

**ADOÇÃO DE TECNOLOGIAS DE AGRICULTURA DE PRECISÃO E INTELIGÊNCIA ARTIFICIAL NO TRIÂNGULO MINEIRO: UM ESTUDO COM PRODUTORES RURAIS****ADOPTION OF PRECISION AGRICULTURE AND ARTIFICIAL INTELLIGENCE TECHNOLOGIES IN THE TRIÂNGULO MINEIRO: A STUDY WITH RURAL PRODUCERS****ADOPCIÓN DE TECNOLOGÍAS DE AGRICULTURA DE PRECISIÓN E INTELIGENCIA ARTIFICIAL EN EL TRIÂNGULO MINEIRO: UN ESTUDIO CON PRODUCTORES RURALES**Pedro Oliveira Marquez¹, Juliana Araujo Santos Martins²

e767999

<https://doi.org/10.47820/recima21.v7i6.7999>

PUBLICADO: 06/2026

RESUMO

Este estudo avalia o nível de adoção e a percepção dos produtores rurais sobre as tecnologias de Agricultura de Precisão (AP) e Inteligência Artificial (IA) na região do Triângulo Mineiro. A fundamentação teórica baseia-se na Teoria da Difusão de Inovações de Rogers (2003) e na evolução da Agricultura 4.0 como paradigma de gestão baseada em dados. A metodologia consistiu em um levantamento quantitativo-descritivo e exploratório, realizado com uma amostra de 20 produtores rurais vinculados à área de influência do Instituto Federal do Triângulo Mineiro (IFTM), selecionados por acessibilidade, utilizando questionário estruturado de 10 perguntas aplicado em 2025. Os resultados indicam que, embora o conhecimento sobre AP seja elevado (90%), a utilização efetiva é de apenas 40%, com variação geracional significativa: 75% entre produtores até 30 anos e 0% acima de 60 anos. Tecnologias consolidadas, como GPS e sistemas de piloto automático, predominam (70%), enquanto ferramentas avançadas de IA, como drones e softwares de gestão analítica, enfrentam barreiras de adoção. Os principais desafios identificados foram o alto custo de implementação (80%) e a falta de conectividade no campo (60%). A análise etária revelou que a falta de capacitação técnica afeta desproporcionalmente produtores acima de 50 anos (80% vs. 25% entre jovens). Conclui-se que o setor vivencia uma transição híbrida, na qual o otimismo quanto ao futuro (85% de intenção de investimento nos próximos dois anos) contrasta com a necessidade urgente de infraestrutura e capacitação técnica para a consolidação de uma gestão baseada em dados (*data-driven*).

PALAVRAS-CHAVE: Agricultura de Precisão. Agronegócio. Tecnologia Rural. Difusão de Inovações.

ABSTRACT

This study evaluates the level of adoption and perception of rural producers regarding Precision Agriculture (PA) and Artificial Intelligence (AI) technologies in the Triângulo Mineiro region of Brazil. The theoretical framework is grounded in Rogers' (2003) Diffusion of Innovations Theory and the Agriculture 4.0 paradigm as a model for data-driven management. The methodology consisted of a quantitative-descriptive and exploratory survey conducted with a sample of 20 rural producers linked to the area of influence of the Federal Institute of Triângulo Mineiro (IFTM), selected by convenience, using a structured 10-question questionnaire applied in 2025. The results indicate that while knowledge of PA is high (90%), effective utilization is only 40% with significant generational variation: 75% among producers up to 30 years old and 0% over 60 years old.

¹ Instituto Federal do Triângulo Mineiro – IFTM, graduando em Engenharia Agrônômica.

² Instituto Federal do Triângulo Mineiro – IFTM, Doutora em Fitotecnia/Fitopatologia.



Consolidated technologies such as GPS and automatic guidance systems predominate (70%), while advanced AI tools like drones and farm management and analytics software face adoption barriers. The main challenges identified were high implementation costs (80%) and lack of field connectivity (60%). Age analysis revealed that the lack of technical training disproportionately affects producers over 50 years of age (80% vs. 25% among young people). It is concluded that the sector is experiencing a hybrid transition, in which future optimism (85% investment intention over the next two years) contrasts with the urgent need for infrastructure and technical training to consolidate data-driven management.

KEYWORDS: *Precision Agriculture. Agribusiness. Rural Technology. Diffusion of Innovations.*

RESUMEN

Este estudio evalúa la adopción y percepción de los productores rurales respecto a la Agricultura de Precisión (AP) e Inteligencia Artificial (IA) en el Triángulo Mineiro, Brasil. El marco teórico se fundamenta en la Teoría de Difusión de Innovaciones de Rogers (2003) y en la Agricultura 4.0 como gestión basada en datos. La metodología consistió en un relevamiento cuantitativo-descriptivo y exploratorio con 20 productores rurales vinculados al Instituto Federal del Triángulo Mineiro (IFTM), mediante un cuestionario estructurado aplicado en 2025. Los resultados indican que, aunque el conocimiento sobre AP es elevado (90%), su uso efectivo es de apenas el 40%, con una marcada variación generacional: 75% entre productores menores de 30 años y 0% en mayores de 60 años. Tecnologías como GPS y piloto automático predominan (70%), mientras que herramientas avanzadas de IA, como drones y softwares analíticos, enfrentan barreras. Los principales desafíos identificados fueron el alto costo de implementación (80%) y la falta de conectividad (60%). El análisis etario reveló que la falta de formación técnica afecta desproporcionadamente a los mayores de 50 años (80% frente al 25% de los jóvenes). Se concluye que el sector vive una transición híbrida, donde el optimismo futuro (85% de intención de inversión) contrasta con la necesidad urgente de infraestructura y capacitación técnica para consolidar la gestión de datos.

PALABRAS CLAVE: *Agricultura de Precisión. Agronegocio. Tecnología Rural. Difusión de Innovaciones.*

1. INTRODUÇÃO

A agricultura mundial enfrenta o desafio de alimentar uma população global crescente com recursos naturais cada vez mais escassos, ao mesmo tempo em que precisa se adaptar às pressões das mudanças climáticas e às exigências de sustentabilidade ambiental. Nesse contexto, a incorporação de tecnologias digitais ao campo deixou de ser uma tendência e passou a ser uma necessidade estratégica (FAO, 2017). A chamada Agricultura 4.0 — ou Agricultura Inteligente emerge como resposta a esse imperativo, integrando sensores, drones, sistemas de georreferenciamento, Big Data e algoritmos de Inteligência Artificial (IA) na gestão das propriedades rurais (WOLFERT *et al.*, 2017).



A Agricultura de Precisão (AP) constitui o principal pilar operacional dessa transformação. Ao incorporar técnicas de manejo localizado e ferramentas de coleta e análise de dados geoespaciais, a AP permite otimizar a aplicação de insumos, reduzir custos operacionais e elevar a produtividade por área cultivada (GEBBERS; ADAMCHUK, 2010; BERNARDES; HINOJOSA, 2021). Mais recentemente, a integração de algoritmos de aprendizado de máquina (*machine learning*) e visão computacional à AP tem ampliado suas capacidades, possibilitando diagnósticos preditivos de pragas, análise de imagens de satélite e tomada de decisão autônoma em tempo real (LIAKOS *et al.*, 2018; KAMILARIS; PRENAFETA-BOLDÚ, 2018).

Apesar do potencial transformador dessas tecnologias, a literatura aponta que sua difusão entre os produtores rurais brasileiros é heterogênea e enfrenta barreiras estruturais significativas. Estudos realizados no Brasil indicam que fatores como o alto custo de implementação, a baixa conectividade nas áreas rurais, a escassez de mão de obra técnica qualificada e a incerteza sobre o retorno do investimento figuram entre os principais obstáculos à adoção (PIVOTO *et al.*, 2019; CARRER; SOUZA FILHO; VINHOLIS, 2022). Esse padrão é teoricamente explicado pela Teoria da Difusão de Inovações de Rogers (2003), segundo a qual a adoção de uma nova tecnologia depende de atributos percebidos como vantagem relativa, compatibilidade, complexidade, experimentabilidade e observabilidade. No contexto agrícola brasileiro, a percepção de complexidade e o custo de entrada frequentemente se sobrepõem à percepção de vantagem relativa, retardando a curva de adoção.

No âmbito do estado de Minas Gerais, a região do Triângulo Mineiro destaca-se como um polo agrícola relevante, com forte concentração na produção de soja, milho, cana-de-açúcar e café, além de pecuária bovina. Trata-se de uma região com infraestrutura logística relativamente desenvolvida, mas que também enfrenta as contradições típicas do agronegócio brasileiro: produtores de diferentes escalas, diferentes graus de capitalização e diferentes níveis de exposição à inovação tecnológica. Apesar de sua importância econômica, há escassez de estudos empíricos que mapeiem especificamente o nível de adoção e os determinantes de uso de AP e IA por produtores rurais dessa região, o que configura a lacuna científica que o presente trabalho busca preencher.

Diante do exposto, o presente trabalho tem como objetivo geral avaliar o nível de adoção e a percepção dos produtores rurais da região do Triângulo Mineiro sobre as tecnologias de Agricultura de Precisão e Inteligência Artificial. Especificamente, busca-se: (a) identificar o perfil dos produtores e das propriedades rurais participantes; (b) mensurar o nível de conhecimento técnico e utilização ativa de ferramentas de AP e IA; (c) mapear as tecnologias efetivamente



empregadas; (d) diagnosticar as principais barreiras que impedem a plena integração tecnológica; e (e) identificar a percepção dos produtores sobre o futuro da IA na agricultura e suas intenções de investimento.

2. REFERENCIAL TEÓRICO

2.1. Agricultura de precisão e agricultura 4.0

A Agricultura de Precisão surgiu na década de 1990 como um conjunto de técnicas orientadas ao manejo localizado de lavouras, substituindo práticas uniformes de aplicação de insumos por intervenções diferenciadas conforme a variabilidade espacial e temporal de cada talhão (FERNANDES, 2018). Seu fundamento técnico reside na integração de sistemas de posicionamento global (GPS), sensores embarcados, estações meteorológicas automatizadas e sistemas de informação geográfica (SIG), que coletam dados em múltiplos pontos da propriedade e os consolidam em plataformas de análise (GEBBERS; ADAMCHUK, 2010).

Com o avanço da conectividade digital e o barateamento dos sensores eletrônicos, a AP evoluiu para o que hoje se denomina Agricultura 4.0 ou *smart farming* — um paradigma que incorpora tecnologias da Quarta Revolução Industrial ao contexto agropecuário (SCHWAB, 2016). Nesse novo modelo, drones equipados com câmeras multiespectrais realizam diagnósticos fitossanitários automatizados, algoritmos de aprendizado de máquina analisam séries históricas de produtividade e variáveis climáticas para recomendar decisões agronômicas, e plataformas de Internet das Coisas (IoT) monitoram em tempo real o comportamento de animais, máquinas e culturas (WOLFERT *et al.*, 2017; SOTO *et al.*, 2021).

2.2. Inteligência Artificial na agricultura

No âmbito agrícola, a IA se manifesta por meio de diversas técnicas computacionais, incluindo redes neurais artificiais, algoritmos de aprendizado supervisionado e não supervisionado, visão computacional e processamento de linguagem natural (RUSSELL; NORVIG, 2020). Liakos *et al.* (2018) revisaram sistematicamente a aplicação de algoritmos de aprendizado de máquina em agricultura e identificaram quatro grandes domínios: gestão de pragas e doenças, gerenciamento de irrigação, monitoramento de solo e predição de produtividade. Kamilaris e Prenafeta-Boldú (2018), por sua vez, demonstraram que modelos de *deep learning* aplicados a imagens aéreas captadas por drones alcançam altas acurácias na detecção precoce de doenças foliares, reduzindo o uso de defensivos agrícolas.

Talaviya *et al.* (2020) destacam o papel da IA na otimização de sistemas de irrigação, demonstrando que modelos preditivos baseados em dados climáticos e de umidade do solo



podem reduzir o consumo de água em até 30%, ao mesmo tempo em que mantêm ou elevam a produtividade. Aubert *et al.* (2013) ressaltam que a IA potencializa a agricultura sustentável, permitindo decisões mais precisas sobre aplicação de fertilizantes e defensivos, com impacto direto na redução da pegada ambiental das operações agrícolas.

2.3. Adoção de tecnologias e a teoria da difusão de inovações

A adoção de inovações tecnológicas no meio rural é um processo complexo, influenciado por fatores individuais, sociais, econômicos e institucionais. Rogers (2003) propõe que a decisão de adoção de uma inovação é moldada por cinco atributos percebidos pelo adotante potencial: vantagem relativa (grau em que a inovação é percebida como superior à ideia que substitui), compatibilidade (grau de consistência com valores, experiências e necessidades do adotante), complexidade (grau de dificuldade percebida de uso), experimentabilidade (possibilidade de testar a inovação em escala limitada) e observabilidade (visibilidade dos resultados para outros). No agronegócio, esses atributos interagem com variáveis contextuais como o porte da propriedade, o nível de capitalização, o acesso a crédito e a disponibilidade de assistência técnica.

Pivoto *et al.* (2019) investigaram os fatores determinantes da adoção de *smart farming* no Brasil e identificaram que o tamanho da propriedade, o nível de escolaridade do produtor e o acesso à internet são preditores significativos da adoção. Carrer, Souza Filho e Vinholis (2022), em estudo específico sobre determinantes da adoção de AP no Brasil, confirmaram que o custo percebido e a incerteza sobre o retorno do investimento constituem as principais barreiras, especialmente entre produtores de menor porte. Silva *et al.* (2020) apontam que a transformação digital na agricultura brasileira avança de forma assimétrica, com adoção concentrada em grandes propriedades produtoras de grãos, enquanto pequenos e médios produtores permanecem à margem do processo.

3. METODOLOGIA

A pesquisa caracteriza-se como um estudo de levantamento (*survey*) de natureza quantitativa, com delineamento descritivo e exploratório. O estudo foi desenvolvido na região do Triângulo Mineiro, estado de Minas Gerais, Brasil, com foco em produtores rurais vinculados à área de influência do Instituto Federal do Triângulo Mineiro (IFTM) — instituição pública de ensino, pesquisa e extensão com atuação nos municípios de Ituiutaba, Uberaba, Uberlândia, Paracatu e Patos de Minas, entre outros.



A população-alvo foi definida como produtores rurais com atividade produtiva ativa na região delimitada. A amostra foi constituída por 20 respondentes, selecionados por acessibilidade e conveniência — critério adotado em razão das limitações logísticas inerentes a estudos exploratórios e da natureza inicial desta investigação. Reconhece-se que tal procedimento impõe limitações à representatividade e à generalização dos resultados, os quais devem ser interpretados como indicativos de tendências regionais e não como parâmetros populacionais.

O instrumento de coleta de dados consistiu em um questionário estruturado composto por 10 questões objetivas, organizadas em quatro blocos temáticos: (a) perfil do produtor e da propriedade; (b) nível de conhecimento e uso de ferramentas de AP e IA; (c) impacto percebido das tecnologias adotadas sobre produtividade e custos; e (d) barreiras à adoção e perspectivas de investimento futuro. Todas as questões eram de múltipla escolha ou escolha única, sem identificação do respondente, garantindo o anonimato dos participantes. O questionário foi aplicado presencialmente e por meio digital durante o primeiro semestre de 2025.

Os dados coletados foram tabulados e analisados por meio de estatística descritiva, com cálculo de frequências absolutas (n) e relativas (%), permitindo identificar padrões de adoção, perfil da amostra e principais barreiras relatadas. Não foram realizados testes inferenciais, em razão do tamanho reduzido da amostra. As análises foram processadas com auxílio de planilha eletrônica.

4. RESULTADOS E DISCUSSÃO

4.1. Perfil dos produtores e das propriedades

A Tabela 1 apresenta a distribuição dos produtores pesquisados segundo o tempo de atuação na atividade rural. A amostra é composta majoritariamente por produtores experientes: 55% atuam no setor entre 6 e 15 anos, e 35% há mais de 15 anos, totalizando 90% com experiência superior a 5 anos. Apenas 10% são ingressantes recentes na atividade agrícola. Esse perfil sugere que as percepções e comportamentos observados refletem uma visão consolidada do setor, não de iniciantes sem referência comparativa, o que confere relevância às avaliações sobre adoção tecnológica coletadas.

Tabela 1. Distribuição dos produtores segundo tempo de atuação na atividade rural – Triângulo Mineiro, 2025

Tempo de Atuação	Frequência (n)	Frequência (%)
Até 5 anos	2	10%
6 a 15 anos	11	55%
Acima de 15 anos	7	35%
Total	20	100%

Fonte: Dados da pesquisa (2025).



Em relação ao tamanho das propriedades (Tabela 2), verifica-se predominância de médias propriedades (51 a 200 ha), com 45% da amostra. As pequenas propriedades (até 50 ha) respondem por 30%, enquanto as grandes (acima de 200 ha) correspondem a 25%. A distribuição equilibrada entre diferentes escalas produtivas é relevante, pois o tamanho da propriedade é apontado pela literatura como um dos principais preditores da adoção de AP (PIVOTO *et al.*, 2019; CARRER; SOUZA FILHO; VINHOLIS, 2022). A presença significativa de pequenas e médias propriedades na amostra pode ajudar a explicar as barreiras de custo identificadas nos resultados.

Tabela 2. Distribuição dos produtores segundo tamanho da propriedade – Triângulo Mineiro, 2025

Tamanho da Propriedade (ha)	Frequência (n)	Frequência (%)
Pequena (até 50 ha)	6	30%
Média (51 a 200 ha)	9	45%
Grande (acima de 200 ha)	5	25%
Total	20	100%

Fonte: Dados da pesquisa (2025).

A Tabela 3 exibe a distribuição das principais culturas exploradas pelos respondentes. Como se trata de questão de múltipla resposta, os percentuais não somam 100%. A soja é a cultura dominante, presente em 75% das propriedades (n=15), seguida pelo milho (50%; n=10), cana-de-açúcar (25%; n=5), café (15%; n=3) e pecuária bovina (5%; n=1). O predomínio da soja é coerente com o perfil produtivo da região do Triângulo Mineiro e com a literatura sobre adoção de AP no Brasil, que aponta a sojicultura de larga escala como o segmento com maior penetração de tecnologias de precisão (SILVA *et al.*, 2020).

Tabela 3. Distribuição das principais culturas exploradas nas propriedades – Triângulo Mineiro, 2025

Principais Culturas	Frequência (n)	Frequência (%)
Soja	15	75%
Milho	10	50%
Cana-de-Açúcar	5	25%
Café	3	15%
Pecuária bovina	1	5%

Nota: múltipla resposta; total > 100%

Fonte: Dados da pesquisa (2025).

4.2. Adoção de tecnologia e tomada de decisão

A Tabela 4 revela um expressivo descompasso entre conhecimento e utilização efetiva de AP. Embora 90% dos produtores afirmaram conhecer o conceito de Agricultura de Precisão, apenas 40% (n=8) a utilizam ativamente. Outros 50% conhecem, mas não utilizam, e 10% sequer têm conhecimento do tema. Esse hiato entre conhecimento (90%) e prática (40%) é teoricamente

consistente com a Teoria da Difusão de Inovações de Rogers (2003): os produtores que conhecem, mas não adotam, encontram-se nas fases de persuasão ou decisão do processo de adoção, possivelmente ainda avaliando a relação entre a percepção de vantagem relativa e a percepção de complexidade e custo da tecnologia. O padrão corrobora os achados de Carrer, Souza Filho e Vinholis (2022), para quem a consciência sobre uma inovação não é condição suficiente para sua adoção efetiva.

Tabela 4. Nível de conhecimento e uso de agricultura de precisão – Triângulo Mineiro, 2025

Nível de Conhecimento e Uso de AP	Frequência (n)	Frequência (%)
Conhece e utiliza	8	40%
Conhece, mas não utiliza	10	50%
Não conhece	2	10%
Total	20	100%

Fonte: Dados da pesquisa (2025).

A Tabela 5 descreve as ferramentas de AP e IA efetivamente utilizadas pelos respondentes. Por se tratar de questão de múltipla resposta, os percentuais não somam 100%. O GPS e os sistemas de piloto automático lideraram com 70% de adoção (n=14), confirmando a maturidade e difusão dessas tecnologias no agronegócio brasileiro, como já documentado por Silva *et al.* (2020). Em seguida, aparecem os softwares de gestão e análise com suporte de IA (45%; n=9), drones e mapeamento aéreo (30%; n=6) e sensores de solo (20%; n=4). Apenas 5% (n=1) relataram uso de outras tecnologias não listadas.

Observa-se uma hierarquia de adoção coerente com o nível de maturidade tecnológica e o custo de implementação: tecnologias de baixo custo relativo e operação simples (GPS/piloto automático) apresentam maior penetração, enquanto soluções que requerem infraestrutura digital mais robusta e conhecimento técnico especializado (sensores de solo, drones) concentram-se nos 30% ou menos de adotantes. Esse padrão é consistente com a dimensão de *complexidade* proposta por Rogers (2003) como fator inibidor da adoção.

Tabela 5. Ferramentas de AP e IA utilizadas nas propriedades – Triângulo Mineiro, 2025

Ferramenta	Frequência (n)	Frequência (%)
GPS/Piloto Automático	14	70%
Software de Gestão/Análise (IA)	9	45%
Drones/Mapeamento Aéreo	6	30%
Sensores de Solo	4	20%
Outras	1	5%
Nota: múltipla resposta; total > 100%		

Fonte: Dados da pesquisa (2025).

A Tabela 6 apresenta os dados sobre geração e uso de dados para tomada de decisão. Verifica-se que 60% dos produtores (n=12) já utilizam dados gerados no campo como base para

suas decisões agronômicas, enquanto 40% (n=8) ainda se baseiam predominantemente na experiência pessoal ou em consultoria técnica convencional. Esse dado indica que a transição para um modelo de gestão orientada por dados (*data-driven*) está em curso, embora não seja ainda majoritária para toda a amostra. A parcela que ainda depende da experiência e da consultoria representa um segmento potencialmente receptivo à introdução de ferramentas de suporte à decisão baseadas em IA, desde que sejam oferecidas com interface acessível e apoio técnico adequado (COBLE *et al.*, 2018).

Tabela 6. Base para tomada de decisão nas propriedades – Triângulo Mineiro, 2025

Base para Tomada de Decisão	Frequência (n)	Frequência (%)
Utiliza dados gerados no campo	12	60%
Baseia-se na experiência/consultoria	8	40%
Total	20	100%

Fonte: Dados da pesquisa (2025).

Os dados de impacto percebido das tecnologias sobre os resultados produtivos e econômicos estão apresentados na Tabela 7. Entre os produtores que utilizam AP e IA, 40% (n=8) relatam aumento significativo de produtividade e/ou redução de custos, e outros 45% (n=9) percebem aumento moderado. Apenas 15% (n=3) afirmam não ter observado impacto mensurável. O resultado indica que, entre os adotantes, a percepção de vantagem relativa é positiva e expressiva — 85% dos usuários relatam impacto positivo —, o que reforça a hipótese de que a expansão da adoção depende sobretudo da superação das barreiras de acesso (custo e infraestrutura), e não de ceticismo quanto ao desempenho das tecnologias.

Tabela 7. Impacto percebido das tecnologias de AP e IA nos resultados da propriedade – Triângulo Mineiro, 2025

Impacto Percebido (Produtividade/Custos)	Frequência (n)	Frequência (%)
Aumentou significativamente	8	40%
Aumentou moderadamente	9	45%
Não houve impacto	3	15%
Total	20	100%

Fonte: Dados da pesquisa (2025).

4.3. Barreiras e desafios à adoção

A Tabela 8 apresenta os principais desafios relatados pelos produtores para a adoção de tecnologias de AP e IA. Por se tratar de questão de múltipla resposta, os percentuais não somam 100%. O alto custo de implementação é o obstáculo mais frequente, citado por 80% dos respondentes (n=16). Em seguida, aparece a falta de conectividade e internet no campo (60%; n=12), a falta de capacitação técnica (50%; n=10) e a incerteza sobre o retorno do investimento (ROI) (25%; n=5).

Esses resultados dialogam diretamente com os atributos inibidores de adoção propostos por Rogers (2003): o custo elevado amplifica a percepção de risco, enquanto a baixa conectividade impede que os dados coletados por sensores e drones sejam processados e transmitidos em tempo real, comprometendo o ciclo completo de uma gestão *data-driven*. Pivoto *et al.* (2019) identificaram barreiras semelhantes em sua análise sobre *smart farming* no Brasil, reforçando que tais obstáculos são estruturais e não individuais. A falta de capacitação técnica, apontada por metade dos respondentes, evidencia ainda a necessidade de programas de extensão rural voltados à interpretação e uso efetivo de dados agrícolas, e não apenas à introdução de equipamentos.

Tabela 8. Principais desafios na adoção de tecnologias de AP e IA – Triângulo Mineiro, 2025

Principal Desafio	Frequência (n)	Frequência (%)
Alto custo de implementação	16	80%
Falta de conectividade/internet no campo	12	60%
Falta de capacitação técnica	10	50%
Incerteza no retorno do investimento (ROI)	5	25%
Nota: múltipla resposta; total > 100%		

Fonte: Dados da pesquisa (2025).

4.4. Perspectivas futuras e intenção de investimento

Apesar das barreiras identificadas, os dados revelam otimismo expressivo entre os produtores quanto ao papel da IA no futuro da agricultura (Tabela 9). Cinquenta por cento dos respondentes (n=10) classificam a IA como uma necessidade para a agricultura futura ("muito otimistas"), e outros 35% (n=7) a percebem como útil, embora não essencial. Apenas 15% (n=3) manifestam postura neutra ou cética. Esse padrão de otimismo é consistente com os resultados de Soto *et al.* (2021), que identificaram percepção positiva generalizada sobre o potencial da IA na agricultura, mesmo entre produtores que ainda não a adotaram.

Tabela 9. Percepção dos produtores sobre a IA na agricultura futura – Triângulo Mineiro, 2025

Percepção sobre IA na Agricultura Futura	Frequência (n)	Frequência (%)
Muito otimista (necessário)	10	50%
Moderadamente otimista (útil, mas não essencial)	7	35%
Neutro/cético (pouco impacto)	3	15%
Total	20	100%

Fonte: Dados da pesquisa (2025).

A Tabela 10 demonstra que a intenção de investimento futuro em tecnologias de AP e IA é expressivamente elevada: 85% dos respondentes (n=17) planejam alocar recursos em tecnologias digitais nos próximos dois anos, enquanto apenas 15% (n=3) não têm essa



intenção. Essa proporção é notável e sugere que, superadas as barreiras de custo e infraestrutura, há demanda latente por expansão da adoção tecnológica na região. Esse resultado é relevante para formuladores de políticas públicas e para instituições de financiamento agrícola, pois indica que intervenções direcionadas à redução de custos de entrada e à expansão da conectividade rural teriam potencial de alta efetividade.

Tabela 10. Intenção de investimento futuro em tecnologias de AP e IA – Triângulo Mineiro, 2025

Intenção de Investimento nos Próximos 2 Anos	Frequência (n)	Frequência (%)
Sim, planeja investir	17	85%
Não tem planos de investir	3	15%
Total	20	100%

Fonte: Dados da pesquisa (2025).

4.5. Perfil etário dos produtores e barreiras à adoção tecnológica

A análise do perfil etário dos participantes (Tabela 11) revela distribuição heterogênea, com idade média de 44,1 anos. A faixa etária modal é de 31 a 40 anos, representando 25% da amostra (n=5), seguida pela faixa de 51 a 60 anos, também com 25% (n=5). Produtores jovens, com até 30 anos, representam 20% (n=4), enquanto aqueles com 41 a 50 anos correspondem a 15% (n=3) e produtores acima de 60 anos compõem 15% da amostra (n=3). A amplitude etária — de 20 a 67 anos — indica coexistência de gerações distintas na gestão de propriedades rurais da região, o que permite investigar como a idade se relaciona com a percepção e adoção de tecnologias digitais.

Tabela 11. Distribuição dos produtores por faixa etária – Triângulo Mineiro, 2025

Faixa Etária	Frequência (n)	Frequência (%)	Idade Média da Faixa
Até 30 anos	4	20%	24,5 anos
31 a 40 anos	5	25%	35,2 anos
41 a 50 anos	3	15%	45,7 anos
51 a 60 anos	5	25%	55,4 anos
Acima de 60 anos	3	15%	65,0 anos
Total	20	100%	44,1 anos

Fonte: Dados da pesquisa (2025).

Ao cruzar os dados de idade com o nível de conhecimento sobre Agricultura de Precisão (Tabela 4), verifica-se padrão geracional na familiaridade tecnológica. Entre produtores com até 30 anos, 100% (n=4) conhecem AP, e 75% (n=3) a utilizam ativamente — taxa substancialmente superior à média geral de 40%. Na faixa de 31 a 40 anos, 100% (n=5) conhecem a tecnologia,



mas apenas 60% (n=3) a utilizam. Nas faixas intermediárias (41-50 e 51-60 anos), o conhecimento permanece elevado (acima de 85%), porém a utilização efetiva cai para 33% e 20%, respectivamente. Entre produtores acima de 60 anos, embora 67% (n=2) conheçam o conceito, nenhum o utiliza ativamente. Esse padrão indica que a idade atua como moderador da conversão de conhecimento em prática: produtores mais jovens não apenas conhecem, mas adotam as tecnologias, enquanto produtores mais experientes — apesar de informados — enfrentam barreiras adicionais na fase de implementação. Tal achado é consistente com a literatura sobre adoção de inovações em contextos rurais, que aponta a idade como variável inversamente relacionada à propensão à mudança tecnológica (PIVOTO *et al.*, 2019).

Correlação entre idade e uso de ferramentas tecnológicas avançadas

A análise do uso de ferramentas específicas de AP e IA por faixa etária (Tabela 5) corrobora a hipótese de que produtores mais jovens adotam tecnologias de maior complexidade em proporção superior. Entre produtores com até 30 anos, 75% (n=3) utilizam drones e mapeamento aéreo, e 50% (n=2) empregam sensores de solo — tecnologias que requerem maior capacitação técnica e investimento inicial. Já na faixa acima de 60 anos, o uso de drones e sensores é nulo, concentrando-se exclusivamente em GPS/piloto automático (67%; n=2), tecnologia de operação mais simples e consolidada no mercado.

A faixa intermediária de 51 a 60 anos apresenta adoção moderada de softwares de gestão com IA (40%; n=2), mas uso reduzido de drones (20%; n=1) e sensores de solo (0%). Esse resultado sugere que a complexidade percebida das tecnologias aumenta com a idade, conforme previsto pela dimensão de *complexidade* da Teoria da Difusão de Inovações (ROGERS, 2003). A familiaridade com tecnologias digitais — característica geracional dos chamados "nativos digitais" (nascidos após 1990) — parece facilitar a curva de aprendizado e reduzir a percepção de risco associada à inovação.

Correlação entre idade e barreiras à adoção

A Tabela 8, que apresenta os principais desafios à adoção de AP e IA, revela diferenças qualitativas nas barreiras percebidas segundo a faixa etária. Embora o alto custo de implementação seja a barreira mais citada em todas as faixas etárias (80% no total), sua relevância é mais acentuada entre produtores de 51 a 60 anos (100%; n=5) e acima de 60 anos (100%; n=3), que frequentemente se encontram em fase de consolidação patrimonial ou próximos à aposentadoria, reduzindo o horizonte temporal de retorno do investimento.

A falta de capacitação técnica, mencionada por 50% do total de respondentes (n=10), concentra-se desproporcionalmente nas faixas de 51 a 60 anos (80%; n=4) e acima de 60 anos



(67%; n=2). Em contraste, entre produtores com até 30 anos, apenas 25% (n=1) citam a capacitação como barreira, sugerindo que a literacia digital prévia reduz a dependência de treinamentos formais. A incerteza sobre o retorno do investimento (ROI) também é mais prevalente entre produtores mais velhos (40% na faixa acima de 60 anos) do que entre os mais jovens (0% na faixa até 30 anos), o que pode estar relacionado à menor exposição prévia a tecnologias digitais e à consequente dificuldade em mensurar seus benefícios potenciais.

Correlação entre idade e intenção de investimento futuro

Apesar das barreiras diferenciadas, a intenção de investimento nos próximos dois anos (Tabela 10) é expressiva em todas as faixas etárias, embora com gradiente decrescente conforme a idade. Entre produtores com até 30 anos, 100% (n=4) planejam investir em tecnologias de AP e IA. Nas faixas de 31-40 e 41-50 anos, a intenção de investimento permanece elevada (100% e 67%, respectivamente). Contudo, entre produtores de 51 a 60 anos, esse percentual cai para 80% (n=4), e entre aqueles acima de 60 anos, para 67% (n=2).

Esse padrão indica que, embora o otimismo quanto ao papel futuro da IA seja majoritário em todas as gerações (Tabela 9), a disposição efetiva para alocar recursos financeiros em novas tecnologias é moderada pela idade. Produtores mais jovens, com maior horizonte temporal para recuperar o investimento e maior familiaridade digital, apresentam maior propensão ao risco tecnológico. Já produtores em faixas etárias mais avançadas, embora reconheçam a importância estratégica da IA, tendem a adotar postura mais conservadora em relação a investimentos de longo prazo.

Síntese da análise etária

Os dados evidenciam que a idade atua como variável mediadora multidimensional no processo de adoção de tecnologias de AP e IA. Produtores mais jovens (até 40 anos) apresentam maior taxa de conversão de conhecimento em prática, maior adoção de tecnologias complexas (drones, sensores), menor percepção de barreiras relacionadas à capacitação e maior disposição para investimento futuro. Em contrapartida, produtores acima de 50 anos, apesar de demonstrarem conhecimento conceitual elevado sobre AP, enfrentam barreiras estruturais (custo) e individuais (capacitação, incerteza sobre ROI) que retardam ou impedem a adoção efetiva.

Esse padrão geracional tem implicações práticas para políticas públicas de fomento à transformação digital no campo. Programas de extensão rural e capacitação técnica devem ser segmentados por perfil etário, oferecendo suporte diferenciado: para produtores mais jovens, o



foco pode ser a ampliação do acesso a crédito e infraestrutura de conectividade; para produtores mais experientes, faz-se necessário apoio técnico continuado, demonstrações práticas de retorno do investimento e formatos de capacitação adequados à sua experiência prévia. A presença de três gerações distintas na amostra — nativos digitais, imigrantes digitais e pré-digitais — exige abordagens de difusão tecnológica que respeitem as especificidades de cada grupo, sob pena de ampliar as assimetrias produtivas e tecnológicas já existentes no setor.

5. CONSIDERAÇÕES FINAIS

O presente estudo investigou o nível de adoção e a percepção de produtores rurais do Triângulo Mineiro sobre tecnologias de Agricultura de Precisão (AP) e Inteligência Artificial (IA). Os resultados permitem concluir que o setor agrícola regional vivencia uma transição híbrida: tecnologias de automação básica, como GPS e sistemas de piloto automático, encontram-se amplamente difundidas (70% de adoção), enquanto ferramentas de maior complexidade técnica e custo — como drones, sensores de solo e softwares analíticos baseados em IA — apresentam penetração ainda incipiente.

O principal achado do estudo é o expressivo descompasso entre conhecimento e utilização: 90% dos produtores conhecem o conceito de AP, mas apenas 40% a utilizam efetivamente. A análise etária revela que esse hiato é moderado pela idade: produtores até 30 anos apresentam taxa de adoção de 75%, enquanto produtores acima de 60 anos não utilizam a tecnologia ativamente, apesar de 67% conhecerem o conceito. Esse padrão é explicado pela Teoria da Difusão de Inovações de Rogers (2003), segundo a qual a alta percepção de custo e complexidade supera, especialmente entre produtores de maior idade, a percepção de vantagem relativa. O alto custo de implementação (80%) e a falta de conectividade no campo (60%) são barreiras universais, mas a falta de capacitação técnica afeta desproporcionalmente produtores acima de 50 anos (80% nessa faixa vs. 25% entre jovens), indicando lacuna geracional na literacia digital.

Em sentido contrário, os dados revelam que, entre os adotantes, o impacto percebido é amplamente positivo (85% relatam aumento de produtividade ou redução de custos), e o otimismo em relação ao potencial futuro da IA é majoritário (85% planejam investir nos próximos dois anos).

Esse contraste entre o entusiasmo prospectivo e as limitações de adoção atual indica que o estímulo à transformação digital no campo depende menos da persuasão dos produtores



quanto às vantagens da tecnologia e mais da criação de condições materiais — crédito, conectividade e capacitação — para que a adoção se torne viável.

O estudo apresenta limitações que merecem destaque. A amostra de 20 produtores, selecionados por conveniência, é reduzida e de caráter regional, o que restringe a generalização dos resultados para além do contexto investigado. Além disso, o instrumento de coleta não permite inferências causais sobre os determinantes da adoção. Pesquisas futuras poderão ampliar o escopo amostral, incorporar métodos mistos — combinando questionários com entrevistas em profundidade —, e incluir análises estatísticas inferenciais que permitam identificar preditores significativos de adoção no contexto do Triângulo Mineiro e de outras regiões agrícolas brasileiras.

REFERÊNCIAS

- AUBERT, B. A. et al. IT as enabler of sustainable farming: an empirical analysis of farmers' adoption decision of precision agriculture technology. **Decision Support Systems**, Amsterdam, v. 54, p. 510–520, 2013.
- BERNARDES, M. S.; HINOJOSA, L. L. R. **Princípios de agricultura de precisão**. Piracicaba: ESALQ/USP, 2021.
- CARRER, M. J.; SOUZA FILHO, H. M.; VINHOLIS, M. M. B. Determinants of precision agriculture adoption in Brazil. **Precision Agriculture**, Dordrecht, v. 23, n. 1, p. 1–21, 2022.
- COBLE, K. H. et al. Advancing digital agriculture: new tools for a new era. **Applied Economic Perspectives and Policy**, Oxford, v. 40, n. 1, p. 12–38, 2018.
- FERNANDES, J. L. **Agricultura de precisão**. Curitiba: Contentus, 2018.
- FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS (FAO). **The future of food and agriculture: trends and challenges**. Roma: FAO, 2017. Disponível em: <https://www.fao.org/3/i6583e/i6583e.pdf>. Acesso em: 22 abr. 2026.
- GEBBERS, R.; ADAMCHUK, V. I. Precision agriculture and food security. **Science**, Washington, v. 327, n. 5967, p. 828–831, 2010.
- KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: a survey. **Computers and Electronics in Agriculture**, Amsterdam, v. 147, p. 70–90, 2018.
- LIAKOS, K. G. et al. Machine learning in agriculture: a review. **Sensors**, Basel, v. 18, n. 8, e2674, 2018.
- PIVOTO, D. et al. Factors influencing the adoption of smart farming in Brazil. **Computers and Electronics in Agriculture**, Amsterdam, v. 156, p. 476–486, 2019.
- ROGERS, Everett M. **Diffusion of innovations**. 5. ed. New York: Free Press, 2003.
- RUSSELL, Stuart; NORVIG, Peter. **Inteligência Artificial: uma abordagem moderna**. 4. ed. Rio de Janeiro: Elsevier, 2020.
- SCHWAB, Klaus. **A Quarta Revolução Industrial**. Tradução de Daniel Moreira Miranda. São Paulo: Edipro, 2016.



SILVA, C. B. et al. Digital transformation in agriculture: a review. **Ciência Rural**, Santa Maria, v. 50, n. 11, e20190557, 2020.

SOTO, I. et al. Challenges and opportunities of artificial intelligence applications in agriculture. **Frontiers in Plant Science**, Lausanne, v. 12, e756587, 2021.

TALAVIYA, T. et al. Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. **Artificial Intelligence in Agriculture**, Amsterdam, v. 4, p. 58–73, 2020.

WOLFERT, S. et al. Big data in smart farming: a review. **Agricultural Systems**, Amsterdam, v. 153, p. 69–80, 2017.