo compreensíveis ao produtor. Além disso, a capacidade de generalização dos algoritmos é frequentemente limitada, modelos treinados em um local ou período específico podem apresentar falhas ao serem aplicados em diferentes contextos geográficos devido a variações climáticas, tipos de solo e práticas de cultivo. Essa deficiência técnica é agravada pelo fato de que as bases de dados agrícolas frequentemente apresentam inconsistências, lacunas e baixa padronização, o que pode induzir modelos a reproduzirem falhas de predição (CRAVERO et al., 2022).

Diante dessas limitações, o uso de *Machine Learning* no campo deixa de ser apenas um desafio tecnológico e passa a envolver graves implicações éticas e operacionais. À medida que os sistemas de ML se tornam mais integrados ao cotidiano agrícola, questões sociais e morais exigem um gerenciamento cuidadoso para a construção de um ambiente de confiança na adoção das inovações (GARDEZI et al., 2023). A dependência de informações privadas de manejo extraídas de propriedades rurais levanta debates sensíveis sobre a privacidade e a governança de dados. Ademais, previsões enviesadas podem induzir o agricultor a decisões financeiras equivocadas, suscitando dilemas sobre a equidade e a responsabilidade (*accountability*) caso ocorram quebras de produtividade induzidas por recomendações algorítmicas falhas (Ryan, 2022).

Considerando essa problemática, o objetivo deste trabalho é propor um *Framework* de Ética em Dados direcionado à aplicação de modelos de *Machine Learning* na estimativa de produtividade da soja. O estudo busca estruturar diretrizes que conciliem a acurácia preditiva com a transparência algorítmica, utilizando técnicas de explicabilidade, como o método SHAP, para identificar fatores críticos de rendimento de forma clara para os gestores. Espera-se que a adoção de um *framework* ético promova não apenas o uso responsável de dados privados e a mitigação de vieses, mas também o entendimento de que as estimativas automatizadas atuam como ferramentas de suporte à decisão humana, mitigando os riscos nos negócios rurais e garantindo uma integração tecnológica confiável, transparente e sustentável na agricultura moderna.

2. REVISÃO TEÓRICA

2.1 A agricultura de precisão e o *Machine Learning* (ML)

A agricultura de precisão consiste na utilização de tecnologias avançadas, conhecimentos integrados e ferramentas especializadas para aprimorar as práticas agrícolas e maximizar a eficiência produtiva. Segundo Sinha et al. (2024), essa abordagem engloba a coleta e a análise de dados referentes às condições climáticas, saúde das culturas e propriedades do solo, viabilizadas pelo uso de tratores guiados por GPS, drones para imageamento aéreo, sensores de solo e softwares de gestão de dados. O objetivo central dessa integração tecnológica é embasar a tomada de decisão no campo, auxiliando os gestores rurais a otimizarem a aplicação de insumos, mitigarem os impactos ambientais e aumentarem o rendimento das safras.

Diante do grande volume e da complexidade das informações geradas por esses sistemas de monitoramento (*Big Data*), as abordagens analíticas convencionais frequentemente mostram-se insuficientes, impulsionando a adoção de sistemas de Inteligência Artificial. Nesse contexto, o Aprendizado de Máquina ou *Machine Learning* (ML), atua como um subcampo focado no desenvolvimento de algoritmos e modelos estatísticos que capacitam os computadores a aprenderem com os dados, reconhecendo padrões complexos para a execução de predições autônomas. Conforme postulado por Mitchell (1997), a diferenciação central do *Machine Learning* em relação à estatística clássica reside na capacidade de adaptar automaticamente a sua estrutura matemática com base no desempenho alcançado durante o treinamento. Essa característica confere aos modelos a flexibilidade necessária para capturar relações não lineares

em sistemas agrícolas, os quais são intrinsecamente marcados por elevada variabilidade espacial e temporal.

A incorporação de modelos de *Machine Learning* à agricultura de precisão tem promovido saltos qualitativos na otimização da cadeia produtiva. Algoritmos preditivos processam informações oriundas do sensoriamento remoto e de históricos de manejo para antecipar cenários de produtividade, detectar pragas de forma precoce e recomendar parâmetros de irrigação. No entanto, a implementação escalável dessas tecnologias no agronegócio depara-se com gargalos técnicos expressivos. Cravero et al. (2022) destacam que a fragmentação das bases de dados agrícolas, a falta de padronização nas informações coletadas nas propriedades rurais e o desafio de processar o *Big Data* constituem os principais entraves para a generalização desses modelos. Superar essas barreiras tecnológicas e de integração de dados é o requisito primário para que os algoritmos preditivos ofereçam suporte real e confiável à gestão agrícola.

2.2 Previsão de produtividade na cultura da soja: avanços e limitações

A aplicação de Inteligência Artificial na previsão de produtividade da soja tem demonstrado resultados substancialmente superiores aos métodos estatísticos tradicionais. Algoritmos avançados, como *Random Forest*, *XGBoost* e Redes Neurais, têm alcançado alta precisão preditiva ao integrar diversas fontes de dados, incluindo variáveis climáticas, edáficas e práticas agronômicas (ACCORSI, 2025; PEREIRA; BEKER; SCHMOELLER, 2024). Além disso, a integração com o sensoriamento remoto tem se provado uma ferramenta decisiva; o uso de imagens de satélite e drones para a extração de índices de vegetação (como NDVI e SAVI) em estádios fenológicos críticos (R4 e R5) permite o monitoramento em tempo real do vigor vegetativo, refinando as estimativas de rendimento e apoiando a agricultura de precisão (MARRA, 2023).

Apesar da elevada acurácia obtida em condições controladas, a implementação prática desses modelos em larga escala na gestão do agronegócio esbarra em limitações estruturais. Um dos principais desafios é a qualidade e a heterogeneidade dos dados. As bases agrícolas frequentemente sofrem com a falta de padronização, lacunas históricas e acessibilidade limitada, características que variam drasticamente entre diferentes propriedades e regiões produtoras (CRAVERO et al., 2022). A eficácia do *Machine Learning* é altamente dependente da integridade dos dados que o alimentam, logo, treinar algoritmos com dados inconsistentes compromete a confiabilidade das predições e dificulta a generalização do modelo para diferentes cenários climáticos, geográficos ou temporais (SINHA et al., 2024).

Outra barreira técnica e operacional significativa reside na complexidade inerente aos modelos preditivos de alto desempenho. Muitos algoritmos operam como uma "caixa preta", o que limita severamente a sua interpretabilidade. Essa falta de transparência impede que produtores e gestores rurais compreendam as razões matemáticas por trás de uma estimativa de produtividade, minando a confiança necessária para que as decisões de manejo sejam baseadas na IA.

Diante desse cenário, a superação das limitações tecnológicas na agricultura transcende os desafios computacionais, adentrando na esfera da responsabilidade gerencial. Fica evidente a necessidade de integrar ferramentas de explicabilidade algorítmica para traduzir previsões complexas em ações práticas, garantindo que o avanço tecnológico não resulte em exclusão digital ou em decisões agronômicas enviesadas.

2.3 Desafios éticos e explicabilidade algorítmica (XAI) na gestão rural

A crescente integração de sistemas de *Machine Learning* no cotidiano agrícola transcende as barreiras tecnológicas, impondo a necessidade de gerenciar cuidadosamente questões éticas e sociais. Para a construção e manutenção da confiança (*trust*) na adoção da Inteligência Artificial pelos gestores rurais, é indispensável enfrentar desafios intrínsecos a essas ferramentas, como o viés algorítmico (*bias*) e a garantia de equidade (*fairness*) na distribuição dos benefícios tecnológicos (GARDEZI et al., 2023). O uso de bases de dados enviesadas ou a exclusão de variáveis locais pode gerar modelos preditivos que favoreçam injustamente grandes corporações agropecuárias em detrimento de pequenos produtores, exacerbando as desigualdades socioeconômicas e a exclusão digital no campo.

Esse cenário evidencia a importância de se estabelecer marcos morais robustos. Ryan (2022) destaca princípios éticos fundamentais que devem nortear a implementação da IA agrícola, incluindo o respeito à privacidade, a justiça e a transparência. Sob a ótica da governança, o treinamento de algoritmos de alta precisão depende da coleta massiva de dados edáficos, climáticos e de manejo, muitas vezes extraídos de softwares privados de gestão rural. A utilização dessas informações levanta debates sobre a propriedade dos dados e a necessidade de protocolos rigorosos de consentimento e anonimização, a fim de proteger o agricultor contra a exploração indevida de seu histórico produtivo.

Além da governança e da privacidade, a indefinição sobre a responsabilidade (*accountability*) na tomada de decisão representa um desafio gerencial crítico, frequentemente apontado como um dos maiores entraves éticos na agricultura inteligente (RYAN, 2022;

GARDEZI et al., 2023). A natureza de "caixa preta" inerente a muitos modelos avançados, como Redes Neurais Profundas, limita severamente a sua interpretabilidade. A falta de transparência impede que gestores e agrônomos compreendam as razões matemáticas que levaram o sistema a sugerir uma determinada intervenção. Diante da instabilidade climática, caso uma recomendação algorítmica resulte em quebra de safra, a dificuldade de atribuir responsabilidade moral e financeira mina a confiança necessária para a consolidação da tecnologia.

Para solucionar o dilema da opacidade, a literatura aponta a necessidade urgente de integrar técnicas de Inteligência Artificial Explicável (XAI - *Explainable AI*), como o LIME e o SHAP, que aumentam a confiança ao tornar as previsões dos algoritmos mais interpretáveis e transparentes. O método SHAP (*Shapley Additive exPlanations*), proposto originalmente por Lundberg e Lee (2017), fornece uma compreensão abrangente das previsões matemáticas ao quantificar a contribuição média e exata de cada característica para o resultado (Mahmud et al., 2024). Ele se destaca por utilizar recursos visuais avançados — como gráficos de resumo (*summary plots*), gráficos de força (*force plots*) e gráficos de dependência — para ilustrar as atribuições de cada variável e mostrar como elas interagem entre si para influenciar a previsão.

Mais do que apenas elencar a importância das variáveis, a análise SHAP permite observar o comportamento local e direcional dos dados agronômicos. A técnica demonstra visualmente, por exemplo, como instâncias com valores mais altos de uma determinada variável (como chuva, umidade ou índice de nutrientes no solo) empurram a previsão de produtividade para cima, enquanto valores mais baixos a reduzem de forma não linear. Ao traduzir o processamento de "caixas pretas" em evidências visuais claras e justificáveis, garante-se um processo decisório participativo e transparente, fator essencial para assegurar a aceitação da sociedade, a mitigação de riscos e a confiança das partes interessadas no agronegócio (BADSHAH et al., 2024).

Sob essa ótica ética, a Inteligência Artificial deixa de ser vista como uma substituta infalível da validação agronômica e consolida-se como um sistema transparente de suporte à decisão. Garantir a explicabilidade e a responsabilidade no uso dos modelos preditivos é, portanto, o alicerce para uma gestão rural justa, segura e tecnologicamente sustentável.

2.4 Governança de dados e aspectos regulatórios

O uso crescente de Inteligência Artificial no agronegócio amplia a necessidade de mecanismos de governança que assegurem transparência, responsabilidade e conformidade regulatória (RYAN, 2022). Embora os dados usados em modelos preditivos agrícolas não sejam

majoritariamente pessoais, informações sobre produtores, propriedades, geolocalização, produtividade e operações podem exigir cuidados específicos quanto a uso, armazenamento e compartilhamento.

Nesse contexto, princípios da LGPD (BRASIL, 2018) contribuem para a governança dos dados agrícolas ao promover transparência, finalidade, necessidade, segurança e responsabilização, além de serem essenciais para garantir a qualidade das informações usadas no treinamento de modelos de Machine Learning.

Cabe destacar uma zona de ambiguidade jurídica: a aplicabilidade da LGPD varia conforme a natureza jurídica do produtor. Como pessoa física, perfil comum entre pequenos e médios agricultores, dados como geolocalização e histórico de manejo podem se enquadrar como dado pessoal identificável, sujeito às proteções da lei. Já em pessoas jurídicas, comuns em grandes propriedades e cooperativas, os mesmos dados tendem a ser tratados como segredo industrial, escapando ao escopo da LGPD e demandando proteção por outras vias, como cláusulas contratuais e propriedade intelectual.

Essa distinção importa porque a LGPD não protege necessariamente o produtor contra a exploração comercial abusiva de seus dados, como o uso de históricos de produtividade por fornecedores de insumos para precificação discriminatória, reforçando a assimetria de poder na cadeia de dados agrícolas e evidenciando uma lacuna que frameworks setoriais de governança, como o proposto neste estudo, buscam parcialmente preencher. Soma-se a isso a ausência de orientações da ANPD específicas para o agronegócio, diferentemente do que já ocorre na saúde.

A adoção de políticas de governança permite reduzir riscos de uso inadequado dos dados, aumentar a confiabilidade dos sistemas preditivos e fortalecer a legitimidade das decisões apoiadas por IA no agronegócio.

3. PROCEDIMENTOS METODOLÓGICOS

3.1 Caracterização da pesquisa

A presente pesquisa caracteriza-se como um estudo de natureza teórico-conceitual, de abordagem qualitativa e objetivos exploratório-descritivos. Quanto aos procedimentos técnicos de execução, adotou-se a revisão bibliográfica estruturada como método sistemático para mapear os desafios éticos, gerenciais e de governança na agricultura digital, servindo de base para a formulação do *framework* conceitual proposto.

Cabe realizar uma importante delimitação de escopo: este artigo especificamente não se configura como uma pesquisa aplicada de modelagem estatística ou desenvolvimento de código computacional direto. Em vez disso, o estudo atua como uma investigação conceitual-normativa baseada no estado da arte da literatura científica. Assim, o trabalho cumpre o papel de consolidar as diretrizes teóricas, as salvaguardas éticas e os requisitos de explicabilidade necessários para subsidiar futuras pesquisas aplicadas, simulações empíricas e implementações de campo, garantindo que o desenvolvimento tecnológico no agronegócio avance em conformidade com as boas práticas de governança de dados

3.2 Estratégia de busca bibliográfica

A revisão bibliográfica foi conduzida em uma única frente de pesquisa, com o objetivo de identificar estudos que integrassem simultaneamente a aplicação de tecnologias como Inteligência Artificial e *Machine Learning* no agronegócio com as discussões teóricas sobre ética em dados, governança, transparência algorítmica, explicabilidade (XAI) e responsabilidade (*accountability*).

As buscas foram realizadas em 14 de junho de 2026 nas bases Scopus e OpenAlex, selecionadas por sua abrangência multidisciplinar e ampla cobertura de publicações científicas nas áreas de tecnologia e agricultura. Para garantir o rigor e a padronização da amostra, a pesquisa em ambas as bases foi restrita exclusivamente a artigos científicos disponibilizados em acesso aberto (*Open Access*) e publicados entre os anos de 2015 e 2026.

3.3 Procedimentos de busca e seleção dos estudos

Para a identificação da literatura técnica, a estratégia de busca foi desenhada para cruzar três eixos temáticos fundamentais: tecnologias de Inteligência Artificial, contexto agrícola e aspectos éticos e de governança, consolidando-os em uma única equação.

A pesquisa nas bases Scopus e OpenAlex foi restrita à área de Ciências Agrárias e estruturada para capturar os termos nos campos de título, resumo e palavras-chave. Visando assegurar o máximo rigor metodológico e a reprodutibilidade da revisão, a busca na base Scopus foi parametrizada utilizando a seguinte sintaxe avançada:

TITLE-ABS-KEY ((("artificial intelligence" OR "machine learning") AND ("agriculture" OR "agribusiness" OR "soybean" OR "soy") AND ("ethics" OR "responsible AI" OR "data governance" OR "algorithmic accountability" OR "explainable AI" OR "transparency"))) AND PUBYEAR > 2015 AND PUBYEAR < 2026 AND (LIMIT-TO (OA , "all")) AND (LIMIT-TO (SUBJAREA , "AGRI")) AND (LIMIT-TO (DOCTYPE , "ar"))

A execução desta estratégia de busca sistematizada, que foi replicada respeitando os mesmos blocos booleanos de palavras-chave e parâmetros limitadores na base OpenAlex, resultou na extração inicial de 51 artigos na base Scopus e 360 artigos na base OpenAlex, compondo um acervo bruto de 411 artigos científicos potenciais para a etapa de triagem e análise.


3.4 Critérios de inclusão e exclusão

Foram incluídos estudos que abordassem pelo menos um dos seguintes temas: aplicação de Inteligência Artificial na agricultura, *Machine Learning* para previsão de produtividade agrícola, sistemas de apoio à decisão no agronegócio, governança de dados; ética em Inteligência Artificial, transparência e explicabilidade algorítmica (XAI) e responsabilidade e *accountability* em sistemas inteligentes.

Foram excluídos documentos duplicados, estudos sem relação direta com os objetivos da pesquisa, publicações sem revisão por pares e trabalhos cujo foco principal não estivesse relacionado à agricultura, ao agronegócio ou aos aspectos éticos do uso da Inteligência Artificial. Da amostra bruta de 426 obras identificadas, 48 registros duplicados entre as bases Scopus e OpenAlex foram removidos na etapa de triagem; os registros remanescentes foram então analisados por meio da leitura de títulos, resumos e palavras-chave, sendo selecionados aqueles com maior acurácia e aderência ao objetivo da pesquisa.

Ao final do processo de triagem e leitura integral, a amostra final foi refinada para 21 obras centrais, sendo 13 artigos provenientes das buscas sistematizadas nas bases Scopus e OpenAlex, e 8 documentos adicionais (incluindo legislações, como a LGPD, guias éticos e literatura prévia e clássica) identificados a partir de buscas manuais. O processo detalhado de identificação, triagem e inclusão dos estudos está visualizado no fluxograma da Figura 1

FIGURA 1 – Fluxograma de seleção e triagem da literatura



Fonte: Elaborado pelos autores (2026)

3.5 Análise dos estudos e construção do *framework*

A amostra final de 21 obras selecionadas foi submetida a um processo sistemático de análise temática, orientado pelas diretrizes metodológicas de Braun e Clarke (2006) para a identificação, análise e reporte de padrões (temas) a partir de dados qualitativos. O procedimento de análise foi realizado de forma manual e individual, estruturado em quatro etapas consecutivas para garantir a reprodutibilidade do estudo

1. **Familiarização com o corpus e extração de dados:** Realizou-se a leitura integral e repetida das 21 obras selecionadas, acompanhada do fichamento estruturado dos objetivos, metodologias, principais tecnologias de IA citadas e conclusões de cada estudo.
2. **Codificação inicial:** Aplicou-se a codificação aberta e indutiva diretamente nos textos. Nesta etapa, trechos específicos que discutiam gargalos, riscos, salvaguardas ou responsabilidades no uso de IA agrícola foram associados a códigos preliminares de significado (por exemplo: expressões como "*black box*", "propriedade dos dados", "exclusão digital de pequenos produtores", "criptografia AES " e "*SHAP/LIME*" foram isoladas e codificadas).
3. **Mapeamento e agrupamento por afinidade:** Os códigos gerados na etapa anterior foram agrupados manualmente por similaridade semântica em subtemas emergentes. Por exemplo, os códigos relacionados a "LGPD", "consentimento" e "arquiteturas federadas" foram correlacionados, assim como os códigos focados na opacidade do modelo e uso de métodos explicativos.
4. **Definição e nomeação dos temas estruturais:** Por meio de um processo iterativo de refinamento conceitual, os agrupamentos foram sintetizados e validados frente ao objetivo geral da pesquisa, culminando na consolidação das cinco dimensões analíticas que fundamentam o *framework* proposto: governança e aquisição ética de dados; integridade e mitigação de vieses algorítmicos; explicabilidade algorítmica (XAI); *accountability* e limites da IA; e segurança e confiabilidade dos dados.

Com base nessas cinco dimensões, o *framework* ético foi desenvolvido de forma a traduzir os achados teóricos da literatura em diretrizes gerenciais e ações práticas, servindo como um guia normativo para a implementação responsável de modelos preditivos na cadeia da soja, mitigando riscos de tomada de decisão e salvaguardando os direitos dos produtores rurais.

4. RESULTADOS E DISCUSSÕES

Apesar dos avanços observados na literatura sobre Inteligência Artificial aplicada ao agronegócio, os estudos analisados abordam predominantemente aspectos específicos da adoção dessas tecnologias, como desempenho preditivo dos modelos, governança de dados, explicabilidade algorítmica (XAI), mitigação de vieses ou responsabilidade no uso da IA. A análise da literatura realizada nesta pesquisa evidenciou que essas dimensões são tratadas, em

geral, de forma independente, não sendo identificado um *framework* conceitual que as integre em uma estrutura única direcionada à previsão da produtividade da soja.

Nesse contexto, a principal contribuição deste trabalho consiste na proposição de um *Framework* de Ética em Dados que organiza essas dimensões de maneira sistêmica e interdependente, estabelecendo um fluxo lógico de diretrizes para apoiar o desenvolvimento, a implementação e a utilização responsável de modelos de *Machine Learning* no agronegócio. Diferentemente de instrumentos de avaliação ética mais amplos, como o ELSA (*Ethical, Legal and Social Aspects*) proposto por van Hilten et al. (2025) — que oferece uma ferramenta geral de checagem para sistemas de IA no setor agroalimentar — o *framework* aqui proposto é especificamente direcionado ao fluxo decisório da previsão de produtividade da soja, articulando governança e aquisição ética de dados, integridade e mitigação de vieses algorítmicos, explicabilidade dos modelos por meio de técnicas de XAI, *accountability* e limites da autonomia da IA, além de segurança e confiabilidade dos dados como componentes complementares de um mesmo processo decisório.

Assim, o *framework* não representa apenas uma consolidação da literatura, mas uma proposta conceitual integradora que transforma evidências científicas dispersas em um modelo estruturado de apoio à gestão agrícola. Ao reunir essas cinco dimensões em uma arquitetura única, o estudo oferece uma contribuição teórica para o campo da Inteligência Artificial aplicada ao agronegócio e um instrumento gerencial capaz de orientar futuras implementações e validações empíricas em sistemas de previsão de produtividade da soja.

A proposição do *Framework* de Ética em Dados para Previsão de Produtividade da Soja fundamenta-se na premissa de que a eficácia da Inteligência Artificial (IA) no agronegócio não deve ser avaliada exclusivamente por métricas de acurácia estatística, mas também por sua transparência, equidade e capacidade de mitigar riscos operacionais e sociais no processo de tomada de decisão.

Para demonstrar a ligação direta entre os desafios estruturais identificados na revisão da literatura e a construção teórica do *framework*, o Quadro 1 sintetiza a fundamentação que originou cada uma das dimensões.


QUADRO 1. Relação de fundamentação das dimensões do framework na literatura científica

Dimensão do <i>framework</i> (eixo)	Foco e Desafios Teóricos identificados	Literatura de Sustentação (Corpus)
Governança e Aquisição Ética de dados	Assimetria de poder na cadeia de dados agrícolas, propriedade da informação técnica das fazendas, consentimento informado e Aprendizado Federado para proteção de dados privados.	RYAN (2020) ; SINHA et al. (2024) ; DEMBANI et al. (2025) ; BRASIL (2018)
Integridade e Mitigação de Vieses Algorítmicos	Exclusão digital no campo, representatividade amostral, viés geográfico e socioeconômico de modelos de alta tecnologia que desconsideram o perfil de pequenos produtores rurais.	CRAVERO et al. (2022) ; BAMPASIDOU et al. (2024) ; VAN HILTEN et al. (2025)
Explicabilidade Algorítmica (XAI)	Opacidade de modelos de "caixa-preta" (<i>black box</i>), necessidade de interpretabilidade agronômica das decisões matemáticas e aplicação do método SHAP para compreender variáveis climáticas e biofísicas.	LUNDBERG; LEE (2017) ; LEE et al. (2025) ; CHEEMA et al. (2026) ; PRABHU; SAMANTH; CHADAGA (2025) .
Responsabilização (<i>Accountability</i>) e Limites da IA	Definição de responsabilidades jurídicas e financeiras em falhas de predição e quebra de safras, preservação da agência e supervisão humana e limitações de generalização espacial/temporal dos algoritmos.	ALEXANDER; YARBOROUGH; SMITH (2024) ; RYAN (2022) ; GARDEZI et al. (2023) .
Segurança e Confiabilidade dos Dados	Vulnerabilidade de dados meteorológicos e edáficos a ataques cibernéticos, necessidade de criptografia avançada (padrão AES-256) nas bases preditivas e rastreabilidade das fontes de informação.	PRABHU; SAMANTH; CHADAGA (2025) ; ONGADI (2024)

Fonte: Elaborado pelos autores (2026).

Como resposta às limitações inerentes aos modelos preditivos classificados como "caixas pretas" e à heterogeneidade das bases de dados agrícolas, o *framework* atua como um protocolo orientador aplicável ao desenvolvimento de sistemas de suporte à decisão. A estrutura proposta divide-se em cinco eixos centrais que acompanham o fluxo de informações desde a captação dos dados na propriedade rural até a validação agronômica da predição final. A Figura 2 apresenta a estrutura conceitual do *framework* proposto.

FIGURA 2. Estrutura conceitual do *Framework* Ético



FONTE: Elaborada pelos autores (2026)

O detalhamento das diretrizes, ações propostas e impactos gerenciais de cada um dos cinco pilares conceituais apresentados na Figura 2 está sistematizado no Quadro 2 a seguir.

QUADRO 2. Diretrizes do *Framework* Ético em Dados para Previsão de Produtividade da Soja

Pilares do <i>Framework</i>	Desafio Técnico e Ético Identificado	Diretriz e Ação Proposta (O Filtro)	Impacto na Gestão do Agronegócio
1. Governança e Aquisição Ética de Dados	Uso de dados de softwares privados de propriedades rurais levanta sérias preocupações com a privacidade dos dados e exclusão digital.	Consentimento e Anonimização: Exigência de protocolos transparentes de autorização do produtor rural para o uso e o compartilhamento do seu histórico de manejo.	Segurança jurídica e estabelecimento de uma relação de confiança na alimentação do Big Data da fazenda.
2. Integridade e Mitigação de Vieses Algorítmicos	Bases agrícolas possuem lacunas, baixa padronização e ruídos de eventos climáticos extremos, gerando "viés algorítmico".	Pré-processamento Rigoroso: Padronização obrigatória de variáveis e tratamento de anomalias (como secas) para que o algoritmo não reproduza um padrão de dados enviesado.	Prevenção contra estimativas distorcidas que induzam o gestor a alocar recursos de forma incorreta e assimétrica.
3. Explicabilidade Algorítmica (XAI)	Modelos preditivos avançados funcionam como "caixas pretas", dificultando a tradução dos cálculos matemáticos para a realidade agronômica.	Aplicação do Método SHAP: Uso de técnicas para quantificar a contribuição exata de cada variável (clima, solo, índices de vegetação) nas previsões de safra geradas, detalhando em nível global e local.	Transparência; o gestor e agrônomo recebe um relatório interpretável, compreendendo os motivos exatos que levaram a IA a sugerir aquela previsão.
4. <i>Accountability</i> e Limites da IA	Algoritmos possuem dificuldade de generalização espacial/temporal; o modelo pode falhar dependendo das variáveis geográficas e climáticas locais.	IA como Suporte à Decisão: Estabelecimento de que a máquina indica riscos e tendências, mas a validação final e a responsabilidade pelas decisões permanecem sob supervisão humana especializada.	Mitigação de riscos financeiros e manutenção do protagonismo do ser humano e da equidade na gestão rural.
5. Segurança e Confiabilidade dos Dados	Falhas na qualidade ou segurança dos dados podem comprometer diretamente a confiabilidade das previsões geradas, produzindo impactos econômicos relevantes.	Validação e Proteção: Validação periódica das bases de dados; identificação de inconsistências; rastreabilidade das fontes; proteção contra alterações não autorizadas e documentação.	Garantir a integridade, disponibilidade e rastreabilidade dos dados utilizados nos sistemas de previsão de produtividade.

Fonte: Elaborado pelos autores (2026)

O primeiro eixo, Governança e Aquisição Ética de Dados, dialoga com as preocupações de Sinha et al. (2024) sobre privacidade na era tecnológica. A coleta massiva de dados de manejo por softwares comerciais, sem governança adequada, levanta debates sobre a propriedade da informação agrícola: conforme Ryan (2020), o acúmulo de dados por grandes provedores de tecnologia cria assimetrias de poder que podem ser exploradas comercialmente. Para mitigar esse risco, Dembani et al. (2025) propõem o "Aprendizado Federado", que permite a colaboração entre fazendas no treinamento de algoritmos sem centralizar os dados brutos.

Essas diretrizes conectam-se ao quinto eixo (Segurança e Confiabilidade dos Dados). A digitalização massiva aumenta a vulnerabilidade a ataques cibernéticos, o que pode desvirtuar as estimativas de safra (ONGADI, 2024). Prabhu, Samanth e Chadaga (2025) demonstraram que a criptografia avançada (padrão AES-256) garante confidencialidade e integridade sem comprometer o desempenho computacional do modelo.

O segundo eixo trata da Mitigação de Vieses. As bases agrícolas sofrem com fragmentação e falta de padronização (CRAVERO et al., 2022); treinar algoritmos com dados enviesados gera recomendações distorcidas. Bampasidou et al. (2024) e Van Hilten et al. (2025) alertam que concentrar o desenvolvimento de IA em dados de grandes propriedades aprofunda o "abismo digital" no campo, exacerbando desigualdades socioeconômicas — tornando o pré-processamento rigoroso e o balanceamento representativo requisitos técnicos e de justiça social.

O terceiro pilar estabelece a integração de recursos de Inteligência Artificial Explicável (XAI) para solucionar a opacidade dos modelos de alto desempenho, que operam como "caixa-preta" e impedem que agrônomos compreendam as variáveis que determinaram uma estimativa. O método SHAP (*Shapley Additive Explanations*), proposto por Lundberg e Lee (2017), traduz os pesos matemáticos do algoritmo em três níveis de interpretação:

1. **Análise de Importância Global:** consolida a relevância de cada atributo agrônomo e meteorológico. No estudo de Lee et al. (2025), o índice NDVI destacou-se como variável de maior peso preditivo global; em Prabhu, Samanth e Chadaga (2025), a característica "Cultivar" foi a de maior impacto, com variedades de alto potencial elevando as estimativas de produtividade.
2. **Diagnóstico Local por Instância:** gráficos de cascata explicam estimativas individuais por talhão. Cheema et al. (2026) demonstram que, diante de uma quebra de safra, o gráfico identifica se o declínio foi motivado por estresse hídrico, permitindo intervenção cirúrgica (irrigação de salvamento, correção localizada).

3. **Relações de Dependência e Interações Não-Lineares:** o SHAP quantifica sinergias entre fatores agroclimáticos — por exemplo, como a radiação solar elevada combinada a estresse hídrico severo induz fotoinibição e reduz a produtividade estimada, ou como a umidade do solo estabiliza a produtividade em solos arenosos.

Ao traduzir decisões matemáticas em relatórios com significado agrônomo palpável, o SHAP transforma previsões abstratas em inteligência prática de campo, reconstruindo a confiança entre produtor e IA e mantendo o operador humano como supervisor final.

Por fim, o quarto eixo aborda os Limites da Autonomia Decisória e a *Accountability*. Modelos preditivos possuem dificuldade de generalização e podem falhar diante de mudanças climáticas abruptas ou variáveis geográficas locais (ALEXANDER; YARBOROUGH; SMITH, 2024). A complexidade da cadeia de desenvolvimento da IA gera ainda o "problema de muitas mãos", diluindo a responsabilidade por falhas preditivas entre desenvolvedores, provedores de nuvem e agricultores (GARDEZI et al., 2023). O *framework* estabelece, assim, que a IA deve atuar como ferramenta de apoio à decisão, não substituta da validação humana — a responsabilidade final recai sobre gestores e agrônomos (ALEXANDER et al., 2024), garantindo alinhamento com a prudência agrônoma e a segurança alimentar.

4.1 Aplicação ilustrativa do *framework*: um caso hipotético

Para demonstrar a operacionalização gerencial do *framework* proposto, simulou-se a aplicação prática de suas diretrizes em uma propriedade hipotética produtora de soja, denominada "Fazenda Bela Vista", localizada no polo agrícola de Luís Eduardo Magalhães, BA. O cenário pressupõe que o proprietário (Produtor Carlos) e sua equipe utilizem um modelo preditivo baseado no algoritmo *eXtreme Gradient Boosting* (XGBoost) alimentado por variáveis meteorológicas, dados de solo e sensoriamento remoto (índice NDVI via satélite) para estimar o rendimento da lavoura. A implementação ocorre de forma integrada ao longo das cinco dimensões éticas estruturadas:

- **Eixo 1 — Governança e Aquisição Ética de Dados:** Antes do plantio, o produtor firma um termo de consentimento claro e livre de jargões com a desenvolvedora do *software*. O acordo detalha a coleta de dados de manejo (semeadura, adubação e maquinário) e garante que o agricultor retenha a soberania informacional sobre seu negócio, mitigando assimetrias de mercado e riscos de espionagem comercial.
- **Eixo 2 — Integridade e Mitigação de Vieses Algorítmicos:** A quebra drástica de rendimento ocorrida na safra 2021/2022 devido a uma estiagem extrema (La Niña) é

tratada via pré-processamento estatístico rigoroso para que esse ruído histórico não distorça as previsões futuras. Além disso, ao estender o sistema para pequenas propriedades vizinhas sem sensores avançados, os cientistas de dados ajustam parâmetros locais para evitar estimativas equivocadas e mitigar a exclusão digital de produtores de menor porte.

• **Eixo 3 — Explicabilidade Algorítmica (XAI via SHAP):** Nos estádios fenológicos R4 e R5, diante de uma projeção alarmante de 42 sc/ha (bem abaixo da média histórica de 58 sc/ha), o método SHAP decodifica a "caixa-preta" algorítmica em três níveis: a *análise global* valida que o vigor vegetativo (NDVI) e a temperatura máxima são as variáveis de maior peso na região; o *diagnóstico local* aponta que a precipitação de apenas 15,2 mm no florescimento foi o principal vetor negativo; e as *relações de dependência* demonstram que a alta radiação solar associada ao déficit hídrico severo induziu à fotoinibição da soja, limitando o potencial produtivo.

• **Eixo 4 — Accountability e Limites da IA:** Embora o sistema sugira automaticamente uma intervenção drástica de manejo, a decisão final não é automatizada. A agrônoma Júlia realiza vistoria presencial para avaliar as condições biológicas reais em campo e a viabilidade econômica da ação (custo da irrigação suplementar emergencial contra o preço futuro da saca), mantendo a supervisão e a responsabilidade técnica estritamente sob agência humana.

• **Eixo 5 — Segurança e Confiabilidade dos Dados:** Para impedir interceptações ou adulterações mal-intencionadas que pudessem corromper as estimativas de safra e comprometer o planejamento financeiro da fazenda, todas as transmissões de dados — desde a telemetria dos sensores de umidade edáfica até a plataforma em nuvem — são protegidas por criptografia avançada sob o padrão AES-256.

Essa integração sequencial na "Fazenda Bela Vista" demonstra como o *framework* opera como um filtro ético-agronômico robusto, convertendo previsões abstratas em decisões de manejo seguras, transparentes e altamente confiáveis para o produtor

5. CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo propor um *Framework* de Ética em Dados direcionado à aplicação de modelos de *Machine Learning* na estimativa de produtividade da soja. A partir da revisão da literatura sobre Inteligência Artificial (IA) aplicada ao agronegócio e sobre os desafios éticos associados ao uso dessas tecnologias, verificou-se que a crescente adoção de

sistemas preditivos na agricultura de precisão amplia não apenas as oportunidades de otimização da tomada de decisão, mas também os riscos relacionados à governança de dados, à transparência algorítmica, à segurança da informação e à responsabilização pelas decisões apoiadas por sistemas autônomos.

Os resultados evidenciaram que a utilização de modelos de *Machine Learning* na previsão de produtividade agrícola enfrenta desafios que vão além das questões técnicas de desempenho e acurácia. Aspectos sociotécnicos relacionados à qualidade dos dados, à mitigação de vieses, à interpretabilidade dos modelos e à definição de responsabilidades tornam-se elementos essenciais para a adoção segura e confiável dessas tecnologias no contexto do agronegócio.

Como resposta a esses desafios, foi proposto um *framework* estruturado em cinco dimensões complementares: governança e aquisição ética de dados; integridade e mitigação de vieses algorítmicos; explicabilidade algorítmica (XAI); *accountability* e limites da IA; e segurança e confiabilidade dos dados. Em conjunto, essas dimensões oferecem diretrizes pragmáticas capazes de apoiar organizações, gestores rurais, pesquisadores e desenvolvedores na implementação responsável de sistemas de Inteligência Artificial voltados à previsão de produtividade da soja.

Destaca-se, ainda, que a utilização de técnicas de Inteligência Artificial Explicável (XAI), especialmente por meio do método SHAP, representa uma alternativa promissora para romper a opacidade característica dos modelos de "caixa preta", ampliando a transparência e fortalecendo a confiança dos usuários nos resultados produzidos pelos algoritmos. Sob essa perspectiva, a Inteligência Artificial deve ser compreendida estritamente como uma ferramenta de apoio à decisão humana, e não como substituta da análise técnica, da agência humana, da experiência agrônoma ou da responsabilidade gerencial.

Como limitação deste estudo, ressalta-se que, embora tenha sido apresentado um cenário de aplicação ilustrativa (Fazenda Bela Vista) para demonstrar a operacionalização das diretrizes do framework, o trabalho preserva um caráter fundamentalmente teórico-conceitual. Dessa forma, recomenda-se que pesquisas futuras realizem a validação empírica e quantitativa do modelo proposto diretamente em propriedades rurais, cooperativas ou organizações do agronegócio que utilizem sistemas de Inteligência Artificial em tempo real para previsão de safras, permitindo mensurar a efetividade prática dessas salvaguardas sob diferentes condições edafoclimáticas e socioeconômicas.



Por fim, conclui-se que o avanço da Inteligência Artificial no agronegócio demanda não apenas inovação tecnológica e computacional, mas também mecanismos capazes de garantir transparência, responsabilidade, segurança e confiança. Nesse sentido, o *framework* proposto contribui para aproximar os princípios da ética em dados das práticas de gestão agrícola, oferecendo uma estrutura conceitual que favorece o desenvolvimento e a adoção responsável de sistemas inteligentes na cadeia produtiva da soja e em outros contextos da agricultura digital.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- ACCORSI, L. **Estudo comparativo de modelos de machine learning para estimar a data de colheita no contexto da agricultura de precisão**. 2025. Trabalho de Conclusão de Curso (Graduação em Engenharia Agrônoma) – Universidade de Passo Fundo, Passo Fundo, 2025. Disponível em: <https://repositorio.upf.br/server/api/core/bitstreams/77005c49-4e42-4804-9d85-7c369b446d01/content>. Acesso em: 01 maio 2026.
- ALEXANDER, C. S.; YARBOROUGH, M.; SMITH, A. Who is responsible for ‘responsible AI’?: Navigating challenges to build trust in AI agriculture and food system technology. **Precision Agriculture**, v. 25, n. 1, p. 146–185, 2024. Disponível em: <https://doi.org/10.1007/s11119-023-10063-3>. Acesso em: 28 jun. 2026.
- BADSHAH, A. et al. Crop Classification and Yield Prediction using Robust Machine Learning Models for Agricultural Sustainability. **IEEE Access**, [S. l.], 2024. DOI: 10.1109/ACCESS.2024.3486653. Disponível em: <https://doi.org/10.1109/ACCESS.2024.3486653>.
- BAMPASIDOU, M. et al. Overcoming ‘digital divides’: Leveraging higher education to develop next generation digital agriculture professionals. **Computers and Electronics in Agriculture**, v. 224, p. 109181, 2024. Disponível em: <https://doi.org/10.1016/j.compag.2024.109181>.
- BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). **Diário Oficial da União**, Brasília, DF, 15 ago. 2018. Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/L13709.htm. Acesso em: 14 jun. 2026.
- CHEEMA, S. et al. Crop Yield Prediction, Informed decision-making, Machine Learning, Smart Agriculture, SHAP Interpretability. **The Journal of Animal & Plant Sciences**, v. 36, n. 3, 2026. Disponível em: <https://doi.org/10.1016/j.jatech.2024.100718>.
- CRAVERO, A. et al. Challenges to Use Machine Learning in Agricultural Big Data: A Systematic Literature Review. **Agronomy**, Basel, v. 12, n. 3, p. 748, mar. 2022. Disponível em: <https://www.mdpi.com/2073-4395/12/3/748>. Acesso em: 20 abr. 2026.
- DEMBANI, R. et al. Agricultural data privacy and federated learning: A review of challenges and opportunities. **Computers and Electronics in Agriculture**, v. 232, p. 110048, 2025. Disponível em: <https://doi.org/10.1016/j.compag.2025.110048>. Acesso em: 28 jun. 2026.
- GARDEZI, M. et al. Artificial intelligence in farming: Challenges and opportunities for building trust. **Agronomy Journal**, [S. l.], 2023. Disponível em: <https://access.onlinelibrary.wiley.com/doi/abs/10.1002/agj2.21353>. Acesso em: 14 jun. 2026.
- LEE, C. et al. Interpretable Analysis of Soybean Yield Forecasting Using Attention and SHAP: Temporal and Spatial Perspective. **International Journal on Advanced Science Engineering Information Technology**, v. 15, n. 6, 2025. Disponível em: <https://doi.org/10.18517/ijaseit.15.6.21656>. Acesso em: 28 jun. 2026.
- LUNDBERG, S. M.; LEE, S.-I. A unified approach to interpreting model predictions. In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS, 30., 2017, Long Beach. **Proceedings [...]**. Long Beach: Curran Associates, 2017. p. 4765-4774. Disponível em: <https://papers.nips.cc/paper/7062-a-unified-approach-to-interpreting-model-predictions>. Acesso em: 14 jun. 2026.
- MAHMUD, T. et al. An Approach for Crop Prediction in Agriculture: Integrating Genetic Algorithms and Machine Learning. **IEEE Access**, [S. l.], 2024. DOI: 10.1109/ACCESS.2024.3478739. Disponível em: <https://doi.org/10.1109/ACCESS.2024.3478739>. Acesso em: 14 jun. 2026.
- MARRA, T. M. **Predição de produtividade de soja por índices de vegetação e modelos de aprendizado de máquina**. 2023. 53 f. Dissertação (Mestrado em Engenharia de Biosistemas) – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal, 2023. Disponível em:

<https://repositorio.unesp.br/server/api/core/bitstreams/6a6641ed-058c-4b49-95e2-ca4a3bdf4257/content>. Acesso em: 2 maio 2026.

MITCHELL, T. M. **Machine learning**. New York: McGraw-Hill, 1997. Disponível em: <https://www.cs.cmu.edu/~tom/files/MachineLearningTomMitchell.pdf>. Acesso em: 2 maio 2026.

ONGADI, P. A. A comprehensive examination of security and privacy in precision agriculture technologies. **GSC Advanced Research and Reviews**, v. 18, n. 1, 2024. Disponível em: <https://doi.org/10.30574/gscarr.2024.18.1.0025>. Acesso em: 28 jun. 2026.

PEREIRA, E. M.; BEKER, J. P. S.; SCHMOELLER, R. Aplicação de Machine Learning na previsão da produtividade da soja. **Revista Pleiade**, [S.l.], v. 18, n. 45, p. 25–38, out./dez. 2024. Disponível em: <https://doi.org/10.32915/pleiade.v18i45.1069>. Acesso em: 3 maio 2026.

PRABHU, O.; SAMANTH, S.; CHADAGA, K. A unified model of explainable regression and AES-based data security for soybean yield prediction. **Smart Agricultural Technology**, v. 12, p. 101506, 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214785322013955>. Acesso em: 28 jun. 2026.

RYAN, M. Agricultural Big Data Analytics and the Ethics of Power. **Journal of Agricultural and Environmental Ethics**, v. 33, p. 49–69, 2020. Disponível em: <https://doi.org/10.1007/s10806-019-09812-0>. Acesso em: 28 jun. 2026.

RYAN, M. The social and ethical impacts of artificial intelligence in agriculture. **AI & SOCIETY**, [S. l.], v. 37, 2022. DOI: 10.1007/s00146-021-01377-9. Disponível em: <https://link.springer.com/article/10.1007/s00146-021-01377-9>. Acesso em: 14 jun. 2026.

SINHA, A. K. et al. Machine Learning Applications in Modern Agricultural Science. **International Journal of Scientific Research & Engineering Trends**, [S.l.], v. 10, n. 4, p. 1454-1458, jul./ago. 2024. Disponível em: https://www.researchgate.net/publication/383271991_Machine_Learning_Applications_in_Modern_Agricultural_Science. Acesso em:

VAN HILTEN, M. et al. Ethical, legal and social aspects (ELSA) for AI: An assessment tool for agri-food. **Smart Agricultural Technology**, v. 10, p. 100710, 2025. Disponível em: <https://doi.org/10.1016/j.atech.2024.100710>.