DETERMINANTES DA ADOÇÃO DE TECNOLOGIAS DE AGRICULTURA DIGITAL POR PRODUTORES DE SOJA NO ESTADO DE SÃO PAULO

DETERMINANTS OF ADOPTION OF DIGITAL AGRICULTURE TECHNOLOGIES BY SOYBEAN FARMERS IN SAO PAULO STATE

Autor(es): Rodrigo Damasceno[1]; Marcelo José Carrer[2]; Larissa Gui Pagliuca[1]; Marcela de Mello Brandão Vinholis[3]
Filiação: 1. Discente no Programa de Pós Graduação em Engenharia de Produção na Universidade Federal de São Carlos (PPGEP/DEP/UFSCar); 2. Docente no Departamento de Engenharia de Produção da Universidade Federal de São Carlos (DEP/UFSCar); 3. Pesquisadora da Embrapa Pecuária Sudeste – São Carlos/SP.
E-mail: damascenorodrigo1993@gmail.com; marcelocarrer@dep.ufscar.br; larigpagliuca@gmail.com; marcela.vinholis@embrapa.br;

Grupo de Trabalho (GT): <<12. Impactos socioambientais das novas tecnologias no agronegócio >>

Resumo
Este artigo analisa os determinantes da adoção das tecnologias de agricultura digital por produtores de soja no estado de São Paulo, Brasil. Para tal, foram utilizados dados primários coletados junto a 144 sojicultores referentes à safra 2023/2024. As tecnologias examinadas incluem piloto automático, amostragem georreferenciada de solo, aplicação de insumos a taxa variável, plantio a taxa variável, monitor de produtividade, mapa de produtividade e softwares de gestão agrícola. Os resultados indicam que a área cultivada com soja, a experiência dos produtores, o uso de consultoria privada e o nível de escolaridade influenciam positivamente a adoção de pelo menos uma das tecnologias estudadas. Por outro lado, a percepção dos custos associadas às tecnologias afeta negativamente sua adoção. Tais achados podem subsidiar a formulação de políticas públicas e orientar estratégias de agentes de extensão rural, consultores e desenvolvedores de tecnologias, visando aprimorar o conhecimento e a difusão de informações relacionadas às tecnologias de agricultura digital para os diferentes elos da cadeia de produção, em especial os produtores rurais.
Palavras-chave: Agricultura 4.0, agricultura de precisão, adoção de tecnologia, regressão logística, soja.

Abstract
This paper analyzes the determinants of adoption of digital agriculture technologies (DAT) by soybean farmers in São Paulo state, Brazil. The study uses primary data from 144 farmers for the 2023/2024 crop year. The analyzed DATs include autopilot, grid soil sampling, variable rate application, variable rate seeding, yield monitor, yield maps and agricultural management software. The findings show that soybean area, experience, private consultancy, and education positively influence adoption of at least one DAT, while the perception of technology costs negatively affects the adoption of DAT. These findings can guide public policy design and help agricultural extension agents, consultants, and technology developers in their strategies for better knowledge and diffusion of digital agriculture technologies information specially for farmers.
Key words*: Agriculture 4.0, precision agriculture, technology adoption; logit regression; soybean*

1. Introdução

A adoção e disseminação de tecnologias digitais tem se intensificado nas atividades agrícolas em diversos países (Barnes et al., 2019; Klerkx et al., 2019; Shang et al., 2021). As tecnologias de agricultura digital consistem na aplicação de diversas ferramentas, estratégias de gestão e soluções fundamentadas em dados com o objetivo de aprimorar a eficiência, maximizar a produtividade e promover a sustentabilidade nas práticas agrícolas (Balasundram et al., 2023). Essas tecnologias abrangem uma ampla gama de ferramentas, desde aplicativos móveis e softwares para suporte à decisão estratégica, até piloto automático, aplicação e plantio a taxa

variada, sistemas de sensoriamento remoto para coleta de dados, drones e robôs avançados para automatizar processos de produção (Balafoutis et al., 2017; Shang et al., 2021; Moreno et al., 2024).

Estudos em nível de fazenda sobre adoção de tecnologia agrícola digital começaram a surgir nos últimos anos (Carrer et al., 2017; Caffaro e Cavallo, 2019; Drewry et al. 2019; Pivoto et al. 2019; Michels et al. 2020, Mozambani et al., 2023; Mendes et al., 2023). Revisões de literatura também foram conduzidas para identificar estudos relacionados aos determinantes da adoção de tecnologias digitais na China (Cui & Wang, 2023), Estados Unidos (Yeo & Keske, 2024) e Europa (Gabriel & Gandorfer, 2022).

No Brasil, há estudos empíricos específicos sobre a adoção de tecnologias digitais na cana-de-açúcar (Mozambani et al., 2023), citros (Carrer et al., 2017), bovinos de corte (Mendes et al., 2023) e produção de grãos (Pivoto et al., 2019). Em geral, os principais determinantes que afetam a adoção de tecnologias digitais estão relacionados à estrutura da fazenda e a fatores socioeconômicos, institucionais e comportamentais.

No entanto, a literatura carece de uma avaliação empírica da adoção de tecnologias digitais por produtores de soja no Brasil, provavelmente devido à dificuldade em encontrar bancos de dados consolidados com microdados primários, como o Agricultural Resource Management Survey (ARMS)/USDA (McFadden et al., 2023).

Este artigo tem como objetivo identificar os fatores que determinam as decisões dos produtores de soja quanto à adoção de tecnologias digitais. Especificamente, avaliar os determinantes da adoção das seguintes tecnologias digitais: piloto automático, amostragem georreferenciada de solo, mapa de produtividade, monitor de produtividade, plantio a taxa variável, aplicação de fertilizante a taxa variável e software de gestão integrada. Um questionário estruturado foi aplicado a 144 produtores de soja do estado de São Paulo para coletar microdados primários do ano-safra 2023/24. O modelo econométrico de escolha qualitativa foi utilizado para estimar os fatores que afetam a probabilidade de adoção no uso dessas tecnologias de agricultura digital.

O artigo está estruturado da seguinte forma: a seção 2 oferece uma revisão da literatura referente à adoção de tecnologias digitais na agricultura; a Seção 3 descreve a metodologia empregada na condução da análise empírica; a Seção 4 apresenta e discute os resultados obtidos; a seção 5 contém as considerações finais.

2. Revisão de literatura

Esta seção apresenta uma breve revisão de literatura sobre fatores que influenciam a adoção de tecnologia na agricultura, com foco especial em estudos empíricos sobre a adoção de tecnologias digitais na produção de grãos.

A adoção de tecnologias digitais para otimizar aplicações de insumos no processo de produção, como sistemas de piloto automático para tratores e colheitadeiras, amostragem georreferenciada de solo e aplicação de insumos de taxa variável, também foi investigada em estudos empíricos (Barnes et al., 2019; Carrer et al., 2022; Blasch et al., 2022; Mozambani et al., 2023). A incorporação dessas tecnologias na produção foi motivada pela exigência de adaptação dos sistemas agrícolas à crescente demanda por alimentos, visando a otimização dos no uso de insumos como terra, água e produtos químicos, ao mesmo tempo em que se promove a preservação ambiental e a segurança alimentar (Blasch et al., 2022; Carrer et al., 2022).

Em relação aos artigos empíricos relacionados a adoção de tecnologias de agricultura digital na produção de grãos, foram utilizados dados primários ao nível de fazenda (microdados) e aplicaram modelos de regressão de escolha qualitativa, como logit (Larson et al., 2008) ou probit (Walton et al., 2010), modelos de regressão de variáveis censuradas, como o tobit

(Watcharaanantapong et al., 2014), modelos de dados de contagem como a distribuição Poisson (Barnes et al., 2019) ou modelos de classes latentes (Blasch et al., 2022).

Dentre as tecnologias de agricultura digital analisadas estão a amostragem de solo (Walton et al., 2010; Watcharaanantapong et al., 2014), piloto automático (D'Antoni et al., 2012) aplicação a taxa variada (Torbett et al., 2007) e de Sistemas de Informação de Gestão Agrícola (Carrer et al., 2017).

A Tabela 1 apresenta um resumo com os principais artigos relacionados aos determinantes da adoção de tecnologia de agricultura digital, ressaltando as tecnologias analisadas por cada artigo, bem como os determinantes, a amostra e a metodologia utilizada.

Tabela 1. Resumo da revisão da literatura sobre os determinantes da adoção de tecnologias de agricultura digital

Referência	Tecnologias de agricultura digital	Determinantes da adoção	Amostra	Métodos
Barnes et al., 2019	Sistemas de orientação de máquinas; Aplicação de nitrogênio e pesticida de taxa variável; Agricultura de tráfego controlado; Irrigação a taxa variada; Plantio a taxa variável;	nível de escolaridade (+) treinamento de pessoal (+), contratação de consultores (+)	971 agricultores europeus	Modelagem de regressão de contagem
D'Antoni et al., 2012	Piloto automático (Sistema de orientação GPS)	percepção dos agricultores sobre a importância das tecnologias agrícolas de precisão (+), percepção de potenciais economias de custos de insumos (+), área da fazenda (+), idade (-), uso de computadores para gestão (+)	469 produtores de algodão nos EUA (2009 Southern Cotton Precision Farming Survey)	Modelo logit multinomial
Larson et al., 2008	sensoriamento remoto para aplicação de insumos a taxa variável: aplicação de reguladores de crescimento de plantas	idade (-), nível de escolaridade (+), área de algodão irrigado (+), uso de computadores no campo (+)	941 produtores de algodão em 11 estados do sul dos EUA	Modelo logit binomial
Paxton et al., 2011	monitor de produtividade, amostragem de solo, imagens de satélite, mapas de levantamento de solo, dispositivos portáteis de GPS	idade do produtor (-), idade do operador (-), educação formal do operador (+), uso do computador para gestão (+), localização da fazenda (+)	892 produtores de algodão do sudeste dos EUA	Modelos de Poisson e binomial negativo

Torbett et al., 2007	aplicação de taxa variável de nitrogênio, potássio, fósforo, cal, sementes, fungicida, herbicida, inseticida e irrigação	idade (+), percepções da importância das tecnologias de agricultura de precisão (+); posse da terra (+); uso de computadores para gestão (+)	1131 produtores de algodão em 6 estados dos EUA	Modelo de logit ordenado
Walton et al., 2010	Amostragem de solo	idade (-), área plantada com algodão (+), posse da terra (+), outras culturas plantadas (+), uso de computador para gestão (+)	827 produtores de algodão em 11 estados dos EUA	Regressões Probit
Watcharaanantapong et al., 2014	amostragem de solo, monitor de produtividade e sensoriamento remoto	Posse da terra (+), idade do produtor (-), informações obtidas por consultores (+),	1088 produtores de algodão em 12 estados dos EUA)	Modelo Tobit trivariado (regressão multivariada)
Blasch et al., 2022	Tecnologias de agricultura de precisão	Influência social (+); consciência ambiental (+)	250 agricultores na Itália Central	modelos logit multinomial e logit de classes latentes

Nota: Os sinais mostram a direção do efeito de cada variável na probabilidade de adoção.

3. Método

O modelo econométrico usado para análise empírica é baseado na estrutura de utilidade aleatória proposta em McFadden (1974). Esta estrutura adota a noção de que um indivíduo deriva utilidade ao escolher uma alternativa. As utilidades são assumidas como uma função de um conjunto de variáveis explicativas X, que descrevem o tomador de decisão n e a alternativa i. Portanto, as preferências individuais são avaliadas com base em escolhas observadas e uma função de utilidade aleatória que geralmente é especificada como uma combinação de um componente determinístico e termo estocástico (Walker e Ben-Akiva, 2002; Blasch et al., 2022). A decisão de adotar uma nova tecnologia ocorre quando a utilidade esperada da adoção (Ua) excede a utilidade esperada da não adoção (Un), ou seja, Ua > Un (Carrer et al., 2017).

O modelo de regressão logística (logit), com variável dependente 0 (não adoção) ou 1 (adoção), foi aplicado para identificar os efeitos das variáveis explicativas (Xi) na probabilidade de adoção individual de sete tecnologias de agricultura digital.

Após obter informações sobre as escolhas dos agricultores de adoção de tecnologia digital, o comportamento padrão observado na adoção de uma tecnologia específica pode ser representado por uma variável dummy (yi), onde:

$yi = 1$ if $Ua > Un$

$yi = 0$ if not.

A probabilidade de adoção da tecnologia pode ser definida da seguinte forma:

$$P[y_i = 1\,] = P(e_i > -X_i\beta) = 1 - F(-X_i\beta) = F(X_i\beta) \quad (1)$$

Onde F é uma função de distribuição cumulativa e β são os parâmetros a serem estimados por meio de procedimentos de máxima verossimilhança. O modelo logit assume uma forma funcional logística e foi aplicado para investigar os fatores que afetam a probabilidade de decisões de adoção de tecnologia digital por produtores de soja. Em sua forma específica, o modelo logit pode ser expresso como (Greene, 2003):

$$P_i = P[y_i = 1] = \frac{e^{x_i\beta}}{1+e^{x_i\beta}} \quad (2)$$

3.1. Amostra

A versão final do questionário foi estruturada em sete partes, a partir da validação do questionário inicial com os produtores e agentes-chave na cadeia produtiva da soja como gestores de cooperativas, agentes de extensão, consultores e prestadores de serviços de tecnologia de agricultura de precisão.

Inclui informações sobre as características da fazenda (como distribuição do uso da terra, localização, tipo de solo, etc.), características da produção de soja no ano-safra 2023/2024 (quantidades e preços pagos por insumos como sementes, pesticidas, fertilizantes e corretivos, bem como dados sobre mão de obra e maquinário), características das estratégias de mercado (contratos de venda antecipado, acesso a crédito e seguro rural), uso de tecnologias digitais na produção de soja, características pessoais do tomador de decisão e uma seção sobre questões comportamentais e percepção do uso de tecnologias de agricultura digital pelos agricultores.

A coleta de dados foi realizada entre 27 de maio de 2024 e 24 de outubro de 2024 e foram entrevistados 201 produtores de soja e/ou pecuaristas. Entretanto, a amostra foi composta por 144 produtores de soja localizadas em 61 municípios do estado de São Paulo (Figura 1).

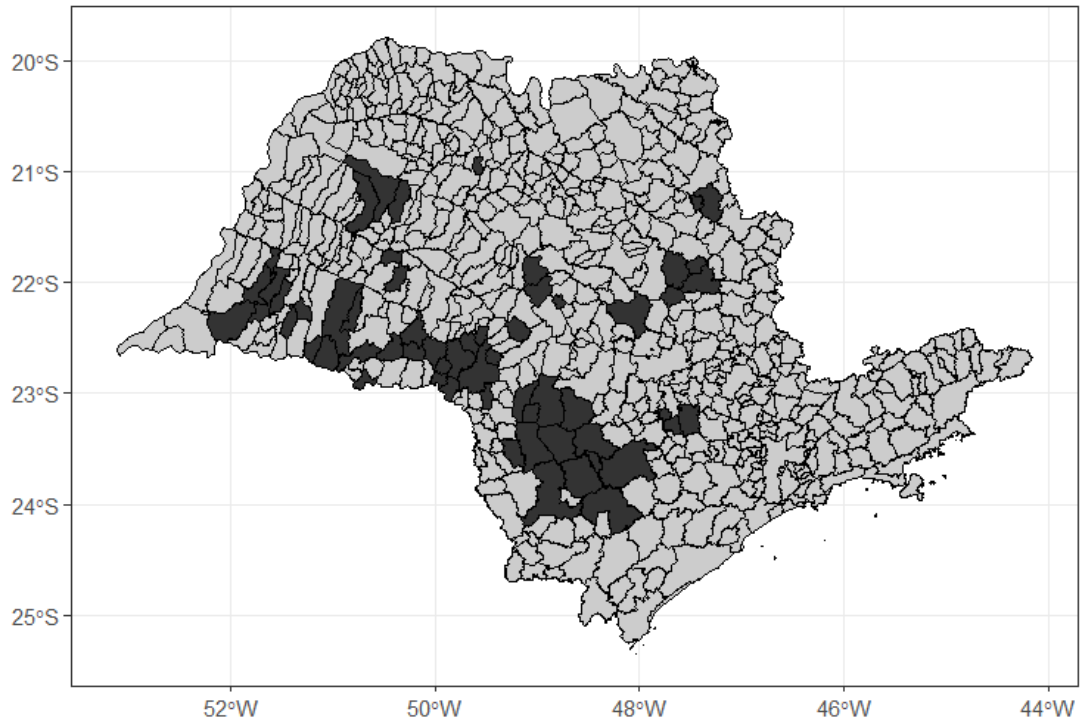


Figure 1. Distribuição dos municípios do estado de São Paulo representados na amostra de produtores de soja

3.2 Variáveis e hipóteses empíricas

Os fatores determinantes da adoção de tecnologias digitais foram agrupados em seis categorias, que serão descritas a seguir: (i) características dos agricultores; (ii) características comportamentais; (iii) percepções da tecnologia; (iv) características da gestão; (v) características da fazenda; (vi) fatores institucionais (Souza Filho et al., 2011; Balafoutis et al., 2017; Carrer et al., 2022; Mendes et al., 2023).

Em relação as características dos produtores, a experiência tem sido usada como um proxy para o conhecimento acumulado e as capacidades gerenciais de um agricultor (Feder et al., 1985; Souza Filho et al., 2021). Portanto, a hipótese a ser testada empiricamente é H1a: Quanto maior a experiência do agricultor, maior a probabilidade de adoção de tecnologias digitais.

A educação formal é outra variável relacionada ao capital humano que pode explicar a probabilidade de adoção de tecnologia digital (Feder et al., 1985). Agricultores com níveis mais altos de educação têm maior capacidade de entender as funcionalidades e gerenciar novas tecnologias (Carrer et al., 2017; Carrer et al., 2022). A segunda hipótese relacionada às características dos produtores é H1b: Agricultores com níveis mais altos de educação são mais propensos a adotar tecnologias digitais.

Ao analisar as características comportamentais, a "inovação" do agricultor se refere à disposição e capacidade dos agricultores de adotar novas tecnologias e práticas em suas atividades agrícolas. Ela abrange a abertura à mudança, experimentação e implementação de soluções inovadoras na gestão agrícola (Walder et al., 2019; Michels et al., 2020; Mendes et al., 2023).

A partir da seguinte afirmação "gosto de testar novas tecnologias na minha fazenda", foi construída uma variável de escala Likert de cinco pontos derivada do nível de concordância do produtor. Assim, a hipótese referente ao perfil inovador do produtor é H2a: Quanto mais propensos à inovação os agricultores forem, maior será a probabilidade de adotarem tecnologias digitais.

Outra variável comportamental incluída na análise foi a aversão ao risco, que se refere à tendência dos agricultores de preferir evitar incertezas e perdas potenciais em vez de assumir riscos que podem levar a ganhos maiores. Em outras palavras, os agricultores avessos ao risco são mais propensos a escolher opções que oferecem resultados mais previsíveis, mesmo que essas opções possam ter retornos potenciais menores (Carrer et al., 2017; Lien et al., 2023).

Uma variável de escala Likert de cinco pontos derivada do nível de concordância do produtor em relação a seguinte afirmação "quando se trata de negócios, prefiro a opção mais segura, mesmo sabendo que posso ganhar menos". Portanto, a seguinte hipótese é formulada H2b: Os agricultores mais avessos ao risco têm menor probabilidade de adotar tecnologias digitais.

As características de percepção dos produtores em relação as tecnologias digitais impactam significativamente a aceitação dos indivíduos e, consequentemente, a probabilidade de adoção (Dwivedi et al., 2019). No setor agrícola, alguns estudos mostraram que as percepções ex-ante dos agricultores sobre as características da tecnologia desempenharam um papel importante na explicação das decisões de adoção (Watcharaanantapong et al., 2014; Mozambani et al., 2023).

A variável em escala Likert de cinco pontos para captar a percepção do produtor em relação a percepção de custo foi derivada da seguinte afirmação: "as tecnologias digitais são muito caras para mim". Assim, a hipótese empírica a ser testada é H3: se o produtor percebe que a tecnologia é cara, a probabilidade de sua adoção diminui.

No que refere as características de gestão, o acesso à informação sobre o uso de novas tecnologias é essencial para incentivar a adoção por indivíduos. Na teoria clássica de difusão de inovações de Rogers (1962), a informação desempenha um papel crucial na disseminação de novas ideias entre agentes econômicos. A transferência de informações e a assistência fornecida por especialistas durante as visitas às fazendas desempenharam um papel importante em informar e ajudar os agricultores e seus funcionários sobre novas tecnologias (Souza Filho et al., 2011; Carrer et al., 2017; Barnes et al., 2019). Assim, a contratação de consultoria (assistência técnica) é a *proxy* considerada como acesso a informação e a hipótese a ser testada é H4: A contratação de serviços de consultoria especializada afeta positivamente a probabilidade de adoção de tecnologias digitais.

Em relação as características da propriedade rural, a escala de produção é amplamente utilizada como um fator que afeta a probabilidade de adoção de tecnologia digital (Barnes et al., 2019; Mozambani et al., 2023). A área é comumente usada como um proxy para a escala de produção (Larson et al., 2008; Watcharaanantapong et al., 2014; Addai et al., 2022; Khan et al., 2022; Mozambani et al., 2023;).

Portanto, a área plantada com soja na safra 2023/2024 foi utilizada como proxy para a escala de produção e a hipótese é H5a: O tamanho da fazenda tem um efeito positivo na adoção de tecnologias digitais pelos agricultores.

Outra característica da propriedade rural incorporada nas análises econométricas é a diversificação de culturas, que se refere a uma prática que envolve o cultivo de vários tipos de culturas dentro de uma área específica ou sistema agrícola para aumentar a sustentabilidade, aumentar a biodiversidade, minimizar a dependência de uma única cultura, reduzir o uso de insumos e conservar recursos para mitigar riscos associados a fatores ecológicos e ambientais (Hufnagel et al., 2020; Barman et al., 2022).

Portanto, a seguinte hipótese é proposta baseada no número total de culturas plantadas pelos produtores na safra2023/2024 H5b: Quanto maior a diversificação de culturas em uma fazenda, maior a probabilidade de adoção de tecnologia digital.

Em relação aos fatores institucionais, o acesso aos mercados financeiros tem sido essencial para a compra de novas tecnologias e insumos, especialmente no setor agrícola (Girma, 2022; Rayhan et al., 2023). A oferta de crédito rural subsidiado tem sido a principal política do governo federal brasileiro para acelerar a difusão de inovações na agricultura. Há evidências empíricas de que o acesso a essa política foi importante para determinar a adoção de tecnologias digitais (Carrer et al., 2020).

O acesso ao crédito foi medido como uma variável *dummy* que indica se os agricultores tiveram acesso ao crédito rural para a safra 2023/2024 e a hipótese a ser testada é que H6: O acesso ao crédito rural influencia positivamente a probabilidade de adoção de tecnologia digital.

Outro fator institucional é a organização dos produtores em cooperativas. As cooperativas agrícolas desempenham um papel crucial como instituições no setor agrícola, facilitando o acesso a recursos, informações e mercados para seus membros (Leite et al., 2021). De acordo com Mendes et al. (2023), as cooperativas ajudam na adoção de inovações tecnológicas, fornecendo um ambiente de apoio para experimentação e compartilhamento de conhecimento. Além disso, estudos mostraram que as cooperativas aumentam o poder de barganha dos agricultores com fornecedores de tecnologia e melhoram seu acesso a crédito e mercados de insumos (Holgado-Silva e Binotto, 2022).

A participação dos produtores em cooperativas foi medida como uma variável *dummy* que indica se o agricultor é membro de uma cooperativa e a hipótese a ser testada nos modelos econométricos é H7. Os agricultores que são membros de cooperativas têm maior probabilidade de adotar tecnologia digital.

A Tabela 2 apresenta a síntese das variáveis utilizadas nos modelos econométricos e suas estatísticas descritivas. São apresentadas as sete tecnologias de agricultura digital (variáveis dependentes) e as variáveis explicativas são categorizadas em seis grupos, conforme explicado anteriormente: (i) fatores pessoais: anos de experiência em cultivo de soja (EXPERIÊNCIA) e nível de educação (ESCOLARIDADE); (ii) fatores comportamentais: propensão a testar novas tecnologias (INOVADOR) e grau de aversão ao risco (RISCO); (iii) percepção das tecnologias: percepção dos altos custos de adoção de tecnologias digitais (CUSTO); (iv) fatores de gestão: uso de assistência técnica/consultoria privada (CONSULT); (v) fatores estruturais: área de soja (ÁREA) e índice de diversificação (DIVERSIF); (vi) fatores institucionais: acesso ao crédito rural (CRÉDITO) e participação em cooperativas de agronegócio (COOP).

Tabela 2. Descrição das variáveis e as respectivas estatísticas descritiva

Variável	Descrição	Média	Desvio padrão	Mínimo	Máximo
Variáveis explicativas					
EXPERIÊNCIA	Tempo de experiência na produção de soja (em anos)	19,58	12,31	1,0	55,0
ESCOLARIDADE	estudo formal do produtor (em anos)	14,27	3,83	3,0	22,0
RISCO	Variável de escala Likert de cinco pontos derivada do nível de concordância do agricultor com a seguinte afirmação "Quando se trata de negócios, prefiro a opção mais segura, mesmo sabendo que posso ganhar menos."	4,25	0,87	1,0	5,0
INOVADOR	Variável de escala Likert de cinco pontos derivada do nível de concordância do agricultor com a seguinte afirmação "Gosto de testar novas tecnologias na minha fazenda."	4,31	0,81	1,0	5,0
CUSTO	Variável de escala Likert de cinco pontos derivada do nível de concordância do agricultor com a seguinte afirmação "Tecnologias digitais são muito caras para mim."	3,38	1,00	1,0	5,0
CONSULT	Variável dummy com valor 1 se o agricultor contratou assistência técnica (consultoria privada) em 2023/2024, 0 caso contrário.	0,38	0,49	0,0	1,0
AREA	Área total de soja plantada na safra 2023/2024 (em hectares)	481,57	678,17	10,5	4912,0
DIVERSIF	Número de diferentes culturas plantadas em um ano-safra	4,13	1,50	2,0	8,0
CREDITO	Variável dummy com valor 1 se o agricultor acessou crédito rural para a safra 2023/2024 e 0 caso contrário	0,59	0,49	0,0	1,0
COOP	Variável dummy com valor 1 se o agricultor for membro de uma cooperativa agroindustrial e 0 caso contrário	0,85	0,35	0,0	1,0
Tecnologias de agricultura digital					

PILOTO	Variável dummy com valor 1 se o produtor adota piloto automático em pelo menos uma máquina e 0 caso contrário	0,56	0,50	0,0	1,0
SOLO	Variável dummy com valor 1 se o produtor adota amostragem georreferenciada de solo e 0 caso contrário	0,53	0,50	0,0	1,0
MONITOR	Variável dummy com valor 1 se o produtor adota monitor de produtividade em pelo menos uma máquina e 0 caso contrário	0,42	0,50	0,0	1,0
MAPA	Variável dummy com valor 1 se o produtor adota mapa de produtividade em pelo menos uma máquina e 0 caso contrário	0,26	0,44	0,0	1,0
PLANTIO	Variável dummy com valor 1 se o produtor adota plantio a taxa variada e 0 caso contrário	0,09	0,29	0,0	1,0
APLICAÇÃO	Variável dummy com valor 1 se o produtor adota aplicação de insumos a taxa variada e 0 caso contrário	0,31	0,46	0,0	1,0
SOFTWARE	Variável dummy com valor 1 se o produtor adota algum software para gestão agrícola e 0 caso contrário	0,42	0,49	0,0	1,0

4. Resultados

A Tabela 4 apresenta os coeficientes β dos modelos econométricos de regressão logística. O teste da razão de máxima verossimilhança rejeita a hipótese nula de que todos os coeficientes são estatisticamente iguais a zero. Portanto, o modelo estimado é apropriado para identificar as variáveis que influenciam a adoção das tecnologias analisadas.

Tabela 3. Resultados dos coeficientes dos modelos logit sobre determinantes da adoção de tecnologias de agricultura digital por produtores de soja

Variáveis	Modelo Logit (coeficientes β)						
	PILOTO	SOLO	MONITOR	MAPA	PLANTIO	APLICAÇÃO	SOFTWARE
Constante	4,57*	-6,66**	-2,32	-3,45	-13,60*	-6,45**	-2,03
EXPERIENCIA	0,006	0,036*	0,047**	0,030	0,061	0,028	0,000
ESCOLARIDADE	0,127*	0,122*	0,131*	-0,009	-0,006	0,125	0,031
RISCO	-0,116	-0,271	-0,255	0,277	-0,687	-0,292	0,018
INOVADOR	-0,088	1,05***	-0,218	0,290	1,79*	0,693	0,496
CUSTO	-0,029	-,487**	-0,135	-0,676***	0,224	-0,540**	-0,753***
CONSULT	0,456	1,96***	0,543	0,305	0,741	1,23**	-0,485
AREA	0,009***	0,001	0,005***	0,002***	0,003***	0,002***	0,002***
DIVERSIF	0,157	0,158	-0,131	0,293*	-0,259	0,153	0,285*
CREDITO	-0,550	0,637	0,273	0,031	0,510	0,614	-0,687
COOP	1,00	0,699	0,105	-0,932	2,11	0,485	0,030
Função de log-verossimilhança	-54,27	-63,32	-60,48	-54,94	-21,62	-53,05	-67,06
Qui-quadrado (10 d.f.)	88,83	72,28	75,30	54,24	44,07	71,16	61,49

p-valor (nível de significância)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
R^2 McFadden	0,450	0,363	0,384	0,330	0,505	0,401	0,314

Nota: * Estatisticamente significativo a 10%, ** estatisticamente significativo a 5%, *** estatisticamente significativo a 1%.

A variável área de soja (proxy para escala de produção) foi estatisticamente significativa no nível de 1% em seis dos sete modelos estimados pelo logit. Esta variável foi positivamente associada à adoção de piloto automático, monitor de produtividade, mapa de produtividade, plantio a taxa variada, aplicação de fertilizante a taxa variada e uso de software. O resultado corrobora a hipótese H5a, destacando a grande importância da escala de produção para explicar a adoção da tecnologia de agricultura digital. Fazendas maiores são mais propensas a adotar essas tecnologias porque algumas delas exigem altos investimentos iniciais em máquinas e equipamentos, como o piloto automático e monitores de produtividade, que são integrados em tratores e colheitadeiras modernos. Máquinas agrícolas equipadas com tecnologia de aplicação a taxa variada, como tratores, pulverizadores e plantadeiras, também exigem um alto investimento inicial. Em ambos os casos, altos custos fixos exigem diluição em um volume de produção substancial. Fazendas maiores podem explorar os benefícios das economias de escala, bem como podem ser mais beneficiadas pela automação de algumas operações de cultivo. Grandes fazendas também têm maior poder de barganha em negociações com fornecedores de tecnologia e mais flexibilidade para testar experimentalmente algumas tecnologias em áreas marginais antes da adoção em larga escala.

A variável CUSTO, que mede as percepções de custo dos agricultores sobre a tecnologia digital, foi significativa no nível de 1% e teve um impacto negativo na probabilidade de adoção de mapa de produtividade e uso de software. Além disso, essa estimativa foi significativa no nível de 5% para a aplicação de fertilizantes a taxa variada e amostragem georreferenciada de solo. Isso mostra que se os agricultores perceberem que a tecnologia é muito cara para eles, a probabilidade de adotar uma determinada tecnologia diminui. Talvez esses agricultores superem o investimento esperado e o custo marginal das tecnologias, reduzindo assim a utilidade esperada da adoção.

A EXPERIÊNCIA do agricultor teve um efeito positivo na probabilidade de adoção de amostragem georreferenciada de solo (ao nível de 10%) e monitor de produtividade (ao nível de 5%). Agricultores com mais experiência na produção de soja podem perceber o valor dessas tecnologias e auxiliar no gerenciamento da propriedade rural a partir do melhor uso dessas tecnologias digitais. A variável não foi significativa para piloto automático, mapa de produtividade, plantio a taxa variada, aplicação a taxa variada e uso de software. No entanto, é interessante observar que as estimativas da variável apresentaram sinal positivo em todos os modelos.

O nível de ESCOLARIDADE do agricultor afetou positivamente a probabilidade de adoção de piloto automático, amostragem georreferenciada de solo e monitor de produtividade no nível de significância de 10%. O nível de educação do agricultor é um *proxy* para o capital humano, indicando maior capacidade de usar as informações geradas pelas tecnologias digitais no processo de tomada de decisão.

As estimativas da variável INOVAÇÃO apresentaram efeitos positivos e estatisticamente significativos na probabilidade de adoção das tecnologias de amostragem de solo e plantio de taxa variável. O resultado para a última tecnologia é particularmente interessante. Essa tecnologia está em estágios iniciais de difusão na produção agrícola brasileira. De acordo com as categorias clássicas de adotantes de tecnologia propostas por Rogers (1962), os adotantes dessa tecnologia podem ser classificados como inovadores, o que é corroborado pelos resultados empíricas.

As estimativas de contratação de consultoria contratada (CONSULT) foram associadas positiva e estatisticamente significativa à adoção de tecnologias de amostragem de solo e aplicação a taxa variável. Essas descobertas corroboram a importância do acesso a informações relevantes para aumentar a adoção de tecnologias digitais. A consultoria privada é importante para a difusão de informações de qualidade sobre tecnologias digitais, bem como para ajudar na sua implementação e gestão. Especialistas têm auxiliado significativamente os agricultores na análise de dados do solo e na formulação de recomendações adequadas para o uso dessa tecnologia.

O índice de diversificação da produção agrícola (DIVERSIF) foi significativo em 10% e afetou positivamente a adoção do mapa de produtividade e do software de gestão. A gestão de fazendas mais diversificadas tende a ser mais complexa (mais operações, maior uso de insumos, mais fornecedores, mais compradores, etc.), o que aumenta a utilidade de tecnologias baseadas em gestão da informação, como mapas de produtividade e software de gestão.

As variáveis acesso ao crédito (CREDITO), associação a uma cooperativa de agronegócio (COOP) e aversão ao risco (RISCO) não foram estatisticamente significativas ao nível de 10% em nenhum dos modelos logit estimados. Portanto não é possível afirmar que essas variáveis afetaram as decisões sobre a adoção de tecnologia agrícola digital pelos produtores de soja da amostra.

A Tabela 4 apresenta se as hipóteses foram ou não suportadas com base nas estimativas dos sete modelos de regressão logística.

Tabela 4. Síntese dos resultados econométricos e as hipóteses testadas

Hipóteses	Variável	A hipótese foi suportada por modelos logit?
H1a: Quanto maior a experiência do agricultor, maior a probabilidade de adoção de tecnologias digitais.	EXPERIÊNCIA	Parcialmente (2 de 7 modelos logit)
H1b: Agricultores com níveis mais altos de educação são mais propensos a adotar tecnologias digitais.	ESCOLARIDADE	Parcialmente (3 de 7 modelos logit)
H2a: Quanto mais propensos à inovação os agricultores forem, maior será a probabilidade de adotarem tecnologias digitais.	INOVADOR	Parcialmente (2 de 7 modelos logit)
H2b: Os agricultores mais avessos ao risco têm menor probabilidade de adotar tecnologias digitais.	RISCO	Não
H3: se o produtor percebe que a tecnologia é cara, a probabilidade de sua adoção diminui.	CUSTO	Parcialmente (4 de 7 modelos logit)
H4: A contratação de serviços de consultoria especializada afeta positivamente a probabilidade de adoção de tecnologias digitais.	CONSULT	Parcialmente (2 de 7 modelos logit)
H5a: O tamanho da fazenda tem um efeito positivo na adoção de tecnologias digitais pelos agricultores.	ÁREA	Parcialmente (6 de 7 modelos logit)
H5b: Quanto maior a diversificação de culturas em uma fazenda, maior a probabilidade de adoção de tecnologia digital.	DIVERSIF	Parcialmente (2 de 7 modelos logit)

H6: O acesso ao crédito rural influencia positivamente a probabilidade de adoção de tecnologia digital.	CRÉDITO	Não
H7. Os agricultores que são membros de cooperativas têm maior probabilidade de adotar tecnologia digital.	COOP	Não

4. Considerações finais

O objetivo deste artigo foi investigar os determinantes da adoção de tecnologias de agricultura digital por produtores de soja no estado de São Paulo. Os resultados indicaram que a área plantada com soja, a experiência, a capacidade de inovação do agricultor, a escolaridade, a diversificação da fazenda e a contratação de consultoria foram estatisticamente significativas e influenciaram positivamente à probabilidade de adoção de pelo menos uma das sete tecnologias analisadas.

Por outro lado, a percepção do custo das tecnologias pelo produtor impactou negativamente na probabilidade de adoção de análise georreferenciada de solo, mapa de produtividade, aplicação de insumos a taxa variada e uso de software de gestão. Ou seja, a percepção que essas tecnologias são caras reduzem a probabilidade de adoção.

A difusão mais ampla dessas tecnologias é crítica para otimizar a produção, seja na redução do uso de insumos e no aumento de produtividade e da renda dos agricultores. Com base nos resultados empíricos, o tamanho da fazenda é a variável mais relevante relacionada à adoção de tecnologias digitais. Portanto, a escala de produção pode ser considerada uma barreira à adoção dessas tecnologias. Várias estratégias podem contribuir para a adoção e difusão dessas tecnologias digitais entre os produtores de soja. Isso inclui a promoção e a participação em cooperativas para melhorar o acesso a tecnologias, aumentar o poder de mercado na compra dos insumos e na venda dos produtos finais; implementar políticas públicas para pequenos agricultores, como facilidades no acesso ao crédito para investimento em equipamentos e máquinas; e oferecer treinamento para agricultores e agentes de extensão rural para disseminar informações sobre as tecnologias digitais.

A diversificação de culturas é outro fator relacionado à maior probabilidade de adoção de tecnologias digitais, o que denota alguma tecnicidade, especificidade para conduzir a atividade agrícola. Nesse sentido, essas tecnologias estudadas são vantajosas para todos os perfis de agricultores. Portanto, todos os *insights* sobre os determinantes da adoção e as barreiras à não adoção de tecnologias digitais são úteis para uma melhor compreensão da especificidade da adoção de tecnologia para produtores de soja no estado de São Paulo.

Essas estratégias podem diminuir a lacuna entre os agricultores e a adoção de tecnologias como amostragem de solo em grade, aplicação de taxa variável, mapeamento de produtividade, monitoramento de produtividade e sistemas de piloto automático. Esses resultados contribuem para ampliar o conhecimento e a difusão de informações relacionadas aos determinantes e as barreiras à adoção das tecnologias de agricultura digital para todos os elos da cadeia de produção agropecuária, desde os fornecedores de insumos até os desenvolvedores dessas tecnologias, com foco especial para os produtores rurais.

AGRADECIMENTOS

Esta pesquisa foi apoiada pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) - processos 2022/02967-5 e 2023/14459-7.

Referências

Balafoutis, A.T., Beck, B., Fountas, S., Tsiropoulos, Z., Vangeyte, J., van der Wal, T., 2017. Smart farming technologies -description, taxonomy and economic impact. In: Pedersen, S., Lind, K. (Eds.), *Precision Agriculture: Technology and Economic Perspectives.* Progress in Precision Agriculture. Springer, Cham, pp. 21–77. https://doi.org/10.1007/978-3-319-68715-5.

Balasundram, S. K., Shamshiri, R. R., Sridhara, S., & Rizan, N. (2023). The Role of Digital Agriculture in Mitigating Climate Change and Ensuring Food Security: An Overview. *Sustainability*, 15(6), 5325. https://doi.org/10.3390/su15065325

Barman, A., Saha, P., Patel, S., & Bera, A. (2022). Crop Diversification an Effective Strategy for Sustainable Agriculture Development. Em V. Singh Meena, M. Choudhary, R. Prakash Yadav, & S. Kumari Meena (Orgs.), Sustainable Crop Production—Recent Advances. *IntechOpen*. https://doi.org/10.5772/intechopen.102635

Barnes, A. P., Soto, I., Eory, V., Beck, B., Balafoutis, A. T., Sanchez, B., Vangeyte, J., Fountas, S., Van Der Wal, T., & Gómez-Barbero, M. (2019). Influencing incentives for precision agricultural technologies within European arable farming systems. *Environmental Science & Policy*, 93, 66–74. https://doi.org/10.1016/j.envsci.2018.12.014

Blasch, J., van der Kroon, B., van Beukering, P., Munster, R., Fabiani, S., Nino, P., & Vanino, S. (2022). Farmer preferences for adopting precision farming technologies: a case study from Italy. *European Review of Agricultural Economics*, 49(1), 33-81.

Caffaro, F., & Cavallo, E. (2019). The effects of individual variables, farming system characteristics and perceived barriers on actual use of smart farming technologies: Evidence from the Piedmont region, northwestern Italy. *Agriculture*, 9(5), 111.

Carrer, M. J., De Souza Filho, H. M., & Batalha, M. O. (2017). Factors influencing the adoption of Farm Management Information Systems (FMIS) by Brazilian citrus farmers. *Computers and Electronics in Agriculture*, *138*, 11–19. https://doi.org/10.1016/j.compag.2017.04.004

Carrer, M. J., Filho, H. M. S., Vinholis, M. M. B., & Mozambani, C. I. (2022). Precision agriculture adoption and technical efficiency: An analysis of sugarcane farms in Brazil. *Technological Forecasting and Social Change*, 177, 121510. https://doi.org/10.1016/j.techfore.2022.121510

Carrer, M. J., Maia, A. G., De Mello Brandão Vinholis, M., & De Souza Filho, H. M. (2020). Assessing the effectiveness of rural credit policy on the adoption of integrated crop-livestock systems in Brazil. *Land Use Policy*, *92*, 104468. https://doi.org/10.1016/j.landusepol.2020.104468

Cui, L., & Wang, W. (2023). Factors Affecting the Adoption of Digital Technology by Farmers in China: A Systematic Literature Review. *Sustainability*, 15(20), 14824. https://doi.org/10.3390/su152014824

D'Antoni, J. M., Mishra, A. K., & Joo, H. (2012). Farmers' perception of precision technology: The case of autosteer adoption by cotton farmers. *Computers and Electronics in Agriculture*, 87, 121–128. https://doi.org/10.1016/j.compag.2012.05.017

Drewry, J. L., Shutske, J. M., Trechter, D., Luck, B. D., & Pitman, L. (2019). Assessment of digital technology adoption and access barriers among crop, dairy and livestock producers in Wisconsin. *Computers and Electronics in Agriculture*, 165, 104960.

Feder G, Just RE, Zilberman D (1985) Adoption of agricultural innovations in developing countries: a survey. *Econ Dev Cult Change* 33(2):255–298.

Gabriel, A., & Gandorfer, M. (2023). Adoption of digital technologies in agriculture—An inventory in a european small-scale farming region. *Precision Agriculture*, 24(1), 68–91. https://doi.org/10.1007/s11119-022-09931-1

Girma, Y. (2022). Credit access and agricultural technology adoption nexus in Ethiopia: A systematic review and meta-analysis. *Journal of Agriculture and Food Research*, 10, 100362.

Greene, W.H., 2003. Econometric analysis. 5 ed. Prentice Hal, New Jersey, 1026 p.

Holgado-Silva, H. C., & Binotto, E. (2022). Innovation Performance: What Is Happening in Agricultural Cooperatives? BBR. *Brazilian Business Review*, 19(6), 626-641.

Hufnagel, J., Reckling, M., & Ewert, F. (2020). Diverse approaches to crop diversification in agricultural research. A review. Agronomy for Sustainable Development, 40(2), 14. https://doi.org/10.1007/s13593-020-00617-4

Khan, N., Ray, R. L., Kassem, H. S., & Zhang, S. (2022). Mobile Internet Technology Adoption for Sustainable Agriculture: Evidence from Wheat Farmers. Applied Sciences, 12(10), 4902. https://doi.org/10.3390/app12104902

Larson, J. A., Roberts, R. K., English, B. C., Larkin, S. L., Marra, M. C., Martin, S. W., Paxton, K. W., & Reeves, J. M. (2008). Factors affecting farmer adoption of remotely sensed imagery for precision management in cotton production. *Precision Agriculture*, 9(4), 195–208. https://doi.org/10.1007/s11119-008-9065-1

Leite, A. R., Padilha, A. C. M., & Binotto, E. (2021). Cooperation challenges in agricultural cooperatives. *Revista de Administração da UFSM*, 14, 809-826.

Lien, G., Kumbhakar, S. C., & Mishra, A. K. (2023). Production Function and Farmers' Risk Aversion: A Certainty Equivalent-adjusted Production Function. *Journal of Agricultural and Applied Economics*, 55(2), 324-340.

McFadden D. (1974). Conditional logit analysis of qualitative choice behavior. In: P. Zarembka (ed.), *Frontiers in Econometrics*. New York: Academic Press, 105–142.

McFadden, J., Njuki, E., Griffin, T. 2023. Precision Agriculture in the Digital Era: Recent Adoption on U.S. Farms, EIB-248, U.S. Department of Agriculture, Economic Research Service.

Mendes, J. D. J., Carrer, M. J., Vinholis, M. D. M. B., & Meirelles De Souza Filho, H. (2023). Adoption and impacts of messaging applications and participation in agricultural information-sharing groups: An empirical analysis with Brazilian farmers. *Journal of Agribusiness in Developing and Emerging Economies*. https://doi.org/10.1108/JADEE-09-2022-0194

Michels, M., Fecke, W., Feil, J. H., Musshoff, O., Pigisch, J., & Krone, S. (2020). Smartphone adoption and use in agriculture: empirical evidence from Germany. *Precision Agriculture*, 21, 403-425.

Moreno, J. C., Berenguel, M., Donaire, J. G., Rodríguez, F., Sánchez-Molina, J. A., Guzmán, J. L., & Giagnocavo, C. L. (2024). A pending task for the digitalisation of agriculture: A general framework for technologies classification in agriculture. *Agricultural Systems*, 213, 103794. https://doi.org/10.1016/j.agsy.2023.103794.

Mozambani, C. I., De Souza Filho, H. M., Vinholis, M. D. M. B., & Carrer, M. J. (2023). Adoption of precision agriculture technologies by sugarcane farmers in the state of São Paulo, Brazil. *Precision Agriculture*, 24(5), 1813–1835. https://doi.org/10.1007/s11119-023-10019-7

Paxton, K. W., Mishra, A. K., Chintawar, S., Roberts, R. K., Larson, J. A., English, B. C., Lambert, D. M., Marra, M. C., Larkin, S. L., Reeves, J. M., & Martin, S. W. (2011). Intensity of Precision Agriculture Technology Adoption by Cotton Producers. *Agricultural and Resource Economics Review*, 40(1), 133–144. https://doi.org/10.1017/S1068280500004561

Pivoto, D., Barham, B., Waquil, P. D., Foguesatto, C. R., Dalla Corte, V. F., Zhang, D., & Talamini, E. (2019). Factors influencing the adoption of smart farming by Brazilian grain farmers. *International Food and Agribusiness Management Review*, 22(4), 571-588.

Rayhan, S. J., Rahman, M. S., & Lyu, K. (2023). The role of rural credit in agricultural technology adoption: The case of Boro rice farming in Bangladesh. *Agriculture*, 13(12), 2179

Rogers, E.M. (1962). Diffusion of Innovations. Free Press, New York.

Shang, L., Heckelei, T., Gerullis, M. K., Börner, J., & Rasch, S. (2021). Adoption and diffusion of digital farming technologies—Integrating farm-level evidence and system interaction. Agricultural Systems, 190, 103074. https://doi.org/10.1016/j.agsy.2021.103074

Souza Filho, H. M., Vinholis, M. M. B., Carrer, M. J., & Bernardo, R. (2021). Determinants of adoption of integrated systems by cattle farmers in the State of Sao Paulo, Brazil. *Agroforestry Systems*, 95, 103-117.

Souza Filho, H.M.; Buainain, A.M., Silveira, J.M.F.J., Vinholis, M. M. B. (2011). Condicionantes da adoção de inovações tecnológicas na agricultura. *Cadernos de Ciência & Tecnologia*, Brasília, v. 28, n. 1, p. 223-255.

Torbett, J. C., Roberts, R. K., Larson, J. A., & English, B. C. (2007). Perceived importance of precision farming technologies in improving phosphorus and potassium efficiency in cotton production. *Precision Agriculture*, 8(3), 127–137. https://doi.org/10.1007/s11119-007-9033-1

Walder, P., Sinabell, F., Unterlass, F., Niedermayr, A., Fulgeanu, D., Kapfer, M., ... & Kantelhardt, J. (2019). Exploring the relationship between farmers' innovativeness and their values and aims. *Sustainability*, 11(20), 5571.

Walker, J., & Ben-Akiva, M. (2002). Generalized random utility model. *Mathematical social sciences*, 43(3), 303-343.

Walton, J. C., Roberts, R. K., Lambert, D. M., Larson, J. A., English, B. C., Larkin, S. L., Martin, S. W., Marra, M. C., Paxton, K. W., & Reeves, J. M. (2010). Grid soil sampling adoption and abandonment in cotton production. *Precision Agriculture*, 11(2), 135–147. https://doi.org/10.1007/s11119-009-9144-y

Watcharaanantapong, P., Roberts, R. K., Lambert, D. M., Larson, J. A., Velandia, M., English, B. C., Rejesus, R. M., & Wang, C. (2014). Timing of precision agriculture technology adoption in US cotton production. *Precision Agriculture*, 15(4), 427–446. https://doi.org/10.1007/s11119-013-9338-1

Yeo, M. L., & Keske, C. M. (2024). From profitability to trust: Factors shaping digital agriculture adoption. *Frontiers in Sustainable Food Systems*, 8, 1456991. https://doi.org/10.3389/fsufs.2024.1456991