

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

ANDERSON RODOLFO DE LIMA

MODELO DE ACEITAÇÃO PARA TECNOLOGIAS DIGITAIS NA
AGRICULTURA: APLICAÇÃO À SISTEMAS DE INFORMAÇÃO DE GESTÃO
AGRÍCOLA

SÃO CARLOS - SP

2023

ANDERSON RODOLFO DE LIMA

**MODELO DE ACEITAÇÃO PARA TECNOLOGIAS DIGITAIS NA
AGRICULTURA: APLICAÇÃO À SISTEMAS DE INFORMAÇÃO DE GESTÃO
AGRÍCOLA**

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do São Carlos, para obtenção do título de Doutor em Engenharia de Produção.

Linha de Pesquisa: Gestão de Cadeias Agroindustriais.

Orientador: Dr. Mário Otávio Batalha

SÃO CARLOS - SP

2023

*Dedico este trabalho aos meus amados pais pelo
cuidado e pela fé durante toda a caminhada e a
minha querida Suellen por ter escolhido ser minha
companheira de vida.*

AGRADECIMENTO

Primeiramente aos meus orientadores, professor Dr. Mário Otávio Batalha e Dra. Claudia De Mori. Gostaria de agradecer pelas conversas, pela atenção, a disponibilidade de tempo, incentivo e transmissão de conhecimento e, principalmente, por toda a dedicação e entusiasmo que teve no decorrer deste trabalho.

Agradeço a todos os professores do Programa de Pós-Graduação em Engenharia de Produção (PPGEP), que compartilharam comigo seus conhecimentos e contribuíram para minha formação. Agradeço também aos servidores da secretaria da UFSCar pelo atendimento sempre cortês e eficiente.

Aos colegas do Grupo de Estudos e Pesquisas Agroindustriais (GEPAI) pelas reuniões sempre animadas e produtivas durante todo o processo.

A todos que, de alguma forma, contribuíram para a realização deste trabalho, a minha gratidão.

*“Agora, até um frango tem mais
tecnologia do que carne”*

Domenico De Masi

RESUMO

Os agricultores que conseguirem aproveitar os benefícios advindos do uso de tecnologias da Agricultura 4.0 obterão vantagem competitiva por meio da diminuição de custos, economia de recursos e aumento da produtividade. Em que pese esta situação, muitos agricultores relutam ou enfrentam obstáculos à adoção de tecnologias digitais. É neste contexto que a identificação e análise dos fatores de aceitação e uso de tecnologias digitais pelos produtores rurais brasileiros assume toda a sua relevância e contemporaneidade. Para tanto, esta tese propõe uma adaptação da Teoria Unificada de Aceitação e Uso da Tecnologia (UTAUT), incorporando o efeito de novas variáveis oriundas do fenômeno da agricultura digital, para o estudo da aceitabilidade de Sistemas de Informação de Gestão Agrícola (*Farm Management Information Systems* (FMIS)) pelos agricultores brasileiros. Assim, esta tese previu a criação e a validação de um modelo analítico via uma pesquisa survey, na qual os respondentes foram convidados a participar em formato eletrônico on-line. Os dados coletados foram tratados por meio de estatística descritiva e multivariada. Utilizou-se a modelagem de equações estruturais (MEE), pela abordagem de mínimos quadrados parciais (PLS-SEM) com um ajuste global de adequação, para análise do modelo. Os resultados confirmaram três das dez hipóteses propostas. A Expectativa de esforço e a pressão externa influenciam positivamente a intenção comportamental dos agricultores de utilizarem FMIS. Por outro lado, o custo percebido influencia negativamente a intenção dos agricultores de utilizarem FMIS. Este estudo fornece contribuições valiosas para os estudos dos modelos comportamentais e o papel dos diferentes fatores na aceitabilidade de FMIS. As descobertas podem ser úteis tanto para agricultores como para outros interessados, incluindo agentes de extensão rural, o governo, empreiteiros, engenheiros agrônomos e trabalhadores rurais.

Palavras-chave: Adoção. Aceitabilidade. Modelos Comportamentais. *Smart farm*.

ABSTRACT

Farmers who are able to take advantage of the benefits arising from the use of Agriculture 4.0 technologies will gain a competitive advantage through cost reduction, resource savings and increased productivity. Despite this situation, many farmers are reluctant or face obstacles to the adoption of digital technologies. It is in this context that the identification and analysis of acceptance factors and use of digital technologies by Brazilian rural producers assumes all its relevance and contemporaneity. Therefore, this thesis proposes an adaptation of the Unified Theory of Acceptance and Use of Technology (UTAUT), incorporating the effect of new variables arising from the phenomenon of digital agriculture, for the study of the acceptability of Agricultural Management Information Systems (Farm Management Information Systems (FMIS)) by Brazilian farmers. Thus, this thesis envisaged the creation and validation of an analytical model via a survey research, in which respondents were invited to participate in an online electronic format. The collected data were treated using descriptive and multivariate statistics. Structural equation modeling (SEM) using the partial least squares approach (PLS-SEM) with a global adequacy adjustment was used for model analysis. The results confirmed three of the ten proposed hypotheses. Effort expectancy and external pressure positively influence farmers' behavioral intention to use FMIS. On the other hand, perceived cost negatively influences farmers' intention to use FMIS. This study provides valuable contributions to studies of behavioral models and the role of different factors in FMIS acceptability. The findings could be useful to both farmers and other stakeholders, including extension agents, the government, contractors, agronomists and farm workers.

Keywords: Adoption. Acceptability. Behavioral Models. smart farm.

LISTA DE ILUSTRAÇÕES

Figura 1 - Elementos da Agricultura Digital.	25
Figura 2 - Revoluções da Agricultura.	26
Figura 3 - A agricultura digital na cadeia produtiva.	32
Figura 4 - Campos de aplicação de IoT.	36
Figura 5 - Curva de adoção de Rogers.	45
Figura 6 - Modelo da Teoria Racionalizada (TRA).	52
Figura 7 - Modelo da Teoria do Comportamento Planejado (TPB).	53
Figura 8 - Modelo de Aceitação Tecnológica (TAM).	54
Figura 9 - Modelo de Taxa de Difusão de uma Tecnologia.	56
Figura 10 - Modelo de Taxa de Difusão de uma Tecnologia.	57
Figura 11 - Modelo de utilização de Computador Pessoal.	58
Figura 12 - O Modelo Motivacional.	59
Figura 13 - Modelo da Teoria Social Cognitiva (SCT).	60
Figura 14 - Modelo UTAUT.	62
Figura 15 - Modelo da Pesquisa.	68
Figura 16 - Etapas da Pesquisa.	78
Figura 17 - Protocolo de uma survey.	81
Figura 18 - Etapas da MEE-PLS.	86
Figura 19 - Distribuição Geográfica dos respondentes.	94
Figura 20 - Modelo e relacionamentos entre as variáveis.	105
Figura 21 - Resultado da avaliação do modelo estrutural. Avaliação do modelo estrutural proposto: resultado dos coeficientes de determinação (R^2) e os coeficientes de determinação ajustados (R^2 adj.) das variáveis endógenas.	115

LISTA DE QUADROS

Quadro 1- Tipos de tecnologias da agricultura digital.	33
Quadro 2 - Tecnologias existentes e promissoras da agricultura digital.	34
Quadro 3 - Funções comerciais de FMIS.	38
Quadro 4 - Principais características de Modelos que embasaram a criação do UTAUT.....	61
Quadro 5- Estudos de adoção utilizando o UTAUT na Agricultura.	64
Quadro 6 - Questionário da Pesquisa.	83

LISTA DE TABELAS

Tabela 1 - Faixa etária dos respondentes.	92
Tabela 2 - Nível de escolaridade dos respondentes.	92
Tabela 3 - Tempo como produtor rural.	93
Tabela 4 - Área cultivada/utilizada em hectares.	95
Tabela 5 - Setor predominante de atuação do agricultor.	95
Tabela 6 - Conhecimento prévio do agricultor acerca de sistemas de gestão.	96
Tabela 7 - Plataforma de preferência para controlar um aplicativo ou sistema de gestão.	96
Tabela 8 - Frequência de uso de sistemas de gestão agrícola.	97
Tabela 9 - Análise descritiva das variáveis.	101
Tabela 10 - Critérios do modelo de Mensuração.	106
Tabela 11 – Valores de Consistência Interna e validade convergente (AVE) do modelo proposto.	107
Tabela 12 – Valores das cargas padronizadas.	108
Tabela 13 - Segunda Rodada - – Valores de Consistência Interna e validade convergente (AVE) do modelo proposto.	109
Tabela 14 - Segunda Rodada - Valores das cargas padronizadas.	110
Tabela 15 - Valores dos Cross Loadings.	111
Tabela 16 - Valores do Critério de Fornell-Larcker.	112
Tabela 17 - Valores do Critério de Heterotrait-Monotrait Ratio of Correlations (HTMT). .	112
Tabela 18 - Critérios do Modelo Estrutural.	114
Tabela 19 - Valores dos coeficientes de caminho.	116
Tabela 20 - Avaliação do efeito do tamanho (f^2).	117
Tabela 21 - Indicador de Relevância Preditiva (Q^2) para variáveis endógenas.	117
Tabela 22 - Resultado das hipóteses e coeficientes de caminho.	118

LISTA DE SIGLAS E ABREVIATURAS

AP – Agricultura de precisão
AVE - Variância Média Extraída
CF - Condições Facilitadoras
CO - Comportamento de Uso
CP - Custo Percebido
CS - Cadeias de Suprimento
CSA - *Community Supported Agriculture*
C-TAM-TPB - Modelo combinado de aceitação
DSS - Sistemas de apoio à decisão
ED - Expectativa de desempenho
E-Digital - Estratégia Brasileira de Transformação Digital
EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária
ERP - *Enterprise Resource Planning*
FAO - *Food and Agriculture Organization*
FMIS - Sistemas de Informação de Gestão Agrícola
GCS - Gestão de Cadeia de Suprimento
GNSS – Sistema de navegação global por satélite
GPS – Sistema de posicionamento global
IA - Inteligência Artificial
IBGE – Instituto Brasileiro de Geografia e Estatística
IC - Intenção Comportamental
IDT - Teoria da Difusão da Inovação
IS - Influência Social
ISO - *International Organization for Standardization*
IOT - Internet das Coisas
MEE - Modelagem de equações estruturais
M-learning - Tecnologias móveis para aprendizado
MM - Modelo Motivacional
MIS - *Management Information Systems*
MPCU - Modelo de Utilização de Computador Pessoal.
MWM -*Modified Waterfall Model*
NFC - *Near-Field Communication*

OCDE - Organização para a Cooperação e Desenvolvimento Econômico

PAT – Piloto automático

PE - Pressão Externa

PLS - *Partial Least Squares*

PMEs - Pequenas e médias empresas

P&D - Pesquisa e desenvolvimento

RUTAM - Modelo de Aceitação de Tecnologia Rural

SAD - Sistema de Apoio à Decisão

SCT - Teoria Social Cognitiva

SEM - *Structural Equation Modeling*

SMS - Mensagem de Texto

TAM - Modelo de Aceitação de Tecnologia

TI - Tecnologia da Informação

TICs - Tecnologias de informação e comunicação

TPB - Teoria do Comportamento Planejado

TRA - Teoria da Ação Racionalizada

UTAUT - Teoria Unificada de Aceitação e Uso de Tecnologia

UAVs - *Unmanned aerial vehicles*

SUMÁRIO

1	INTRODUÇÃO	16
1.1.	Objetivos	19
1.1.1.	Objetivo Geral	19
1.1.2.	Objetivos Específicos	19
1.2.	Justificativa e Relevância do Tema	19
1.3.	Estrutura da Tese	21
2	REFERENCIAL TEÓRICO	22
2.1.	AGRICULTURA DIGITAL	22
2.1.1.	Agricultura Digital: origem, conceitos e evolução.	22
2.1.2.	Impactos e riscos da agricultura digital na produção rural.	26
2.1.3.	Tecnologias da Agricultura Digital	31
2.1.4.	<i>Farm Management Information System (FMIS)</i>	37
2.1.5.	O Brasil no cenário da agricultura digital	39
2.2.	ADOÇÃO DE TECNOLOGIAS: CONCEITOS E MODELOS	43
2.2.1.	Conceitos básicos e fundamentos teóricos de adoção de novas tecnologias	43
2.2.2.	O processo de aceitabilidade e adoção de novas tecnologias na agricultura	46
2.2.3.	Fatores determinantes de adoção de novas tecnologias na agricultura	48
2.3.	MODELOS DE ADOÇÃO DE TECNOLOGIAS	51
2.3.1.	Teoria da Ação Racionalizada	52
2.3.2.	Teoria do comportamento planejado	53
2.3.3.	Modelo de aceitação tecnológica	53
2.3.4.	Teoria da difusão da inovação	55
2.3.5.	TAM e TPB combinados	56
2.3.6.	Modelo de utilização de PC	57
2.3.7.	Modelo Motivacional	58
2.3.8.	Teoria social cognitiva	59

2.3.9.	O Modelo da Teoria Unificada de aceitação e uso da tecnologia (UTAUT)	62
3	MODELO TEÓRICO PROPOSTO	68
3.1.	Expectativa de Desempenho	69
3.2.	Expectativa de Esforço	70
3.3.	Condições facilitadoras	72
3.4.	Custo Financeiro Percebido	74
3.5.	Pressão externa	75
3.6.	Intenção Comportamental	76
4	MÉTODO	78
4.1.	Delineamento da pesquisa	78
4.2.	O método Survey	80
4.3.	Operacionalização da survey	81
4.4.	Técnica de Análise de Dados	84
4.4.1.	Avaliação do modelo de mensuração	87
4.4.1.1.	Consistência interna	87
4.4.1.2.	Validade convergente	88
4.4.1.3.	Validade discriminante	88
4.4.2.	Avaliação do modelo estrutural	88
4.4.2.1.	Variância explicada	89
4.4.2.2.	Coeficientes de caminho	89
4.4.2.3.	Coeficientes de determinação	89
4.4.2.4.	Relevância preditiva	90
5	RESULTADOS DA PESQUISA	91
5.1.	Característica da amostra	91
5.2.	Análise dos Dados Descritivos	98
5.3.	Modelagem de Equações Estruturais	104
5.3.1.	Avaliação do modelo de mensuração	106

5.3.1.1.	Consistência interna e validade convergente	106
5.3.1.2.	Validade discriminante	110
5.3.1.3.	Considerações sobre a avaliação do modelo de mensuração	113
5.3.2.	Avaliação do modelo estrutural	113
5.3.2.1.	Variância explicada (R^2)	114
5.3.2.2.	Coeficientes de caminho (β)	116
5.3.2.3.	Avaliação do efeito do tamanho (f^2)	116
5.3.2.4.	Avaliação da relevância preditiva (Q^2)	117
5.3.3.	Validação das hipóteses: análise e discussão dos resultados	118
6	CONSIDERAÇÕES FINAIS	127
	REFERÊNCIAS	131

1 INTRODUÇÃO

A agricultura desempenha um papel importante no desenvolvimento econômico e social, contribuindo decisivamente para a segurança alimentar e a redução da pobreza (BATALHA; SILVA, 2021; RONAGHI; FOROUHARFAR, 2020). Há décadas que a produção agrícola se pauta pela busca por tecnologias agrícolas cada vez mais sofisticadas que promovam o aumento da produtividade, substituição do trabalho humano, melhor gestão de recursos e menor degradação dos recursos naturais (GIUA; MATERIA; CAMANZI, 2022; MICHELS; BONKE; MUSSHOFF, 2020; MOLINA-MATURANO et al., 2021; ROSE; CHILVERS, 2018).

As tecnologias agrícolas dizem respeito às técnicas, métodos, ferramentas e máquinas usadas com o propósito de apoiar o aumento da produtividade no campo (ABDULLAH; SAMAH, 2013). A tecnologia disponível é regularmente transformada e alterada para tornar-se mais efetiva em suas aplicabilidades e capacidades de executar funções cada vez mais avançadas e complexas (KRÜMPPEL, 2019).

Na última década, este processo pôde ser visto nas transformações digitais ocorridas no agronegócio, com, por exemplo, o uso crescente de tecnologias inteligentes e automatizadas voltadas para captação e análises de dados aplicadas nos processos agrícolas (BOURSIANIS et al., 2022). Esse fenômeno vem sendo conhecido como “agricultura digital”. Para alguns autores, a agricultura digital é aquela que utiliza um conjunto de novas soluções técnicas que utiliza as denominadas “tecnologias digitais” (também chamadas de tecnologias inteligentes ou 4.0) para maximizar os retornos econômicos e garantir a preservação de recursos, sem gerar prejuízos ao meio ambiente (KNIERIM et al., 2019).

Espera-se que por meio de tecnologias como inteligência artificial (IA), *big data*, internet das coisas (*internet of things* - IoT), computação em nuvem, sistemas *cyberfísicos*, tecnologias de informação e comunicação (TICs), entre outros, os agricultores consigam utilizar menos recursos de produção e aumentar a produtividade das áreas cultiváveis (MASSRUHÁ et al., 2020). Além disso, pode-se esperar que a aceitação das tecnologias digitais melhore a troca de conhecimentos por meio de dados onipresentes, aprimorando o monitoramento de crises e a resolução de problemas em cadeias e setores agrícolas (KLERKX; JAKKU; LABARTHE, 2019; SHARMA et al., 2023).

Pesquisas indicam que a introdução bem-sucedida de uma nova tecnologia está altamente associada à compreensão dos fatores que impactam a intenção dos usuários em adotá-la (YU, 2012). Especificamente, algumas inovações adicionam novas exigências para sua aceitação e uso. Segundo Poppe et al (2015),

o processo de adoção de tecnologias digitais inovadoras requer recursos e competências que nem todos os atores possuem. Estudos identificaram barreiras para aplicação de tecnologias digitais como: falta de integração entre sistemas, baixo nível de educação e conhecimento em TI (tecnologia da Informação) dos agricultores, dificuldades na manipulação de dados e informações obtidas de equipamentos e máquinas e má infraestrutura de telecomunicações em propriedades (KLERKX; JAKKU; LABARTHE, 2019; MICHELS; BONKE; MUSSHOFF, 2020; PIVOTO et al., 2018).

Concomitantemente, alguns estudos assinalam que apesar da relevância e dos benefícios potenciais das tecnologias da agricultura digital, elas apresentam uma baixa aceitação e adoção pelos agricultores (CAVALLO et al., 2014; CULLEN; FORBES; GROUT, 2013; HAN; XIONG; ZHAO, 2021; HÖTZEL; SNEDDON, 2013; MERCURIO; HERNANDEZ, 2020). De fato, estudos demonstram que os altos investimentos percebidos e os baixos retornos esperados pelos agricultores, culminaram em malsucedidas ou mesmo baixas taxas de adoção de tecnologias, mesmo daquelas mais estabelecidas como computadores e smartphones que fornecem informações de forma fácil e possibilitam o aumento do rendimento das colheitas (ANNOSI et al., 2019; MOLINA-MATURANO et al., 2021; REGAN, 2019; SNEDDON; HÖTZEL, 2011).

Os estudos que investigam os fatores determinantes na adoção de tecnologias na agricultura focam, em sua grande maioria, na análise de aspectos objetivos, racionais e associado a aspectos econômicos como os relacionados à estrutura da propriedade (tamanho, setor, posse de terras) ou nas características socioeconômicas dos agricultores (idade, educação, experiência) (GIUA; MATERIA; CAMANZI, 2022). Entretanto, a literatura existente frequentemente destaca outros fatores, aparentemente irracionais, para a rejeição ou aceitação de uma nova tecnologia (WHEELER, 2008; HÖTZEL; SNEDDON, 2013). O trabalho de Cullen, Forbes e Grout (2013) revelou que apesar de colherem os benefícios econômicos esperados, alguns agricultores descartavam a tecnologia e voltavam à prática anterior.

Esse cenário reforça a necessidade de estudos que levem em consideração não somente fatores econômicos, mas aspectos sociopsicológicos na adoção de tecnologias (GIUA; MATERIA; CAMANZI, 2022; JAFRY; O'NEILL, 2000; UNAY-GAILHARD; BOJNEC, 2016). Estudos de modelos comportamentais de aceitação de tecnologia apontam o papel que esses aspectos

desempenham e podem ocupar na tomada de decisão dos usuários das tecnologias (DAVIS; BAGOZZI; WARSHAW, 1989; MOLINA-MATURANO et al., 2021).

Visando preencher essas lacunas, este estudo visa construir e testar empiricamente um modelo teórico que permita compreender o processo de tomada de decisão dos agricultores em relação à adoção aceitabilidade de tecnologias digitais, especificamente a de FMIS (*Farm Management Information System*: Sistemas de Informação de Gestão Agrícola).

Os FMIS têm atraído atenção crescente, permitindo que os agricultores tomem decisões não apenas relacionadas às práticas agrícolas, mas também às operações financeiras e gerenciais (GIUA; MATERIA; CAMANZI, 202). Sørensen et al. (2010) definiram FMIS como um sistema planejado para a coleta, processamento, armazenamento e disseminação de dados, gerando informações necessárias para realizar a gestão da propriedade.

A aplicação do modelo será feita no contexto da agricultura brasileira, para a qual não foram identificados estudos acerca da adoção de tecnologias digitais, bem como estudos de adoção de tecnologias agrícolas envolvendo aspectos sociopsicológicos. Logo, o presente estudo pretende utilizar como ponto de partida teórico, a Teoria Unificada de Aceitação e Uso de Tecnologia (UTAUT) proposto por Venkatesh et al. (2003), uma vez que ele considera os fatores e contingências relacionados à previsão da aceitação da tecnologia e intenção de uso de tecnologias da informação.

Para tanto, o modelo UTAUT foi estendido a fatores antecedentes relacionados ao contexto de adoção de tecnologias digitais na agricultura. O modelo UTAUT é geralmente estendido por construtos contextuais adicionais que incorporam fatores específicos do domínio de uso (MIN; JI; QU, 2008). A opção pelo modelo UTAUT se justifica pela sua ampla utilização em pesquisas sobre adoção e difusão com foco em estudos empíricos que investigam preditores de intenção e comportamento de uso de usuários (FARIDI; KAVOOSI-KALASHAMI, EL BILALI, 2020; SALLOUM; SHAALAN, 2018).

Portanto, entender os fatores que possam levar a uma relutância em adotar FMIS, àquelas que podem impactar a eficiência das propriedades, consequentemente de cadeias agrícolas, revela-se como de fundamental importância, em especial na agricultura, onde a busca por melhores práticas de gestão e pelo aumento da produtividade é constante.

1.1. Objetivos

A partir da questão de pesquisa apresentada, são definidos, na sequência, o objetivo geral e os objetivos específicos do presente estudo.

1.1.1. Objetivo Geral

O objetivo geral deste estudo define-se como sendo:

Propor e testar um modelo teórico que identifique os fatores que afetam a aceitabilidade de tecnologias digitais no contexto da agropecuária brasileira.

1.1.2. Objetivos Específicos

A consecução do objetivo geral pressupõe que os seguintes objetivos específicos sejam atingidos:

- i) Relatar o estado da arte acerca da agricultura digital
- ii) Examinar os modelos de adoção de tecnologias e sua adequação ao contexto da agricultura.
- iii) Identificar fatores de aceitabilidade para tecnologias digitais aplicadas à agricultura e estruturar modelo aplicado a FMIS;
- iv) Realizar a validação do modelo proposto e confrontar os resultados com a literatura.

1.2. Justificativa e Relevância do Tema

Atualmente, o setor agrícola enfrenta pressão para lidar com diversos fatores complexos como: segurança alimentar global, necessidade de aumento da produtividade, diminuição de terras cultiváveis, alteração de políticas de mercado, mudança de hábitos de consumo e implementação de práticas mais sustentáveis de produção (LEZOCHÉ et al., 2020; MARIA; MARIA; ANDREA, 2021; WALTER et al., 2017). Adicionalmente, os agricultores têm que se adaptar a novas leis e regulamentações (LEZOCHÉ et al., 2020) e atenderem um novo perfil de consumidores que pressionam por práticas que sejam ambientalmente corretas e socialmente justas (ROSE et al., 2021).

A redução nas terras aráveis em diversos países implica na necessidade de aumento da produtividade para atender à necessidade alimentar, em um cenário de uma população mundial crescente e de recursos cada vez mais escassos (ROSE et al., 2021; TRIVELLI et al., 2019). A *Food and Agriculture Organization* (FAO) estima que a população mundial deverá atingir 9 bilhões de pessoas em 2050, sendo necessário um aumento de 70% na produção global de alimentos para cumprir uma demanda sempre crescente (SHI et al., 2022)

Vários autores concordam que a agricultura digital pode contribuir de forma decisiva ao enfrentamento e mitigação dessas questões (LAJOIE-O'MALLEY et al., 2020; LEZOCHE et al., 2020; MASSRUHÁ et al., 2020; MUANGPRATHUB et al., 2019; ROSE et al., 2021). O potencial para melhoria da produtividade proporciona benefícios sociais (por exemplo, maior segurança alimentar e renda) e benefícios ambientais, à medida que menos terra é utilizada para produção (FARIDI; KAVOOSI-KALASHAMI, EL BILALI, 2020; MOLINA- MATURANO et al., 2021; ROSE; CHILVERS, 2018; RÜBCKE VON VELTHEIM; HEISE, 2021).

Isso é evidenciado por um número crescente de artigos sobre agricultura digital e o potencial transformador dessas tecnologias para sistemas de produção agrícola, cadeia de valores e sistemas alimentares (KLERKX; JAKKU; LABARTHE, 2019; RÜBCKE VON VELTHEIM; HEISE, 2021). Entretanto, um grande corpo de literatura é predominantemente voltado à ciência do design e (potenciais) aplicações de tecnologias digitais na agricultura. Poucos estudos abordaram a adoção de tecnologias digitais por agricultores (CAFFARO et al., 2020; PIVOTO et al., 2018; REGAN; 2019).

Além disso, apesar da relevância e benefícios das tecnologias digitais, pesquisas anteriores relataram baixa aceitação e rara adoção dessas tecnologias entre os agricultores (CAFFARO et al., 2020; CAVALLO et al., 2014; YOON; LIM; PARK, 2020). Historicamente, a transição e difusão de novas ideias e tecnologias na agricultura não ocorrem rapidamente, como ocorreu no caso das tecnologias agrícolas de precisão (AP) (EASTWOOD; KLERKX; NETTLE, 2017).

Ademais, a maioria dos estudos realizados com agricultores, focaram principalmente nos efeitos das características e variáveis econômicas do agricultor e da fazenda (GARCÍA-CORTIJO; CASTILLO-VALERO; CARRASCO, 2019; TEY; BRINDAL, 2012). Baumgart-Getz, Prokopy e Floress (2012) sugerem a importância da inclusão de construtos sociopsicológicos, como percepções, intenções e objetivos, no estudo da tomada de decisão dos agricultores em relação à aceitação e à adoção de tecnologias.

No que se refere à contribuição teórica, o presente trabalho propõe um modelo UTAUT expandido de estudo da aceitabilidade de novas tecnologias digitais que inclui fatores que

refletem as características idiossincráticas da produção agropecuária e seus atores. Assim, resulta desse esforço teórico um modelo inédito para o estudo da aceitabilidade de tecnologias digitais, mais especificamente das FMIS, pelos agricultores e pecuaristas.

Do ponto de vista da contribuição gerencial, é do interesse das organizações e instituições do agronegócio conhecer a dinâmica de difusão das tecnologias digitais como forma de propor estratégias que permitam explorar com sucesso este movimento. Compreender quais fatores afetam as percepções e intenções dos usuários em potencial quanto à adoção de FMIS, e como e em que direção eles exercem esse efeito, pode ajudar os *stakeholders* a desenvolver os meios apropriados para demonstrar as vantagens e promover sua adoção junto aos agricultores.

Além das lacunas teóricas de pesquisa mencionadas no decorrer desta seção, o desenvolvimento deste estudo justifica-se pela ausência de estudos que abordem a aceitabilidade de tecnologias digitais considerando fatores sociopsicológicos do agricultor brasileiro. De fato, não foram identificados exemplos da aplicação do modelo UTAUT no contexto agrícola brasileiro.

1.3. Estrutura da Tese

Esta pesquisa está estruturada em cinco capítulos. O primeiro capítulo apresenta uma contextualização do tema, tendo como cenário as mudanças implementadas pela Agricultura digital. A partir desse quadro, apresenta-se o problema de pesquisa e justifica-se a sua relevância em função das lacunas percebidas na literatura.

O segundo capítulo traz o referencial teórico acerca da agricultura digital. Neste capítulo são apresentadas as várias fases que a agricultura passou, as tecnologias que constituem a agricultura digital e os desdobramentos dessa revolução digital na dimensão econômica, ambiental e social. Além disso, foi realizada uma revisão de teorias de comportamento de aceitabilidade e adoção de tecnologias.

No terceiro capítulo é apresentado o modelo teórico proposto. No quarto capítulo, são apresentadas as escolhas metodológicas, a partir dos protocolos de pesquisa e as etapas de aplicação da *survey* e da coleta de dados, bem como a técnica de análise de dados.

Por fim, no quinto e sexto capítulo são apresentados os resultados deste estudo e as considerações finais, respectivamente.

2 REFERENCIAL TEÓRICO

2.1. AGRICULTURA DIGITAL

Neste subcapítulo, são apresentados os principais conceitos relacionados à Agricultura Digital. Em um primeiro momento, buscou-se definir origem, evolução e os seus principais conceitos. Em seguida, foram descritos os principais impactos e riscos na cadeia agroalimentar. Depois, foi abordado as tecnologias da agricultura digital, em específico dos FMIS, e o seu potencial transformador. Finalmente, foi discutido sobre a posição de destaque do Brasil no contexto da agricultura digital.

2.1.1. Agricultura Digital: origem, conceitos e evolução.

Os seres humanos cultivam terras e criam animais para obter alimentos para sua sobrevivência desde tempos imemoriais. Esta prática, conhecida como agricultura, evoluiu seguindo um processo progressivo e de longo prazo, passando por períodos disruptivos em suas práticas, conhecidos como “Revoluções Agrícolas” (ZHAI et al., 2020). Em cada revolução agrícola, novas tecnologias e visões de mundo introduziram mudanças significativas nos sistemas econômicos e nas estruturas sociais (USB, 2018). A primeira revolução agrícola, chamada por alguns autores de Agricultura 1.0, iniciou-se no século XVII impulsionada pelos avanços da I Revolução Industrial e pelo aumento da demanda por alimentos decorrente do aumento populacional na Europa (MASSRUHÁ et al., 2020). Importante salientar que até aquele momento, a agricultura era fortemente dependente das condições edafoclimáticas para o cultivo da terra e criação de animais, com pouco conhecimento acumulado e compartilhado pela sociedade (USB, 2018).

Na agricultura 1.0 ocorreu a transição da caça e da coleta para a agricultura assentada, além do aumento de áreas cultivadas, novas abordagens de comercialização e introdução de ferramentas agrícolas (MASSRUHÁ et al., 2020). Nesse estágio, embora ferramentas simples como foices e pás fossem usadas em atividades agrícolas, os agricultores ainda não dispunham de mecanismos que os auxiliassem na execução de trabalhos com maiores exigências de esforços físicos (ZHAI et al., 2020).

No início do século XX, um terço da mão de obra ativa exercia atividade na produção agrícola, sendo um sistema intensivo de trabalho, capaz de alimentar a população, mas demandando muita terra e com um baixo nível de produtividade (SPONCHIONI et al., 2019). Nesse cenário,

iniciou-se a segunda revolução, “Agricultura 2.0”, ou mais comumente conhecida como Revolução Verde, caracterizada pela busca pelo aumento da produtividade de mão-de-obra, oriunda da II Revolução Industrial, e pela inserção de materiais genéticos melhorados e produtos químicos para proteção e aumento da fertilidade de solos.

A Revolução Verde foi iniciada no final da década de 1950, a partir de novas práticas e tecnologias agrícolas (como a utilização de nitrogênio suplementar), novos produtos químicos (como pesticidas sintéticos e fertilizantes) e máquinas de produção mais eficientes (motores de combustão como a semeadora Jethro Tull), rotação de culturas e novas técnicas de fertilização de solo (MASSRUHÁ et al., 2020; ROSE; CHILVERS, 2018). Esses acontecimentos permitiram que insumos relativamente baratos fossem adotados no contexto agrícola, aumentando o potencial de rendimento e retornos crescentes de escala em todos os níveis de produção (SPONCHIONI et al., 2019).

Obviamente, a Agricultura 2.0 aumentou significativamente a eficiência e a produtividade das atividades agrícolas. No entanto, essa melhoria substancial teria trazido algumas consequências prejudiciais como contaminações químicas do campo, destruição do meio ambiente, consumo excessivo de energia e desperdício de recursos naturais (ZHAI et al., 2020). Atividades agrícolas que eram realizadas manualmente passaram a ser realizadas com máquinas e equipamentos movidos por motores a vapor ou combustão interna (PIVOTO, 2018).

Nas décadas seguintes o desenvolvimento de semicondutores (1960), computação pessoal (1970) e Internet (1990) impulsionaram o avanço tecnológico para culminar na terceira revolução industrial e, conseqüentemente, a terceira revolução agrícola, denominada “Agricultura 3.0” (USB, 2018). Nesse estágio, o rápido desenvolvimento de programas de computadores, uso de satélites, tecnologias móveis e técnicas robóticas permitiram que as máquinas agrícolas executassem operações de maneira eficiente e inteligente, possibilitando a aplicação local e exata de irrigação, fertilizantes, pesticidas e herbicidas (FEDERICO, 2008). Essa revolução é marcada pelo uso da Agricultura de Precisão (AP ou *Precision Farming*), que envolve soluções de direção automática, sensoriamento e controle para aplicações em taxa variável, telemática para monitorar a frota de veículos e rebanhos e gerenciamento de dados por meio de softwares agrícolas (SPONCHIONI et al., 2019). O objetivo da AP é aplicar a quantidade certa de insumos no local e no momento certo, para aprimorar a produção e melhorar a qualidade, enquanto protege o meio ambiente (SPONCHIONI et al., 2019).

Além disso, a AP, por meio de um processo cíclico de observação e aquisição de dados, seguido por uma interpretação e avaliação das informações adquiridas e pela implementação de uma série de decisões oriundas dela, possibilita informações sobre o solo, clima, características das

plantas e dos animais, aplicação de insumos, colheita e produção (MASSRUHÁ et al., 2020; PEDERSEN; LIND, 2017). Desde então, os sistemas tornam-se complexos, envolvendo muitas variáveis e marcado pela presença de um grande volume de dados advindos da incorporação das TICs em máquinas e equipamentos e de sensores nos sistemas de produção agrícola (MASSRUHÁ et al., 2020; WOLFERT et al., 2017).


Uma nova revolução no campo da agricultura foi desencadeada pela chamada digitalização (*digitalization*). A digitalização compreende fenômenos e tecnologias como *big data*, internet das coisas (*Internet of Things* - IoT), realidade aumentada, robótica, sensores, impressão 3D, integração de sistemas, conectividade onipresente, inteligência artificial (IA), aprendizado de máquina, *blockchain*, entre outros (KLERKX; JAKKU; LABARTHE, 2019).

O uso dessas tecnologias permite o surgimento de ecossistemas agrícolas, com plataformas que combinam dados de várias fontes na fazenda (sensores ou equipamentos) ou fontes externas, permitindo ao agricultor monitorar suas operações a partir de um painel com informações em tempo real (ou quase) para tomada de decisões com base em dados objetivos (SPONCHIONI et al., 2019). Além disso, permite a cooperação entre diferentes atores da cadeia de suprimentos, por meio da coleta e compartilhamento de dados, possibilitando o controle de todos os processos dentro de sistemas de produção cada vez mais complexos (SPONCHIONI et al., 2019).

Esse fenômeno está sendo chamado, por alguns autores, de agricultura digital ou agricultura 4.0 (em referência à quarta revolução agrícola). Como o período atual comporta a gênese do fenômeno, não existe um consenso entre os autores sobre alguns conceitos e diferentes terminologias, bem como suas origens (BASSOI et al., 2019; SPONCHIONI et al., 2019). Neste trabalho, adotando a definição de Zheng et al. (2011), o termo Agricultura Digital compreende, o uso das tecnologias para digitalizar, visualizar, projetar, monitorar e controlar objetos e processos relevantes para as necessidades agrícolas.

Quanto à perspectiva semântica, um conjunto de autores compreende o fenômeno como uma evolução do conceito de AP (ZAMBON et al., 2019). Diferentemente da AP, que está apenas levando em consideração a variabilidade do campo, a Agricultura Digital vai além, baseando as tarefas de gerenciamento não apenas no local, mas também em todo o sistema produtivo no qual a agricultura insere-se (SPONCHIONI et al., 2019), integrando diferentes elementos (Figura 1). Isso é possível, devido a sistemas ciber-físicos (*cyber-physical system*), que permitem conectar os sistemas computacionais ao mundo físico, garantindo ao agricultor controle e conhecimento dos dados sobre sua produção (FRESCO; FERRARI, 2018).


Figura 1 - Elementos da Agricultura Digital.



Fonte: Adaptado de Fresco e Ferrai (2018) e Sponchioni et al. (2019).

Em outra ótica, seria uma continuação das revoluções agrícolas, conforme ilustrado na Figura 2. Nessa visão, o conceito da como uma aplicação das tecnologias da Indústria 4.0 no campo agrícola, daí o termo Agricultura 4.0 (ANDRITOIU et al., 2018; HUH; KIM, 2018; ZAMBON et al., 2019). Logo, as tecnologias são integradas em cada processo agrícola e conectadas por toda cadeia alimentar, gerando dados para os tomadores de decisão do produtor até consumidor final (SPONCHIONI et al., 2019).

Figura 2 - Revoluções da Agricultura.



Fonte: Adaptado de USB (2018).

Independentemente de sua origem, a agricultura do futuro e os sistemas alimentares sob a ótica da agricultura digital, estão em pleno desenvolvimento e são crescentemente operacionais, embora ainda não tenham conseguido atingir todos os efeitos benéficos que seus defensores alardeiam (KLERKX; ROSE, 2020). Ademais, a expectativa para os próximos anos, é que a estratégia ajude a enfrentar desafios sustentáveis, aumentando as receitas das partes interessadas da cadeia de suprimentos agroalimentares, diminuindo sua pressão para lidar com fatores complexos e externos que eles não podem controlar, como o clima, comportamentos e políticas de mercado (KLERKX; ROSE, 2020).

2.1.2. Impactos e riscos da agricultura digital na produção rural.

A agricultura faz parte de um sistema complexo que transcende fronteiras (ROSE; CHILVERS, 2018). A natureza disruptiva da digitalização implica na inevitabilidade dos impactos desse fenômeno em mercados, modelos de negócios, cadeias de valor, comunidades rurais, propriedades, privacidade dos dados e meio ambiente (KLERKX; JAKKU; LABARTHE, 2019; LAJOIE-O'MALLEY et al., 2020; MARIA; MARIA; ANDREA, 2021; ROSE et al., 2021).

Os benefícios das tecnologias digitais para as cadeias agrícolas de suprimentos são múltiplos. Eles permitem a criação de oportunidades de negócios para toda a cadeia de valor, de fornecedores de tecnologia e insumos a agricultores, processadores e setores do varejo e promoção de práticas mais sustentáveis de produção (MWANGI; KARIUKI, 2015; UNAY-GAILHARD; BOJNEC, 2016; WALTER et al., 2017).

Ademais, o fator de maior atração é o aumento da produtividade e do lucro prometido para os agricultores. De fato, as tecnologias digitais, aplicadas em cadeias agrícolas, aumentam a produtividade, eficiência e lucratividade das operações, como apontado por Carolan (2017), Walter et al. (2017) e Saiz-rubio e Rovira-mas (2020). A diminuição da entrada de recursos economiza dinheiro e mão de obra do agricultor e o aumento da confiabilidade de dados reduz os riscos. Dados de previsões meteorológicas específicas para o local, projeções de rendimento e mapas de probabilidade para doenças e desastres, baseados em uma densa rede de dados, permitem o cultivo de culturas da melhor maneira possível (WALTER et al., 2017).

Também se espera que a digitalização melhore a troca de conhecimento e a aprendizagem entre os elos da cadeia de suprimentos, por meio do uso de dados, aprimorando o monitoramento de crises e controvérsias em sistemas agrícolas (KLERKX; JAKKU; LABARTHE, 2019). Se todos os dados relacionados ao produto são registrados por sensores automatizados, o tempo necessário para priorizar a aplicação de recursos e tomada de decisões na gestão diminui (WALTER et al., 2017).

Pela perspectiva social, o uso das tecnologias, pode ajudar a tratar preocupações em torno da agricultura como: o envelhecimento da população, redução da população agrícola, proveniência e rastreabilidade dos alimentos e bem-estar animal (BALAFOUTIS et al., 2017; KLERKX; JAKKU; LABARTHE, 2019; YOON; LIM; PARK, 2020).

Pela perspectiva ambiental, os agricultores podem reduzir a pegada ecológica de suas atividades agrícolas, bem como aumentar a eficiência (KRUMPEL, 2019). A aplicação minimizada ou localizada de insumos, como fertilizantes e pesticidas, em sistemas de AP atenua os problemas de lixiviação e a emissão de gases de efeito estufa (WALTER et al., 2017). Por outro lado, o uso permite a produção de mais alimentos nas terras existentes, poupando assim uma maior conversão de áreas de vegetação nativa em terras agricultáveis (ROSE et al., 2021).

As tecnologias digitais também têm o potencial de aumentar a aceitação dos alimentos e de produtos agrícolas pelo consumidor. Por exemplo, Walter et al. (2017) afirmam que ao otimizar o gerenciamento da produção, a qualidade do produto é aumentada. Isso é visível na produção (por meio de um menor uso de químicos), no transporte (utilizando materiais inteligentes) e no

varejo (produto disponível com melhor aparência). Além disso, o uso dessas tecnologias permite o registro de qual fazenda produziu e sob que circunstâncias, colaborando para a transparência da produção e do processamento, e oferecendo novas formas mais diretas de interação entre agricultores e consumidores (WALTER et al., 2017).

Entretanto, apesar dos benefícios (reais e potenciais) da digitalização para os diversos elos da cadeia serem evidentes nas narrativas tecnocêntricas dominantes, devem ser tratadas com cautela (WHITFIELD; CHALLINOR; REES, 2018). Algumas das tecnologias digitais podem ter impactos indesejáveis na fazenda, bem como na sociedade em geral. Portanto, é provável que elas possam causar resistência, de maneira semelhante à de tecnologias de modificação genética (ROSE; CHILVERS, 2018).

Preliminarmente, existem algumas condições básicas que devem ser atendidas para o uso de tecnologias digitais e que são, portanto, pré-requisitos para a transformação digital do setor agrícola (BOURSIANIS et al., 2020). Estas incluem: infraestrutura e conectividade (assinaturas móveis, cobertura de rede, acesso à Internet e fornecimento de eletricidade), acessibilidade, capacitação do usuário (alfabetização, educação em TIC) e apoio institucional (UBS, 2018).

Por outro lado, como citado anteriormente, algumas tecnologias digitais ainda não atingiram o estágio completo de implementação (KLERKX; ROSE, 2020). Além disso, países desenvolvidos e em desenvolvimento estão em fases diferentes de implementação, devido aos elevados custos destas tecnologias (KNIERIM et al., 2019). Autores apontam que mesmo para os Estados Unidos as novas tecnologias possuem um custo elevado para a maioria dos agricultores (KLERKX; JAKKU; LABARTHE, 2019; LIOUTAS; CHARATSARI, 2020).

Um outro fator a ser considerado é que as inovações são implementadas de formas e em momentos diferentes, dependendo do contexto da fazenda e da tecnologia em questão (KNIERIM et al., 2019). Como agravante, outros fatores são apontados na literatura como barreiras à adoção de tecnologias digitais, por exemplo: integração com sistemas pré-existentes nas propriedades; acesso de lugares remotos; estrutura complexa; custo; elevado consumo de energia, entre outros (TERENCE; PURUSHOTHAMAN, 2020).

Como acontece com todos os cenários em que novas tecnologias são introduzidas na sociedade, também existe o potencial para consequências adversas imprevistas (REGAN, 2019). Diversos autores apontam que o impacto potencial das tecnologias é rodeado por um grau de incertezas e complexidade em diversos contextos (CAROLAN, 2017; KLERKX; JAKKU; LABARTHE, 2019; MARIA; MARIA; ANDREA, 2021; ROSE et al., 2021).

Por exemplo, no contexto macro, existe o risco de que os países em desenvolvimento envolvidos na digitalização não recebam os benefícios experimentados pelos investidores estrangeiros que administram empresas agrícolas ou pelos países mais ricos que importam os alimentos (ROSE et al., 2021). No micro, Fleming et al. (2018) especifica que a amplificação digital pode aumentar desigualdades entre: regiões (por exemplo, urbano e rural), fazendas (por exemplo, pequenas e grandes) e indivíduos (por exemplo, disparidades socioeconômicas ou de educação).

Nesse sentido, o acesso a tecnologias mais modernas pode permanecer restrito a grandes fazendas com capital elevado, fazendo com que os benefícios das tecnologias digitais fiquem limitados aos produtores focados na produção de culturas conhecidas e amplamente cultivadas, como: trigo, milho e arroz (WALTER et al., 2017). Assim, levar essas vantagens para as fazendas dependerá não apenas da vontade dos produtores de adotar novas tecnologias em suas propriedades, mas também do perfil específico da fazenda em termos de economias de escala e disponibilidade de capital (SAIZ-RUBIO; ROVIRA-MAS, 2020).

As disparidades no acesso a tecnologias e serviços digitais significam que existe o risco de uma exclusão digital (JAKKU et al., 2019). Fleming et al. (2018) abordam que os altos custos de implantação destas tecnologias para fazendas individuais e o conhecimento e habilidades limitadas podem ser obstáculos significativos à adoção, especialmente, nos países em desenvolvimento.

Os pequenos agricultores e outras pessoas nas áreas rurais correm o risco de ficar para trás, não apenas em termos da alfabetização digital e do acesso a recursos digitais, mas também em termos de produtividade e aspectos de integração econômica e social (ROSE; CHILVERS, 2018). O trabalho de Wiseman et al. (2019) aponta que os aspectos sociais estão ausentes dos principais relatórios dos impactos da agricultura digital.

Rose et al. (2021) apontam três fatores da implementação das tecnologias digitais que podem gerar controvérsias: i) a mudança da natureza do trabalho, ii) empregos e iii) a propriedade dos dados. Se por um lado o uso das tecnologias reduz o trabalho manual, por outro, pode mudar a vida no campo e a natureza do trabalho, tornando-a indesejável para alguns agricultores (ROSE et al., 2018).

Carolan (2017) demonstrou que o trabalho físico, envolvimento com a terra e o meio ambiente, práticas tradicionais agrícolas e experiências fazem parte da natureza do trabalho e do que é ser um “agricultor”. O aumento do uso da tecnologia pode resultar na marginalização desse conhecimento experiencial e na desconexão entre o agricultor e o ambiente (ROSE et al., 2021).

Rose et al. (2021) ressaltam que essas mudanças da natureza do trabalho podem fazer com que muitos agricultores (principalmente os pequenos) abandonem o setor. Concomitantemente, os trabalhadores fixos e sazonais podem sofrer as consequências, bem como os consultores, em um cenário onde as máquinas cada vez mais tomam decisões autônomas baseadas em evidências sem o envolvimento humano (ROSE et al., 2021).

Além disso, segundo Walter et al. (2017) a potencial perda da responsabilidade dos agricultores em relação aos robôs e sistemas de TIC podem aumentar ou diminuir o reconhecimento e a valorização de sua profissão. Para os autores, é necessário questionar se este cenário motivará ou desencorajará pessoas talentosas a entrar no campo da agricultura.

Vale ressaltar que revoluções tecnológicas anteriores causaram redução da necessidade de mão de obra no campo (GOODMAN et al., 1987). As novas tecnologias criadas para automatizar tarefas e aumentar a eficiência podem desqualificar ou deslocar agricultores e trabalhadores agrícolas e excluir ou discriminar aqueles que não são alfabetizados digitalmente. Apesar da digitalização gerar empregos, estes não serão adequados para muitos trabalhadores agrícolas existentes, que já são marginalizados e subestimados pela sociedade (ROTZ et al., 2019).

A propriedade de dados também levantará questionamentos. Atualmente, uma quantidade significativa de dados é coletada por novas tecnologias, mas a propriedade desses dados e como eles são usados e armazenados continua sendo uma preocupação (WISEMAN et al., 2019). Walter et al. (2017) afirma que é necessário resolver as questões de direito e propriedade de uso dos dados gerados pelas tecnologias digitais. O potencial uso indevido de dados cria desafios legais e éticos adicionais para regulamentação e monitoramento (LIOUTAS et al., 2019).

Os dados gerados por máquinas podem ser usados para coagir os agricultores com produtos ou torná-los refém de empresas já poderosas (LIOUTAS et al., 2019). Os estudos de Jakku et al (2019) verificaram relações de desequilíbrios de poder, particularmente decorrentes da propriedade e compartilhamento de dados. Rose e Chilvers (2018) apontam que possíveis efeitos colaterais e desdobramentos éticos do uso de IA já estão sendo discutidos na esfera política.

A agricultura digital também enfrenta desafios como o de combinar o conhecimento e as experiências dos agricultores com essas novas tecnologias (WALTER et al., 2017). Alguns autores argumentam que algumas tecnologias digitais já podem ser fundidas em práticas existentes para criar combinações de habilidades digitais e analógicas ou dar origem a um novo tipo de "profissionalismo responsável" (KLERKX; JAKKU; LABARTHE, 2019).


Outro tema emergente são os aspectos éticos concernentes ao manejo animal (O'GRADY; O'HARE, 2017). Isso acontece, por exemplo, em manejos automatizados como sistemas de ordenha robotizados, nos quais aspectos éticos sobre a autonomia animal e a relação homem-animal são analisadas (BELANCHE, 2019).

Para enfrentar essas questões, é necessária uma abordagem holística para a digitalização envolvendo todos os *stakeholders*. (BRAUN; COLANGELO; STECHEL, 2018). Isso permitiria criação de valor eficiente em todos os níveis ao longo da cadeia de abastecimento e requer que os atores estejam cientes das melhores ferramentas para lhes conferir competitividade no mercado. (BRAUN; COLANGELO; STECHEL, 2018).

Por fim, Regan (2019) aponta que estudar a implementação digital é compreender o risco como um fenômeno social, cultural e psicológico. Diferentes atores e *stakeholders* terão, inevitavelmente, diferentes visões e expectativas sobre o desenvolvimento da agricultura digital. Rose e Chilvers (2018) reforçam, a partir de experiências passadas, que não é viável ignorar os riscos e a opinião pública de uma inovação, para construir uma visão compartilhada do futuro.

2.1.3. Tecnologias da Agricultura Digital

As tecnologias digitais agrícolas modernas introduzem um novo nível de tecnologia no campo, incluindo robótica, tecnologias de mapeamento e sistemas digitais, modelagem de dados e processos estatísticos (ROSE; CHILVERS, 2018). A sua implementação permite ao agricultor coletar dados, integrá-los a repositórios de dados de fornecedores externos ou internos, gerando conhecimento para sistemas de apoio à decisão para os agricultores (LEZOCHÉ et al., 2020). Diversos trabalhos ressaltam o potencial transformador da implementação dessas tecnologias em sistemas de produção agrícola, cadeias de valor e sistemas alimentares (EL BILALI; ALLAHYARI, 2018; HUNT; DAUGHTRY, 2018; KAMILARIS; KARTAKOULLIS; PRENAFETA-BOLDÚ, 2017; KLERKX; JAKKU; LABARTHE, 2019). Lezoche et al. (2020) consideram que as tecnologias permitirão que a agricultura evolua em um conjunto de sistemas conectados com base de dados, inteligente, ágil e autônomo. A Figura 3 ilustra a agricultura digital na cadeia produtiva nas fases de pré-produção, produção e pós-produção.

Figura 3 - A agricultura digital na cadeia produtiva.

Fonte: Adaptado de Massruhá et al. (2020).

A fase de pré-produção, por meio de tecnologias de mineração de dados, computação e modelagem, possibilitam avanços nas áreas da produção animal e vegetal e melhoramento genético (MASSRUHÁ et al., 2020). Já na fase da produção, tecnologias de AP e robótica possibilitam um mapeamento mais preciso e automação dos processos. Por fim, na fase de pós-produção, sistemas de predição, monitoramento e rastreabilidade permitem o acompanhamento de todo escoamento da produção e garantia de qualidade.

As tecnologias digitais começaram a ser implementadas na agricultura a partir dos avanços da AP, que introduziu o sensoriamento remoto, uso de satélites, FMIS e sistemas de apoio à decisão (LEZOCHÉ et al., 2020). Esses avanços abriram caminho para uma ampla transformação digital na agricultura e desenvolvimentos recentes como computação em nuvem, *IoT*, *big data*, *blockchain*, robótica e IA, permitiram a integração de linhas de produtos/processos isoladas em sistemas inteligentes e conectados (LEZOCHÉ et al., 2020; WOLFERT et al., 2017). O Quadro 1 apresenta uma categorização pela funcionalidade da tecnologia.

Quadro 1- Tipos de tecnologias da agricultura digital.

Aquisição de Dados	Sistemas globais de navegação por satélite utilizados para condução e mapeamento
	Tecnologias de mapeamento (topografia de campo, abastecimento do solo com nutrientes, rendimento)
	Tecnologias para obtenção de informações sobre as propriedades da vegetação e do solo (com base em câmeras e sensores)
	Máquinas e softwares para tecnologias de coleta de dados (tratores usando o protocolo internacional ISOBUS, Veículo aéreo não tripulado (VANT), Veículos terrestres não tripulados (VTNT), sistemas de informação de gestão agrícola, softwares para monitoramento e previsão de rendimentos, etc.
Transmissão de Dados	Conexão Móvel
	<i>Low-power wide-area network</i> (LPWAN)
	Internet (wireless, broadband)
Armazenamento e Análise de Dados	Técnicas de análise de dados para isolar zonas homogêneas dentro do campo
	Sistemas de Suporte à Decisão
	Sistemas de gestão de informações de empresas agrícolas
	Big Data
Aplicação de precisão	Computação em Nuvem
	Tecnologias de acionamento (movimento controlado em campo, autopiloto)
	Tecnologias de uso diferenciado (aplicação diferencial de minerais, orgânicos, fertilizantes de cal, produtos químicos fitossanitários, semeadura diferenciada, destruição física precisa de ervas daninhas, irrigação precisa, etc.
Soluções complexas (combinadas com outros grupos)	Internet das Coisas
	Robôs
	Veículos aéreos e terrestres não tripulados
	Inteligência Artificial

Fonte: Adaptado de Balafoutis et al. (2017) e Korotchenya (2019).

As tecnologias da agricultura digital são diversas e podem ser categorizadas de acordo com o foco de estudo na literatura (MARIA; MARIA; ANDREA, 2021; TRIVELLI et al., 2019; WOLFERT; GOENSE; SØRENSEN, 2014). Um grupo de autores, orientados à ciência do design¹, estudaram as aplicações potenciais de tecnologias digitais na agricultura (LEZOCHE et al., 2020; ROSE et al., 2021; SCUDERI et al., 2019). Ao passo que outro grupo de autores estudam tecnologias específicas e seus usos reais de aplicação (OZDOGAN; GACARI; AKTAS, 2017; ZHAI et al., 2020). Ademais, existem inúmeras oportunidades em termos de aplicação de tecnologias digitais na busca da melhoria da eficiência, eficácia e sustentabilidade

¹ Ciência do Design é uma abordagem para o desenvolvimento estruturado e colaborativo de novas soluções, produtos e serviços.

da produção agrícola. Exemplos de tecnologias existentes e promissoras para o futuro da agricultura digital podem ser visualizadas no Quadro 2.

Quadro 2 - Tecnologias existentes e promissoras da agricultura digital.

CONCEITO	DEFINIÇÃO
Agricultura Vertical (<i>Vertical Farming</i>)	A agricultura vertical pode ser definida em termos gerais como um sistema de agricultura comercial pelo qual plantas, animais, fungos e outras formas de vida são cultivadas para alimentos, combustíveis, fibra ou outros produtos ou serviços, empilhando-os artificialmente verticalmente um sobre o outro, como em um arranha-céu ou contêineres empilhados.
Bioinformática (<i>Bioinformatics</i>)	A bioinformática visa enriquecer o conhecimento biológico e aplicar conhecimentos de TI aos dados biológicos. Trata-se de armazenamento, análise e troca de grandes quantidades de dados biológicos. Frequentemente, essa identificação é feita com o objetivo de entender melhor a base genética da doença, adaptações únicas, propriedades desejáveis (especialmente nas espécies agrícolas) ou diferenças entre as populações. A bioinformática tem o potencial de dar um grande impulso à nossa capacidade de analisar dados e influenciar os atributos de plantas, animais e seres humanos.
Blockchain	O conceito de blockchain pode ser definido como um livro-razão descentralizado e distribuído para armazenar transações com registro de data e hora entre muitos computadores em uma rede ponto a ponto. Para que qualquer registro envolvido não possa ser alterado retroativamente. Isso permite que os usuários do blockchain auditem e verifiquem as transações de forma independente e transparente. Blockchain é utilizado na cadeia de suprimentos para garantir a segurança operacional, gestão financeira e a rastreabilidade das informações.
Computação em Nuvem (<i>Cloud computing</i>)	A computação em nuvem é um grupo de computadores virtualizados interconectados que prestam serviços aos clientes. A computação em nuvem oferece ao agricultor a capacidade necessária para armazenamento, análise e agregação de dados.
Impressão 3D e 4D (<i>3D/4D printing / additive manufacturing/ rapid prototyping</i>)	A impressão 3D é um processo de fabricação de objetos 3D feitos com base em um projeto (digital) (um arquivo de computador). Geralmente é um processo aditivo em que o objeto é construído camada por camada por meio de uma impressora 3D. Os objetos podem assumir (quase) qualquer forma ou geometria. O material de construção para esses objetos sólidos consiste em um pó fino (uma mistura de material vegetal, plástico e gesso). A impressão 4D adiciona uma quarta dimensão aos objetos impressos em 3D: movimento. Ela tem como objetivo produzir objetos que mudam de forma ou alteram a tensão em resposta a uma fonte de energia, como calor ou movimento.
Inteligência Artificial (<i>Artificial intelligence/ Deep learning Machine Learning</i>)	A inteligência artificial (IA) é um ramo da ciência da computação que lida com a simulação de comportamento inteligente em computadores. É um termo que descreve uma máquina que exibe inteligência humana realizando atos como reconhecimento de linguagem, aprendizado, raciocínio, percepção, planejamento e resolução de problemas. As máquinas também não são limitadas pelo espectro visível da luz e podem utilizar raios-x e outras tecnologias de imagem. A IA tem muitos usos na agricultura inteligente e automatizada. Uma área chave de seu uso é na análise de dados agrícolas.
Materiais Inteligentes (<i>Smart Materials/ Smart Packaging</i>)	O termo materiais inteligentes é usado como um nome coletivo para materiais que podem mudar de forma por meio de influências externas, incluindo pressão, temperatura, umidade, acidez (pH) e campos elétricos e magnéticos. Em breve, os alimentos poderão ser mantidos por mais tempo ou serão mais rápidos de preparar se o material de embalagem esfriar ou aquecer por si mesma.
Robôs (<i>Robotics/ Autonomous Systems / Mechatronics</i>)	A robótica trata das implicações teóricas e aplicações práticas de sistemas automatizados. Os robôs podem funcionar de forma totalmente autônoma ou semiautônoma (com um operador). Os robôs vêm em todos os tipos e formas, variando de microrrobôs (tão pequenos que podem, por exemplo, funcionar em vasos sanguíneos humanos) a humanóides (robôs que imitam a aparência e o comportamento humanos).


Fonte: Adaptado de UBS (2018) e Lezoche (2020).

A seguir, são apresentadas algumas tecnologias facilitadoras da agricultura digital.

Os **sensores** são elementos essenciais que moldam várias outras aplicações dentro da agricultura digital, como: estações meteorológicas, sensoriamento remoto em diferentes

plataformas, robôs e aplicações de IoT (O'GRADY; O'HARE, 2017). Um sensor é um componente eletrônico, módulo ou subsistema que tem a finalidade de detectar eventos ou mudanças em seu ambiente e enviar as informações para outros eletrônicos, frequentemente um computador (FRESCO; FERRARI, 2018). Os sensores são embutidos nos objetos que são conectados por intermédio de redes (com ou sem fio) por meio do uso de um esquema de endereçamento semelhante ao usado para a Internet (MITAL et al., 2018). As tecnologias de detecção podem ser vistas em toda a cadeia de valor na agricultura, desde a aquisição de dados meteorológicos, passando pela colheita e processamento do produto, até em tecnologias de rastreabilidade na etapa de transporte (O'GRADY; O'HARE, 2017).

O **sensoriamento móvel** geralmente é realizado por meio de drones (*Unmanned aerial vehicles* – UAV's). Um drone é uma aeronave sem piloto humano a bordo, controlada de forma autônoma ou por controle remoto com sensor embutido (USB, 2018). Eles são utilizados para mapeamento de cultivo, monitoramento da saúde da colheita, detecção e categorização de pragas e doenças e aplicação de insumos e fertilizantes (MARIA; MARIA; ANDREA, 2021). Destaca-se também a inserção de conceitos que abrangem a aplicação de um conjunto de tecnologias para um fim específico, como o IoT ou o Big Data. O termo “IoT” é um neologismo que se refere a um ambiente que possibilita a troca de dados em tempo real (BORGIA, 2014). Essa troca de informações é realizada sem assistência humana, podendo ser feita por *Bluetooth*, comunicação por campo de proximidade (*Near-Field Communication* - NFC), redes e sensores (KIM; LEE; KIM, 2020). Na agricultura, o IoT é usado para uma variedade de atividades. Kim, Lee e Kim (2020) categorizam quatro campos de aplicação do IoT: (i) sistemas de gerenciamento, (ii) sistemas de monitoramento, (iii) sistemas de controle e (iv) sistemas não tripulados, conforme mostrado na Figura 4.

Figura 4 - Campos de aplicação de IoT.

Fonte: Kim, Lee e Kim (2020).

O termo Big Data refere-se a grandes volumes de dados variados que podem ser capturados, analisados e usados para a tomada de decisões (WOLFERT et al., 2017). O volume de dados na agricultura aumenta continuamente pela integração de sensores, smartphones e plataformas de IoT nas propriedades, gerando um conjunto de dados diversos, complexos e de grande escala (HASHEM et al., 2015). Além disso, fontes de dados externos, como dados meteorológicos, de mercado, de redes sociais e de parceiros, requerem um conjunto de técnicas e tecnologias para integrar esse conjunto de dados e revelar *insights* para os agricultores (WOLFERT et al., 2017).

Logo, a análise de Big Data, no contexto agrícola, pode ser descrita como uma nova geração de tecnologias e práticas projetadas para que os agricultores e organizações relacionadas possam tomar decisões e extrair valor econômico dos dados (KAMILARIS; KARTAKOULLIS; PRENAFETA-BOLDÚ, 2017). Para Wolfert et al. (2017), o Big Data na agricultura está em sua gênese e causará grandes mudanças no mercado agrícola, pois estará continuamente reinventando novos modelos de negócios devido a velocidade e volume de informações que permite coletar e analisar.

Outras tecnologias que estão gerando grandes mudanças são os FMIS. Eles são um exemplo de TIC's que potencialmente desempenham um papel crucial no aprimoramento de fazendas para desenvolver a capacidade de gerenciamento de informações (KIM; YAGI; KIMINAMI, 2023). Eles podem ser baseados em aplicativos digitais e apoiar o usuário no processo de

tomada de decisão. Além disso, o FMIS pode contribuir para a redução dos custos de produção e atender às crescentes demandas de segurança e qualidade dos produtos agrícolas. Tendo em vista o objetivo desta tese, o subcapítulo seguinte discorre com detalhes sobre os FMIS.

2.1.4. *Farm Management Information System (FMIS)*

A agricultura entrou em uma nova era em que a chave para o sucesso é o acesso a informações oportunas e tomadas de decisões mais elaboradas (FOUNTAS et al., 2015). Entretanto, os agricultores podem encontrar dificuldades em tomar decisões adequadas sobre a gestão agrícola devido à grande quantidade de informações que recebem, como por exemplo: dados ambientais, econômicos, relacionados ao cultivo ou criação, entre outros (TAECHATANASAT; ARMSTRONG, 2014).

Nesse contexto, os sistemas de apoio à decisão (*Decision support systems – DSS*) foram desenvolvidos para facilitar as atividades diárias do agricultor, colaborando para a produção funcionar de forma mais eficaz (SØRENSEN et al., 2010). Tais sistemas têm permitido que os agricultores tomem decisões pautadas não apenas por informações associadas às práticas agrícolas (relacionadas à cultura), mas também às operações financeiras e gerenciais (FOUNTAS et al., 2015).

Nesse cenário, Giua, Materia e Camanzi (2021) apontam que a categoria de FMIS vem obtendo destaque. Segundo Sørensen et al. (2010), os FMIS são parte de sistemas como ERP (*Enterprise Resource Planning*) e MIS (*Management Information Systems*), envolvendo funções de planejamento, organização, monitoramento e controle das operações no contexto agrícola.

Carrer, Souza Filho e Batalha (2017) ressaltam que os FMIS refletem a estrutura organizacional das fazendas e o processo de tomada de decisão em estágios específicos de produção nas propriedades. Ao utilizar práticas mais modernas de gestão, o uso de FMIS permite uma tomada de decisão baseada em dados (FOUNTAS et al., 2015).

Além disso, eles contribuem para a redução de custos de produção, qualidade e segurança do produto e cumprimento dos padrões agrícolas (FOUNTAS et al., 2015). Em uma perspectiva macro, um FMIS pode ser projetado para lidar com questões gerenciais, apoiando decisões estratégicas e operacionais (NURKKA; NORROS; PESONEN, 2007). O Quadro 3 apresenta os tipos de funções comerciais de FMIS identificadas na literatura.

Quadro 3 - Funções comerciais de FMIS.

Função Comercial	Objetivo
Operações de campo	Registrar as atividades agrícolas. Esta função de gerenciamento também ajuda o agricultor a otimizar a produção agrícola, planejando atividades futuras e observando a execução real das tarefas planejadas. Além disso, medidas preventivas podem ser iniciadas com base nos dados monitorados.
Práticas específicas	Aplicar as melhores práticas de acordo com os padrões agrícolas (por exemplo, padrões orgânicos, requisitos de gestão integrada de culturas). Uma estimativa de rendimento é viável através da comparação das demandas reais e possibilidades alternativas, dados cenários hipotéticos de melhores práticas. Inclui tarefas de produção e métodos relacionados à estimativa de rendimento.
Finanças	Realizar a estimativa do custo de cada atividade agrícola, cálculos de insumos e produtos, necessidades de trabalho por unidade de área. Os custos projetados e reais também são comparados e inseridos na avaliação final da viabilidade econômica da propriedade.
Inventário	Objetivo é o monitoramento e gerenciamento de todos os materiais de produção, equipamentos, produtos químicos, fertilizantes e materiais de semeadura e plantio. As quantidades são ajustadas de acordo com os planos do fazendeiro e pedidos do cliente.
Rastreabilidade	Controlar a produção utilizando um sistema de etiquetagem de ID para cada lote. Além disso, permite registros de rastreabilidade relacionados ao uso de materiais, funcionários e equipamentos, podendo ser facilmente arquivados para rápida recuperação.
Monitoramento	Criar relatórios agrícolas, como planejamento e gestão, progresso do trabalho, planilhas e instruções de trabalho e relatórios de custos de compras.
Aplicação de taxa variável	Mapear as características do campo, reduzindo ou otimizando a entrada de insumos e aumentar a produção. A análise dos dados coletados pode ser usada como um guia para a aplicação de insumos com taxas variáveis.
Vendas	Realizar a gestão de encomendas, a gestão de embalagem e a transferência de despesas entre empresas, encargos de serviços e o sistema de cálculo de custos de mão-de-obra, fornecimentos e despesas de equipamento.
Gestão de pessoas	Fazer a gestão de funcionários, incluindo a disponibilidade de funcionários no período específico e no local da propriedade. O objetivo é o tratamento rápido e estruturado de questões relativas aos funcionários, como horários de trabalho, pagamento, qualificações, treinamento, desempenho e especialização.
Gestão de maquinário	Detalhar o uso do equipamento, o custo médio por hora de trabalho ou por unidade de área. Também inclui gestão de frota e logística.
Gestão da qualidade	Realizar o monitoramento do processo e a avaliação da produção de acordo com as normas, legislação e critérios de qualidade.

Fonte: Fountas et al. (2015).

Entretanto, como citado anteriormente, a operação de uma empresa agrícola exige que a administração tome e implemente várias decisões durante toda a produção oriundas de diversas fontes (TAECHATANASAT; ARMSTRONG, 2014). Logo, o desenvolvimento e a aplicação de conceitos de FMIS no setor agrícola é um desafio, devido à diversidade e à variabilidade dos processos agrícolas e ao volume de dados (SOUZA et al., 2014; SØRENSEN et al., 2010). Diversos estudos foram realizados na tentativa de entender melhor as necessidades dos produtores e a aplicação dos FMIS (CARRER; SOUZA FILHO; BATALHA, 2017; FOUNTAS et al., 2015; NURKKA; NORROS; PESONEN, 2007; SOUZA et al., 2014). Tummers, Kassahun e Tekinerdogan (2019), por meio de uma revisão de literatura, identificaram os obstáculos para o desenvolvimento de FMIS, além de fornecer um estado da arte sobre as funcionalidades dos sistemas. Os achados apontaram que as características técnicas foram as maiores barreiras, como padrões de dados e integração de sistemas.

Em outro estudo, Giua, Materia e Camanzi (2021) buscou identificar os fatores determinantes e as barreiras à adoção de FMIS. Os resultados indicaram que os fatores mais recorrentes são a facilidade de uso, o tamanho da fazenda e o nível de educação do agricultor. Entre as barreiras identificadas estão aspectos relacionados à complexidade dos FMIS, tais como: interfaces não intuitivas ou excessivamente complicadas, excesso de recursos quando comparados às necessidades reais dos usuários e dificuldades de implementar, entender e usar.

Por isso, transferir essas informações para o conhecimento prático e a correta tomada de decisão, é um fator crítico de sucesso, bem como o envolvimento do agricultor no desenvolvimento e implementação dos FMIS (SØRENSEN et al., 2010; TAECHATANASAT; ARMSTRONG, 2014). Sørensen et al. (2010) relataram que o sucesso da implementação de um FMIS está no desenvolvedor FMIS entender o que o agricultor precisa e os fatores que os levam a realizar a tomada de decisão, incluindo o que ele pensa que está funcionando bem e o que não está funcionando bem.

2.1.5. O Brasil no cenário da agricultura digital

O Brasil ocupa uma posição de destaque no agronegócio mundial. De acordo com a FAO, é o terceiro maior produtor de alimentos do mundo, depois da China e dos Estados Unidos (FAO, 2022). O relatório Perspectivas Agrícolas 2019-2028 (OECD/FAO, 2019). mostrou que o Brasil ultrapassará os Estados Unidos como o maior produtor de soja na próxima década, enquanto a produção de milho será impulsionada, principalmente, pela América Latina.

De acordo com Thorstensen e Thomazella (2020), o crescimento da produtividade no Brasil foi impulsionado por investimentos públicos e privados em P&D (pesquisa e desenvolvimento) e pela atuação de universidades públicas de ponta e da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). Esse crescimento também foi auxiliado pela incorporação de novos métodos e técnicas de cultivo, bem como novas tecnologias, tais como: melhoramento genético de plantas, mecanização e tecnologias de AP (ANSELM, 2012; BOLFE et al., 2020). Para isso, diversas iniciativas vêm sendo tomadas para incorporar as tecnologias digitais ao agronegócio brasileiro.

Em 2018, o governo brasileiro instaurou a Estratégia Brasileira de Transformação Digital (E-Digital) com o objetivo de coordenar diversas políticas públicas que facilitem a apropriação de tecnologias digitais no Brasil (BRASIL, 2018). Nela fica determinado que a digitalização do setor agropecuário seja uma das prioridades da EMBRAPA em seu Plano Estratégico, enfatizando ações na área de automação, agricultura de precisão, sistemas de informação e computação científica, geotecnologias e nanotecnologias (BRASIL, 2018).

Além disso, no âmbito federal brasileiro, desenvolveu-se no entorno do agronegócio um ambiente de empreendedorismo digital por meio de programas de aceleração de *startups* de tecnologia orientadas ao agronegócio, tais como o Startup Brasil e o InovAtiva Brasil (BRASIL, 2018). Essas *startups*, usualmente conhecidas como Agtechs, podem estar ligadas a universidades, centros de pesquisa, grandes companhias agropecuárias, fabricantes de insumos e equipamentos agrícolas e investidores (FAPESP, 2020).

Embora se observe ações de estruturação e desenvolvimento da digitalização do setor agropecuário, o cenário brasileiro da agricultura digital está cheio de contrastes. O Censo Agropecuário de 2017 apontou que o número de agricultores que acessam dados por meio de dispositivos eletrônicos atingiu 1,5 milhão (IBGE, 2018), um aumento de 1.900% comparado ao último Censo, porém alcançando menos de 1/3 do total de estabelecimentos agropecuários. No entanto, uma pesquisa da McKinsey (2021) demonstrou que os agricultores brasileiros estão à frente de seus pares americanos e europeus na preferência por canais digitais para compras agrícolas.

Segundo a pesquisa, mais de 70% dos agricultores fazem uso da internet para atividades gerais ligadas à produção e 57,5% deles utilizam redes sociais para obter ou divulgar informações da propriedade e da produção (MCKINSEY, 2021). O levantamento também demonstrou que as principais funções das tecnologias digitais utilizadas pelos agricultores são obtenção de informações e planejamento (66,1%); compra e venda de insumos, produtos e produção (40,5%); e a previsão meteorológica (30,2%) (MCKINSEY, 2021).

Em contrapartida, dados do último Censo Agropecuário mostraram que mais de 70% das propriedades rurais não possuem conexão com a internet (IBGE, 2018). Além disso, apenas 5% da área agricultável do Brasil possui acesso à internet (FAPESP, 2020). Contudo, apesar das restrições estruturais, diversos autores apontam que o Brasil é um protagonista no emprego de tecnologias da informação voltadas ao campo (BOLFE et al, 2020)

Uma revisão de literatura identificou que a maioria dos estudos são voltados para a aplicação de tecnologias específicas de AP e o da inserção das Agtechs na agricultura brasileira. Um estudo realizado por Griffin e Lowenberg-DeBoer (2020), sobre a adoção de AP por agricultores brasileiros, demonstrou que fatores como pouco uso de informática nas propriedades rurais e custo elevado das tecnologias contribuem para uma adoção lenta e desigual das tecnologias.

Em outro estudo, Silva, De Moraes e Molin (2011) estudaram a adoção de tecnologias de AP no setor sucroalcooleiro do Estado de São Paulo. Os resultados do estudo indicaram que a probabilidade de as usinas adotarem tais tecnologias é maior em usinas de capital nacional, que fazem parte de um grupo empresarial com orientação para o mercado estrangeiro e possuam gestão profissional.

No estado do Rio Grande do Sul, Anselmi (2012) investigou os fatores que levam à adoção e o perfil dos produtores rurais que adotam tecnologias de AP. Os achados apontaram que os adotantes levam o tempo médio de 4,3 anos para adotar a tecnologia, possuem grau de escolaridade elevado, utilizam diversas fontes de informação, têm a renda predominantemente agrícola e cultivam grandes áreas de terra. Ademais, os atributos da tecnologia da AP – vantagem relativa, visibilidade, compatibilidade e experimentação – determinaram 48% da satisfação do adotante, sendo a vantagem relativa da tecnologia o fator de maior potencial explicativo (ANSELMÍ, 2012).

O estudo de Bernardi e Inamatsu (2014) realizou uma survey com proprietários e administradores de 301 propriedades rurais em vários estados brasileiros sobre o uso de TICs e tecnologias da AP. Os resultados indicaram que 53% dos agricultores adotavam a AP e o perfil dos adotantes é jovem, instruído, propenso a utilizar mais tecnologias e informática e cultivam grandes extensões de terras (BERNARDI; INAMATSU, 2014).

No estado do Tocantins, Borghi et al. (2016) investigou a percepção dos produtores e concessionárias de serviços sobre as tecnologias de AP. Os resultados sugeriram que o crescimento da AP estava atrelado aos ganhos agronômicos e econômicos observados no campo, apesar de que, em algumas situações, os agricultores não conseguiam medir o impacto real da tecnologia no sistema produtivo. Além disso, a dificuldade de utilização de softwares e

equipamentos da AP, decorrentes da falta de capacitação técnica das equipes de campo, poderiam ser fatores que limitaram o aumento da adoção (BORGHI et al., 2016).

O estudo de Bolfi et al., (2020) realizou uma survey com 504 agricultores brasileiros sobre as tecnologias digitais em uso, bem como os benefícios percebidos e os desafios. Os resultados constataram que 84% dos agricultores entrevistados utilizam pelo menos uma tecnologia digital em seu processo produtivo. Ao passo que o principal benefício percebido foi o aumento de produtividade, enquanto os principais desafios apontados foram a ausência de conectividade e os custos de aquisição de máquinas, equipamentos e softwares (BOLFI et al., 2020).

Portanto, dada a relevância do Brasil no agronegócio mundial, identifica-se a importância de pesquisas que abordem a agricultura digital no Brasil. Além disso, é evidente que apesar da constatação de alguns estudos que abordam o assunto, pouco se sabe sobre a dinâmica do processo de adoção e a aceitabilidade das tecnologias digitais no Brasil.

2.2. ADOÇÃO DE TECNOLOGIAS: CONCEITOS E MODELOS

Neste subcapítulo, são apresentados os principais conceitos básicos de aceitabilidade e adoção de novas tecnologias. Em um primeiro momento, buscou-se definir os fundamentos básicos. Em seguida, são apresentados os processos de aceitabilidade e adoção de novas tecnologias na agricultura. Finalmente, são apresentados alguns fatores determinantes de tecnologias no contexto agrícola.

2.2.1. Conceitos básicos e fundamentos teóricos de adoção de novas tecnologias

A tecnologia visa melhorar uma determinada situação ou alterar o *status quo* para um nível mais desejável (ROGERS, 1995). Freeman e Perez (1988) afirmam que elas são elementos principais para modificar um sistema econômico de uma sociedade. Além disso, permitem ao usuário trabalhar “de modo mais fácil” do que faria na ausência da tecnologia, portanto, ajuda a economizar tempo e trabalho (BONABANA-WABBI, 2002).

Para que uma tecnologia tenha impacto positivo sobre o sistema econômico, é necessário que seja integrada à rotina normal do sistema onde ela está presente, modificando-o positivamente (FREEMAN; PEREZ, 1988). Isso pressupõe superar a incerteza associada às novas tecnologias (ROGERS, 1995). Portanto, não é surpresa que pesquisadores se proponham a estabelecer quais são os fatores facilitadores (se forem potencializadores) de adoção de tecnologias e como podem ser eliminadas as barreiras de rejeição à sua adoção e uso (BONABANA-WABBI, 2002).

Ao longo dos anos, muitos estudos foram realizados sobre inovação e aceitação de novas tecnologias em diversas áreas da ciência (MWANGI; KARIUKI, 2015). A adoção de uma tecnologia refere-se à aceitação de um grupo ou indivíduo para usar um novo produto ou inovação (DOBRE; DRAGOMIR; PREDA, 2009). Entretanto, cabe ressaltar, que apesar de diferentes definições, os conceitos de aceitação e aceitabilidade são, usualmente, tratados como sinônimos na literatura (ACOSTA SALGADO, 2021)

A aceitabilidade visa prever o comportamento dos futuros usuários, a fim de limitar os riscos de rejeição e garantir o sucesso de projetos de inovação (BOBILLIER-CHAUMON; DUBOIS, 2009). Ao passo, que a aceitação é associada a percepção do usuário na etapa de comercialização e uso do produto acabado, levando em consideração fatores subjetivos e a experiência dos usuários (ACOSTA SALGADO, 2021).

Ao começar a utilizar uma tecnologia, em qualquer contexto, é determinante a percepção do usuário quanto às características referentes à sua utilidade e à facilidade de uso para que ela seja adotada definitivamente. Isso porque é por intermédio de tal percepção que se passa a reconhecer o seu valor e, então, tomar a decisão entre a sua adoção ou rejeição (MIN; JI; QU, 2008). Para Oye, Iahad e Ab-Rahim (2014), caso o usuário não perceba vantagens ao adotar uma tecnologia, ela pode ser considerada sem valor. Logo, a literatura sobre adoção apresenta vários elementos-chave que determinam a adoção ou rejeição de uma tecnologia.

Nos últimos anos, o aumento do grau de complexidade e funcionalidades das tecnologias lançadas no mercado, trazem a necessidade de os consumidores aprenderem novas competências para utilizar uma tecnologia (MIN; JI; QU, 2008). Assim, para o sucesso de novos produtos, é necessário a assimilação e aceitação dessas novas informações pelos usuários. Esse fenômeno é subjetivo e ocasionado por diversas variáveis que afetam a experiência e a percepção do usuário (SAAKSJARVI, 2003).

Os estudos relacionados à adoção de inovação tecnológica abrangem duas categorias principais de usuários consumidores: indivíduos e organizações. O trabalho de Woodside e Biemans (2005) demonstrou as diferenças entre a adoção de tecnologia nos níveis individual e organizacional. A pesquisa demonstrou que a adoção de tecnologia é um processo mais complexo e de evolução gradual em organizações como: hospitais, militares ou grandes empresas. Por isso, os usuários têm propensão maior a visualizar problemas que a tecnologia pode causar no ambiente. Por outro lado, os usuários individuais compram para si e suas expectativas são altas em termos de desempenho e utilidade do produto.


Cabe ressaltar que na agricultura há uma mescla das duas categorias. Estudos de administração rural evidenciam que o processo de tomada de decisão de adoção de tecnologias recai sobre o agricultor, que planeja e executa ao mesmo tempo (CARRIERI, 1992). Segundo Lima (2005), o agricultor reconhece a realidade da sua propriedade frente a cadeia produtiva que está inserido, lhe conferindo uma racionalidade própria para a tomada de decisão, condicionada por um ambiente físico, social, político e econômico.

Um grupo de autores sugere que a adoção passa por estágios que levam a aceitação de uma tecnologia ou a sua rejeição (MIN; JI; QU, 2008; SAAKSJARVI, 2003). Rogers (1995) conceitua cinco estágios no processo de adoção que são: conhecimento, persuasão, decisão, implementação e confirmação. A primeira etapa, o conhecimento, ocorre quando uma pessoa descobre a existência da inovação e obtém algumas informações sobre ela. A persuasão acontece quando uma pessoa forma uma atitude positiva ou negativa em relação à inovação. A etapa de decisão ocorre quando o usuário toma a decisão a partir do envolvimento estabelecido,

podendo levar à adoção ou rejeição. A decisão de adoção leva a fase de implementação, quando uma pessoa faz uso da tecnologia. Já a confirmação sucede quando o usuário repensa a decisão de adoção, por exemplo, ao ser exposto a informações contraditórias sobre a inovação ou ao avaliar os resultados da sua aceitação. Nesta fase, a pessoa ainda pode optar por adotar a inovação ou rejeitá-la (ROGERS, 2003).

Em contrapartida, a literatura mais recente sugere que esses estágios podem ocorrer simultaneamente e alguns podem ou não ocorrer nos processos de decisão de adoção (MIN; JI; QU, 2008). O ciclo temporal também influencia neste processo. Parte da literatura sugere que muitas inovações requerem um período de muitos anos, desde o momento em que se tornam disponíveis até o momento em que são amplamente adotadas (LIONBERGER et al., 1960). O tempo médio entre a informação inicial e a adoção final varia consideravelmente de acordo com a pessoa, o lugar e a tecnologia (NORTON; ALSTON; PARDLEY, 1995). A Figura 5 mostra a forma que a maioria dos processos de adoção tomam durante o tempo.

Figura 5 - Curva de adoção de Rogers.



Fonte: Rogers (1995).

A curva de adoção de Rogers (1995) define as categorias de adotantes como uma classificação dos indivíduos dentro de um sistema social com base em sua capacidade de inovação. Segundo o autor, os indivíduos variam muito com relação à sua disposição para adotar uma determinada inovação. Eles são divididos em inovadores, adotantes iniciais, maioria inicial, maioria tardia e retardatários.

Os inovadores e adotantes iniciais seriam os indivíduos que adotam a tecnologia imediatamente após seu lançamento, correspondendo a uma baixa porcentagem do sistema social. Após os investimentos em comercialização e propaganda, a adesão à tecnologia aumenta pela maioria (inicial e depois a tardia) até ocorrer a estabilização da aceitação. Por fim, os retardatários

adotam deixando assim a tecnologia de ser caracterizada como uma novidade (ROGERS, 1995).

2.2.2. O processo de aceitabilidade e adoção de novas tecnologias na agricultura

Os estudos sobre os modelos e o processo de aceitação, adoção e difusão de tecnologias na agricultura são realizados desde a década de 1940, sendo os estudos de Ryan e Gross (1943), Griliches (1957) e Rogers (1962) considerados os pioneiros. Feder *et al.* (1982), levando em consideração os diferentes participantes, escala tecnológica e tempo na produção agrícola, dividiu as adoções em três categorias: adoção individual no nível da fazenda versus adoção no nível total, adoção divisível versus indivisível e adoção de uso único versus adoção em toda a produção.

Feder, Just e Zilberman (1985) definiram a adoção de tecnologia individual em nível de fazenda como a extensão em que uma nova tecnologia é usada por um produtor, por um período de longo prazo, a partir de informações completas sobre a nova tecnologia e seu potencial. Logo, a informação sobre a existência de (novas) tecnologias agrícolas é um pré-requisito, evidentemente, para a adoção de uma tecnologia (ROGERS, 1962).

Segundo Adesina e Zinnah (1993) existem três grupos de paradigmas que buscam explicar as decisões de adoção e difusão de tecnologias, a saber: i) Modelos de inovação-difusão ii) Modelos de restrição econômica; e iii) Modelos de percepção do adotante. O primeiro grupo é decorrente do trabalho de Rogers (1962) e enfoca seus estudos na importância do acesso à informação sobre uma inovação dos potenciais usuários finais, pois esse seria o fator-chave para a adoção e, conseqüentemente, a difusão de uma inovação.

O segundo grupo contempla os estudos sobre os impactos das restrições econômicas como determinantes do comportamento de adoção. Segundo Adesina e Zinnah (1993) padrões assimétricos de distribuição de recursos (acesso a crédito, capital, insumos) restringiram a rápida adoção de tecnologia.

O último paradigma aborda a percepção do adotante e sugere que os atributos percebidos das inovações condicionam comportamento de adoção (ADESINA; ZINNAH, 1993). Os primeiros trabalhos desse grupo adicionaram uma variável de percepção, junto aos modelos criados, visando identificar se ela seria um condicionante para a decisão de adoção (ADESINA; ZINAH, 1993; GOULD; SAUPE; KLEMME; 1989).

Os estudos do terceiro grupo indicaram que os aspectos psicossociais e a percepção do produtor sobre a tecnologia, apesar de serem menos tangíveis, é um condicionante de adoção de tecnologia na agricultura (GOULD; SAUPE; KLEMME; 1989). Assim, alguns atributos importantes da tecnologia, tais como: facilidade de uso, experimentação, vantagem relativa em relação às tecnologias existentes, seriam fatores que afetariam a adoção de tecnologias (ROGERS, 2003).

Mais recentemente, estudos incluíram o aprendizado e a relação com as novas tecnologias nas categorias de fatores que determinam a adoção das tecnologias (UAIENE; ARNDT; MASTERS, 2009). Segundo Loevinsohn et al. (2013), às decisões dos agricultores “Acerca da possibilidade de adotar” e como adotar novas tecnologias agrícolas, são condicionadas pela interação dinâmica entre as características da própria tecnologia e a variedade de condições e circunstâncias do agricultor e do ambiente.

Por isso, os benefícios potenciais de uma nova tecnologia só podem ser percebidos quando ela é compreendida pelo usuário, as decisões de adoção requerem uma comparação rigorosa dos benefícios e custos percebidos associados à tecnologia (UAIENE, 2011). Entretanto, vale ressaltar, que o processo de adoção é dinâmico, tanto da perspectiva do agricultor individual quanto em termos da difusão de novas tecnologias ao longo do tempo e do espaço (FEDDER; JUST; ZILBERMAN, 1985; UAIENE; ARNDT; MASTERS, 2009).

Rogers (1962) descreve a difusão como o processo pelo qual uma inovação é comunicada através de certos canais ao longo do tempo entre os membros do sistema social. No contexto da agricultura o processo de difusão é definido como a disseminação de uma nova tecnologia em um determinado local, podendo ser mensurado pelo nível de uso em uma determinada área geográfica ou população (VICENTE, 1998).

A própria difusão resulta de uma série de decisões individuais para começar a usar a nova tecnologia, decisões que muitas vezes são o resultado de uma comparação dos benefícios incertos da nova invenção com os custos incertos da sua adoção (HALL; KHAN; JONES, 2002). Por isso, segundo os autores, uma compreensão dos fatores que influenciam essa escolha é essencial tanto para os economistas que estudam os determinantes do crescimento, quanto para os geradores e disseminadores de tais tecnologias.

Outro fator relevante é o tempo de adoção. Potencialmente, os adotantes iniciais teriam a maior parte dos benefícios de uma nova tecnologia em relação aos adotantes posteriores (ROGERS, 2003). Além disso, em muitos casos, a vontade e a capacidade de adotar novas tecnologias, o peso relativo dos fatores de adoção e as necessidades de suporte associadas à implementação da tecnologia podem mudar com o tempo (BONABANA-WABBI, 2002).

De acordo com Ugochukwu e Philips (2018), uma tecnologia será assimilada e implementada quando os benefícios da implementação forem percebidos rapidamente. Muito embora, dada a vasta gama de tecnologias disponíveis, a incerteza de seus efeitos e o contexto da política e do mercado, o agricultor tem dificuldade em decidir em qual tecnologia investir (TEY; BRINDAL, 2013). Por isso, para compreender melhor o papel que uma nova tecnologia desempenha, é necessário compreender os fatores importantes que podem afetar a adoção da tecnologia (UGOCHUKWU; PHILIPS, 2018).

2.2.3. Fatores determinantes de adoção de novas tecnologias na agricultura

Existe uma vasta literatura sobre fatores que determinam a adoção de tecnologias agrícolas. Alguns estudos classificam esses fatores em diferentes categorias. Um dos primeiros a categorizar foi Nowak (1987) agrupando-os em informacionais, econômicos e ecológicos. Kebede et al. (1990) classificaram os fatores que influenciam a adoção de tecnologias nas categorias: social, econômica e física, enquanto McNamara, Wetzstein e Douce (1991) rotularam os fatores em características do agricultor, estrutura da fazenda, características institucionais e estrutura gerencial. Posteriormente, Wu e Babcock (1998) os classificaram em capital humano, produção, políticos e recursos naturais.

Mais recentemente, Souza Filho et al. (2011) classificam os fatores em quatro categorias: condições socioeconômicas e características do produtor, características da produção e da propriedade rural, características da tecnologia e fatores sistêmicos. Akudugu et al. (2012) agruparam determinantes da adoção da tecnologia agrícola em três categorias: fatores econômicos, sociais e institucionais.

Embora existam muitas categorias para agrupar os determinantes da adoção da tecnologia, não há um recurso distintivo claro entre as variáveis em cada categoria. A categorização é feita para se adequar à tecnologia atual sendo investigada, ao local e às preferências do pesquisador, cada qual com suas especificidades (BONABANA-WABBI, 2002). Por exemplo, o nível de educação de um agricultor foi classificado como capital humano por alguns pesquisadores, enquanto outros o classificaram como um fator específico da família (TEY; BRINDAL, 2013; MELESSE, 2018).

A categoria de fatores mais recorrente nas revisões de literatura são os fatores socioeconômicos. Eles referem-se ao histórico pessoal do principal tomador de decisões da

fazenda (TEY; BRINDAL, 2013). As variáveis mais recorrentes identificadas na literatura são: educação, idade, experiência, hábito e tamanho da propriedade.

Presume-se que a educação do agricultor tenha uma influência positiva na decisão dos agricultores de adotar novas tecnologias. Pessoas com alto nível de escolaridade podem aumentar a difusão de inovações e, potencialmente, adotar novas tecnologias antes dos menos educados, pois possuem mais conhecimento e podem acessar facilmente as informações necessárias para tomar uma decisão de adoção antecipada (UGOCHUKWU; PHILIPS, 2018). No contexto da agricultura digital, agricultores com melhor educação percebem maiores vantagens na coleta de dados por meio de novos softwares e tecnologias (KRUMPEL, 2019). No estudo de Rose et al. (2016), a análise estatística revelou um efeito positivo significativo da educação, sugerindo que aqueles com maior grau de instrução acharam um software agrícola mais útil.

A idade do agricultor tem um efeito variável na decisão de adotar tecnologias agrícolas (PIERPAOLI, 2013). Em alguns casos, a idade mais jovem foi reconhecida como relevante para adoção (UGOCHUKWU; PHILIPS, 2018). Por outro lado, alguns autores observaram que a diferença entre a idade dos adotantes e não adotantes é inconsistente, mesmo que significativa (ANSELMINI, 2012). Finalmente, em alguns casos, a idade está positivamente ligada ao uso de tecnologias agrícolas, indicando que os agricultores mais velhos têm maior probabilidade de adotar novas tecnologias (PIERPAOLI, 2013). No contexto de tecnologias digitais, gerações mais novas podem estar mais propensas à adoção.

A experiência do produtor e os seus hábitos possuem relação positiva com a adoção de tecnologias, conforme demonstram Khanna (2001), Melo (2008) e Araújo et al (2010). Para Antolini (2015), a experiência do produtor possibilita maior entendimento das melhores decisões a serem tomadas para o seu negócio, propiciando o tempo necessário para que uma nova adoção de tecnologia se prove.

Ao passo que os hábitos desempenham um papel significativo na adoção, pois os agricultores que estão acostumados a utilizar tecnologias, irão adotar as novas tecnologias mais rapidamente em sua rotina (TEY; BRINDA, 2013). De acordo com o estudo de Rose et al. (2016), a ausência de hábitos pode criar uma aversão a tecnologia e, provavelmente, é um dos fatores mais difíceis de superar, pois um posicionamento contrário, não seria revertido por uma melhoria no *design* ou sistema da tecnologia (ROSE et al., 2016).

O tamanho da propriedade também é um determinante recorrente na literatura na adoção de tecnologias (AKUDUGU et al., 2012). A adoção de uma inovação tende a ocorrer mais cedo em propriedades maiores, pois em pequenas propriedades grandes custos fixos se tornam uma

restrição à adoção de tecnologias, especialmente se ela requerer uma quantidade substancial de custo inicial de implementação (MWANGI; KARIUKI, 2015). O estudo de Rose et al. (2016) identificou que fazendas maiores eram mais propensas a adotar sistemas de gerenciamentos e *softwares* agrícolas.

O tipo de produção também é um fator relevante. Em produções altamente especializadas, com valor agregado e maior renda, assim como em unidades agrícolas intensivas, as inovações tecnológicas estão mais presentes ou são passíveis de adoção (PIGNATTI; CARLI; CANAVARI, 2015). Souza Filho et al. (2011) afirmam que o sucesso de uma tecnologia agrícola depende da sua adequação e compatibilidade com as condições do tipo de cultura e do sistema de produção escolhido. Assim, os demais fatores importantes para adoção são apresentados no modelo proposto por este estudo.

2.3. MODELOS DE ADOÇÃO DE TECNOLOGIAS

As teorias de aceitação e adoção de tecnologia possuem raízes nas áreas de psicologia, sociologia e sistemas de informação (VENKATESH, 2003). Os estudos tiveram início na década de 1980 quando as empresas começaram a investir valores consideráveis em recursos tecnológicos e, mesmo assim, em alguns casos, os usuários não aderiram às novas tecnologias. Dessa forma, os estudos buscavam compreender os fatores que levavam um indivíduo a adotar ou não uma tecnologia e quais variáveis influenciavam essa decisão (DAVIS; BAGOZZI; WARSHAW, 1989).

Os estudiosos se dividiram em duas escolas de pensamento: as que concentraram seus estudos na intenção do **comportamento** do indivíduo frente às novas tecnologias e as que direcionaram seus esforços para entender a **atitude** do indivíduo perante elas (DAVIS; BAGOZZI; WARSHAW, 1992). As escolas geraram uma série de modelos teóricos, que competem entre si, cada um com um conjunto diferente de determinantes que procuram responder se um indivíduo aceita ou não, uma nova tecnologia (DAVIS; BAGOZZI; WARSHAW, 1989).

Baseados em uma ampla revisão da literatura, Venkatesh et al. (2003) propuseram a Teoria Unificada de aceitação e uso da tecnologia (*Unified Theory of Acceptance and Use of Technology* - UTAUT), que faz uso de constructos e moderadores de oito modelos diferentes: Teoria da Ação, Teoria do Comportamento Planejado, Modelo de Aceitação Tecnológica, Combinação dos modelos TAM e TPB; Modelo de Utilização do PC; Teoria da Difusão da Inovação e Teoria Social Cognitiva.

O modelo UTAUT explicou 70% da variação na intenção comportamental, que é considerado um aprimoramento significativo em relação aos oito modelos originais, que haviam conseguido um potencial máximo próximo de 40% (VENKATESH et al., 2003). Estudos posteriores apontaram que a validade e a confiabilidade das medidas do UTAUT são confiáveis, fazendo-o um modelo amplamente reconhecido e utilizado (THOMAS et al., 2014).


Para compreensão do UTAUT é necessário conhecer como os modelos que o compõem evoluíram ao longo dos anos e quais são os constructos dependentes e independentes usados na previsão, explicação e compreensão da aceitabilidade e adoção de novos produtos ou tecnologias pelas pessoas. Na próxima seção são descritos os oitos modelos que deram base ao UTAUT e no final, é apresentado um resumo com ênfase nas diferenças entre os vários modelos.

2.3.1. Teoria da Ação Racionalizada

O primeiro modelo comportamental conhecido foi a Teoria da Ação Racionalizada (*Theory of Reasoned Action* - TRA), desenvolvida por Ajzen e Fishbein (1969). O modelo foi originalmente usado no campo de pesquisa em psicologia social e desenvolvido para prever o comportamento voluntário das pessoas. Segundo Ajzen (1985) a teoria deriva do fato de que as pessoas se comportam de maneira sensata e racional, mantendo em mente as informações internas e externas ao decidir se devem ou não agir.

Para o autor, o pressuposto é de que o comportamento é alicerçado em dois constructos: “Norma Subjetiva”, que avalia a opinião das pessoas sobre o comportamento e “Intenção em Relação ao Comportamento”, que leva em consideração as crenças e valores do indivíduo para realizar o comportamento. A Figura 6 ilustra o modelo TRA.

Figura 6 - Modelo da Teoria Racionalizada (TRA).



Fonte: Fishbein e Ajzen (1969).

O modelo era amplo e visava explicar qualquer tipo de comportamento humano, sendo base para outros modelos, como o TAM e o UTAUT, entretanto, foi objeto de diversas críticas pela sua generalidade (DAVIS, 1985). Além disso, Ajzen (1985) observou que a teoria era limitada pois se aplicava apenas ao comportamento que é conscientemente pensado de antemão. Decisões irracionais, ações habituais ou qualquer comportamento que não fosse adotado de forma consciente e racional, não eram explicadas pelo modelo. Devido às limitações do TAM,


Ajzen (1985) criou posteriormente o modelo teórico conhecido como a Teoria do Comportamento Planejado (TCP).

2.3.2. Teoria do comportamento planejado

O modelo da Teoria do Comportamento Planejado (*Theory of Planned Behavior* - TPB), desenvolvida por Ajzen (1985), é uma extensão da teoria da ação racional e, de forma semelhante ao modelo original, tem como fator central a intenção do indivíduo de adotar um determinado comportamento.

Foi incluído o constructo “Controle comportamental percebido” para explicar o comportamento que Ajzen (1985, pág. 148) define como "um construto hipotético que, inacessível à observação direta, deve ser inferido a partir de respostas mensuráveis". Logo, o TPB também inclui ações sem o controle volitivo de uma pessoa, mas que pode ser medido ou previsto de alguma forma. A Figura 7 ilustra o TPB.

Figura 7 - Modelo da Teoria do Comportamento Planejado (TPB).



Fonte: Ajzen (1985).


2.3.3. Modelo de aceitação tecnológica

O Modelo de Aceitação da Tecnologia (*Technology Acceptance Model* – TAM) foi desenvolvido por Davis (1985) a partir do modelo TRA. O modelo é voltado para a área de tecnologia da informação e busca explicar quais determinantes levam uma pessoa a aceitar ou

rejeitar uma tecnologia. Contudo, o TAM não inclui o constructo “Normas subjetivas” e o constructo “Atitude” do TRA como determinante para adoção de uma tecnologia.

O diferencial do TAM frente ao TRA é o constructo “Variáveis Externas” que é composto por particularidades da tecnologia e do ambiente em que ela é ofertada como: características dos sistemas, processo de desenvolvimento, treinamento para uso, etc. (DIAS, ZWICKER e VICENTIN, 2003). A partir desse constructo são avaliados os impactos na “Utilidade Percebida” e “Facilidade de uso percebida” pelo usuário, atuando como determinante da intenção de uso e esta, por sua vez, funciona como mediadora do uso de uma tecnologia (DAVIS, 1985). A Figura 8 ilustra o TAM.

Figura 8 - Modelo de Aceitação Tecnológica (TAM).



Fonte: Davis (1985).

Não obstante os avanços do TAM para adoção de tecnologias, a teoria desconsidera outros fatores que podem influir sobre a intenção de uso, como aspectos da realidade organizacional (facilitando ou dificultando a intenção de adoção), liberdade de uso da tecnologia para alguns usuários e falta de orientações como facilitador da adesão (VENKATESH; DAVIS; MORRIS, 2007). Com isso, o avanço das pesquisas envolvendo o TAM e suas limitações identificadas, fizeram com que o modelo ganhasse extensões, como o TAM2 e o TAM3.

Na primeira extensão, os autores acrescentaram construtos voltados a influência social e aspectos cognitivos (VENKATESH. DAVIS, 2000). Enquanto, na segunda foram adicionados os constructos: Normas Subjetivas, Imagem, Relevância ao Trabalho, Qualidade do Trabalho, Demonstrabilidade de Resultado, Usabilidade Percebida e Facilidade de Uso, Ansiedade, Controle Externo Percebido, Diversão, Usabilidade Objetiva e Prazer (VENKATESH; DAVIS; MORRIS, 2007).


2.3.4. Teoria da difusão da inovação

Para compreender a Teoria da Difusão da Inovação (*Innovation Diffusion Theory- IDT*), instituída por Rogers (1962), é necessário compreender o conceito de difusão e inovação. Difusão é um processo no qual uma inovação é comunicada por meio de certos canais ao longo do tempo entre os membros de um sistema social. Por sua vez, a inovação é definida como uma ideia, prática ou objeto que é percebido como novo por um indivíduo ou outra unidade de adoção.

O objetivo da IDT é fornecer a indivíduos de qualquer disciplina interessada na difusão de uma inovação, um paradigma conceitual para entender o processo de difusão e mudança social (MD NOR; PEARSON; AHMAD, 2010). A teoria da difusão da inovação fornece conceitos bem desenvolvidos e um grande corpo de resultados empíricos aplicáveis ao estudo de avaliação, adoção e implementação de tecnologia, além de ferramentas, quantitativas e qualitativas, para avaliar a taxa provável de difusão de uma tecnologia, identificando numerosos fatores que facilitam ou dificultam a adoção e implementação (FICHMAN, 1992).

Para Rogers (2003) a taxa de adoção é a velocidade relativa com a qual uma inovação é adotada por membros de um sistema social, geralmente medida pelo número de indivíduos que adotam uma nova ideia em um período de tempo especificado. Em outras palavras, é um indicador numérico da inclinação da curva de adoção para uma inovação.

A partir da definição anterior de difusão, Rogers (2003) apontou cinco variáveis que vão definir a taxa de difusão de uma tecnologia sendo: (1) atributos da inovação (2) canais de comunicação (3) tempo (4) sistema social e (5) esforço promocional. O modelo de taxa de difusão de uma tecnologia está ilustrado na figura 9.

Figura 9 - Modelo de Taxa de Difusão de uma Tecnologia.

Fonte: Rogers (2003).

Por fim, cabe ressaltar, que os atributos de inovação respondem pela maior variabilidade da taxa de adoção (49-87%), e as percepções dos indivíduos sobre os atributos de uma inovação ou agentes de mudança afetam a taxa de adoção (ROGERS, 2003). Os cinco atributos percebidos da inovação são inter-relacionados empiricamente, mas cada um é conceitualmente distinto (AGARWAL; KARAHANA, 2000).

2.3.5. TAM e TPB combinados


Como o nome indica, TAM e TPB combinados, trata-se de um modelo que combina o Modelo de Aceitação de Tecnologia e o Modelo de Comportamento Planejado. Taylor e Todd (1995) o criaram para compensar as limitações do modelo TAM, que não possui constructos referentes a fatores sociais, o que pesquisas posteriores comprovaram que têm um efeito moderador no comportamento.

O Modelo C-TAM-TPB, demonstrado na Figura 10, combina os três preditores do TPB com o constructo “Utilidade percebida” do TAM para fornecer um modelo híbrido” (VENKATESH et al., 2003, p. 429). Outra característica é que o modelo distingue entre usuários experientes e inexperientes (TAYLOR; TODD, 1995).

O estudo de Taylor e Todd (1995) revelou que o C-TAM-TPB explica 60% da variação relacionada à intenção comportamental de usuários inexperientes e 43% da variação

relacionada à intenção comportamental de usuários experientes. Logo, o maior poder de previsão da teoria relacionado ao comportamento real para usuários experientes pode indicar que a experiência anterior influenciou a intenção comportamental.

Figura 10 - Modelo de Taxa de Difusão de uma Tecnologia.




Fonte: Taylor e Todd (1995).

2.3.6. Modelo de utilização de PC

O Modelo de Utilização de Computador Pessoal (*Model of Personal Computer Utilization - MPCU*) é baseado na teoria do comportamento humano criada por Triandis (1977), sendo semelhante ao TRA. O modelo MPCU difere na maneira como o modelo faz uma distinção entre elementos cognitivos e afetivos das atitudes. A intenção comportamental tem um papel central e consiste em atitudes, normas sociais, hábitos e a consequência esperada do comportamento.

De acordo com o modelo (Figura 11) existem seis componentes que influenciam a intenção comportamental, a saber: adequação da função, complexidade do uso, consequências de longo prazo, influencia no uso, fatores sociais e condições facilitadoras (THOMPSON; HIGGINS; HOWELL, 1991).

Figura 11 - Modelo de utilização de Computador Pessoal.

Fonte: Thompson, Higgins e Howell (1991).

2.3.7. Modelo Motivacional


O Modelo Motivacional (*Motivational Model* - MM) foi desenvolvido por Davis, Bagozzi e Warshaw (1992) a partir de aspectos extrínsecos e intrínsecos da motivação, considerados pelos autores como os principais impulsionadores da intenção das pessoas em adotar um comportamento. O estudo dos autores foi sobre motivação extrínseca e intrínseca para se usar computadores no local de trabalho.

Nesta perspectiva, eles consideram que a motivação extrínseca para usar uma tecnologia no trabalho será apoiada por uma recompensa esperada ou antecipada (por exemplo, aumento ou bônus), desde que a tecnologia seja percebida como útil para alcançar esses objetivos. Por sua vez, a motivação intrínseca ao uso da tecnologia refere-se ao prazer percebido de usá-la, independentemente do resultado do desempenho que possa ser obtido (DAVIS; BAGOZZI; WARSHAW, 1992).

Os resultados evidenciaram que as intenções das pessoas de usar computadores no local de trabalho foram influenciadas principalmente por suas percepções sobre a utilidade dos computadores para melhorar seu desempenho no trabalho e, em segundo lugar, pelo grau de prazer que experimentam ao usá-los (DAVIS; BAGOZZI; WARSHAW, 1992).

No MM, demonstrado na Figura 12, os autores traduziram as motivações extrínsecas e intrínsecas, respectivamente, nos constructos “Utilidade” e “Prazer”. Além disso, para os autores, outros dois constructos “Facilidade de uso” e “Qualidade do Resultado” atuam como antecedentes dos constructos “Utilidade” e “Prazer”, sendo estas relações moderada pela “Utilidade da tarefa”. Assim, para o indivíduo a “Facilidade de uso” e a “Qualidade do resultado” somente tem um grau de importância se ele considerar a tarefa algo importante (DAVIS; BAGOZZI; WARSHAW, 1992).

Figura 12 - O Modelo Motivacional.



Fonte: Davis, Bagozzi e Warshaw (1992).

2.3.8. Teoria social cognitiva


O último modelo, que contribui para o modelo UTAUT, é a Teoria Social Cognitiva (*Social Cognitive Theory* – SCT) (BANDURA, 1986). A SCT deriva da teoria da aprendizagem social lançada pela publicação de Miller e Dollard (1941), quando eles introduziram o princípio da aprendizagem por meio de reprodução de "Modelos". Nesse sentido, Bandura (1986) descreve a reprodução do comportamento observado como uma interação entre elementos pessoais, comportamentais e ambientais. Salienta-se ainda outro conceito chave da teoria, a autoeficiência, que é definida como o auto julgamento de um indivíduo de sua capacidade, em usar uma tecnologia para realizar um determinado trabalho ou tarefa (BANDURA 1986; COMPEAU; HIGGINS, 1995).

Atualmente, existem diversas versões de modelos baseados no SCT, entretanto, todos compartilham três princípios básicos: (1) As consequências das respostas, como recompensa e

punição, influenciam o comportamento de um indivíduo; (2) Aprendizagem é observacional, logo as pessoas podem aprender observando os outros, além de aprender participando pessoalmente de um ato; (3): Indivíduos modelam seu comportamento, por meio da observação de outros indivíduos com quem se identificam ou são emocionalmente apegados (COMPEAU; HIGGINS, 1995).

Os autores Compeau e Higgins (1995) buscaram compreender os aspectos sobre a autoeficácia e a expectativa do resultado sobre o uso de computadores. Os constructos “Encorajamento por outros”, “Uso dos outros” e “Suporte” como elementos do ambiente, conforme demonstrado na Figura 13. O constructo “Uso” é o objetivo final como elemento do comportamento. E os demais constructos são elementos dos indivíduos que vão afetar as expectativas e o uso do computador.

Figura 13 - Modelo da Teoria Social Cognitiva (SCT).



Fonte: Compeau e Higgins (1995).

Dessa forma, após apresentado os oito modelos, o Quadro 4 resume as principais características dos modelos teóricos utilizados na composição do UTAUT.

Quadro 4 - Principais características de Modelos que embasaram a criação do UTAUT.


Modelo	Sigla	Nível de Análise	Fatores dependentes principais	Fatores independentes principais	Autores
Teoria da Ação Racionalizada (<i>Theory of Reasoned Action</i>)	TRA	Individual	- Intenção comportamental- Comportamento	- Atitude em relação ao comportamento - Norma subjetiva	Fishbein (1967); Ajzen e Fishbein (1973); Fishbein e Ajzen (1975)
Modelo de Aceitação de Tecnologia (<i>Technology Acceptance Model</i>)	TAM	Individual	- Intenção comportamental de uso - Uso do sistema	- Utilidade percebida - Facilidade de uso percebida - Norma subjetiva (somente em TAM2)	Davis (1986); Davis (1989)
Modelo Motivacional (<i>Motivational Model</i>)	MM	Individual	- Intenção comportamental	- Motivação extrínseca - Motivação intrínseca	Vallerand (1997)
Teoria do Comportamento Planejado (<i>Theory of Planned Behavior</i>)	TPB	Individual	- Intenção comportamental	- Atitude em relação ao comportamento - Norma subjetiva - Controle comportamental percebido	Ajzen (1985; 1991)
Combinação TAM e TPB (<i>Combine TAM and TPB</i>)	C-TAM-TPB	Individual	- Uso comportamental	- Atitude em relação ao comportamento - Norma subjetiva - Controle comportamental percebido - Utilidade percebida	Taylor e Todd (1995)
Modelo de Utilização de Computador Pessoal (<i>Model of PC Utilization</i>)	MPCU	Individual	- Intenção comportamental	- Adaptação ao trabalho - Complexidade - Consequências a longo prazo - Influência no uso - Fatores sociais - Condições facilitadoras	Thompson et al. (1991)
Teoria da Difusão da Inovação (<i>Innovation Diffusion Theory</i>)	IDT	Grupo, empresa, indústria, sociedade	- Sucesso na implementação ou adoção de tecnologia	- Vantagem relativa - Facilidade de uso - Visibilidade - Demonstração de resultados - Imagem e compatibilidade	Lazarsfeld et al. (1949); Rogers (1962); Rogers e Shoemaker (1971); Rogers (1995)
Teoria Social Cognitiva (<i>Social Cognitive Theory</i>)	SCT	Individual/Grupo	- Aprendizagem-Mudança de comportamento	- Expectativas de resultados desempenhados - Expectativas de resultados pessoais - Auto-eficácia - Afeto e ansiedade	Bandura (1986)

Fonte: Adaptado de Birsch (2009).

2.3.9. O Modelo da Teoria Unificada de aceitação e uso da tecnologia (UTAUT)

O UTAUT, conforme mencionado anteriormente, foi introduzido por Venkatesh et al. (2003) como resultado da revisão e unificação das oito teorias existentes de aceitação da tecnologia do usuário. Para atingir esse objetivo, os autores: (1) revisaram a literatura de aceitação do usuário e discutiram os oito modelos anteriormente abordados, (2) compararam empiricamente os oito modelos e suas extensões, (3) formularam um modelo unificado que integra elementos dos oito modelos e (4) validaram empiricamente o modelo unificado (VENKATESH et al. 2003). O modelo estrutural UTAUT é apresentado na Figura 14.

Figura 14 - Modelo UTAUT.



Fonte: Venkatesh et al. (2003).

O modelo UTAUT possui quatro constructos principais: “Expectativa de desempenho (ED)”, “Expectativa de esforço (EE)”, “Influência social (IS)” e “Condições facilitadoras (CF)”, detalhados na próxima seção. No modelo, três construtos são determinantes diretos da intenção comportamental (IC) de adotar uma tecnologia (com 70% de variação na intenção, estando praticamente nos limites da literatura relacionada) e um construto (Condições Facilitadoras) é determinante direto do comportamento uso (CO) da tecnologia (VENKATESH et al., 2003). Ele também possui quatro variáveis (“Gênero”, “Idade”, “Experiência” e “Voluntariedade”) que atuam como moderadores, afetando os principais relacionamentos do modelo (VENKATESH et al., 2003). Resumindo, a estrutura fornece uma possibilidade não apenas de

examinar as relações entre as construções no modelo, mas também de explorar seus efeitos combinados ao comportamento de um usuário com uma tecnologia.

As pesquisas baseadas no UTAUT mostraram que gênero, idade, experiência e voluntariedade têm um efeito moderador no comportamento em ambientes voluntários. Em contextos obrigatórios, a influência dos quatro elementos é mais relevante, enquanto a internalização e identificação associadas à experiência são mais relevantes em contextos voluntários (VENKATESH et al., 2003). Quanto ao gênero, mulheres são mais sensíveis às opiniões dos outros, bem como, as pessoas de maior idade. Além disso, os usuários são mais responsivos quando têm pouca experiência com um comportamento; o que, neste caso, significa utilizar uma certa tecnologia de uma certa maneira (VENKATESH, et al., 2003).

Uma revisão de literatura permitiu identificar trabalhos que utilizaram o modelo UTAUT para estudar a aceitabilidade e adoção de tecnologias agrícolas em diversos países. O Quadro 5 dispõe um resumo de cada estudo e na sequência eles são detalhados.

Quadro 5- Estudos de adoção utilizando o UTAUT na Agricultura.

Autores	Modelo	Local	Objeto de estudo	Análise dos Dados
Bakar et al. (2020)	UTAUT e TCP	Malásia	Tecnologias pós-colheita	Estatísticas Descritiva
Michels, Bonke e Mußhoff (2019)	UTAUT	Alemanha	Aplicativos de proteção de culturas	MEE e Modelo logit
Mahamood et al. (2016)	UTAUT e TDI	Malásia	Tecnologias de comunicação	Análise Fatorial e Regressão
Ronaghie Forouharfar (2020)	UTAUT	Irã	<i>Internet of Things</i>	MEE
Chhachhar, Chen e Jin (2016)	UTAUT	Paquistão	Celulares	Análise Descritiva e Correlação de Pearson
Aribe Jr et al. (2019)	UTAUT e Modified Waterfall Model (MWM)	Filipinas	Aplicativo de Android	Entrevistas
Diekmann e Theuvsen (2019)	UTAUT2	Alemanha	CSA	MEE
Ibrahim, Hassan e Gusau (2018)	UTAUT	Malásia	TICs	Análise Fatorial e MEE
Islam e Grönlund (2011)	UTAUT e RUTAM	Bangladesh	Celulares	Análise de Frequência e Análise de Conteúdo
Kahenya, Sakwa e Iravo (2014)	UTAUT	Quênia	TICs	Análise de Correlação
Rusere et al. (2020)	UTAUT	África do Sul	Tecnologias de intensificação ecológica	Grupo Focal
Wu (2012)	UTAUT	China	Sistema de Informações	MEE
Lee e Heo (2020)	UTAUT	Córea do sul	Drones	AFE
Beza et al. (2018)	UTAUT2	Etiópia	SMS móvel	MEE
Mulugo et al. (2020)	UTAUT	Uganda	Materiais de plantio de banana	MEE
Nampijja e Birevu (2016)	UTAUT	Uganda	M-Learning	Grupo Focal
Narine, Harder e Roberts (2019)	UTAUT	Trinidad	SMS móvel	Regressão logística
Nejadrezaei et al. (2018)	UTAUT	Irã	Irrigação pressurizada	MEE
Rose et al. (2016)	UTAUT	Reino Unido	Ferramentas de suporte a decisão	Análise de Conteúdo

Fonte: Elaborado pelo autor.

O estudo de Chhachhar, Chen e Jin (2016) foi realizado com agricultores no Paquistão e buscou identificar a intenção de comportamento e o efeito do uso de celulares com finalidade agrícola, como o uso para o marketing e informações meteorológicas. O resultado indicou correlação positiva dos quatro construtos originais do UTAUT com a intenção de utilizar celulares.

Entretanto, a maioria dos agricultores não utilizava o telefone celular em seus locais de trabalho, devido a falta de cobertura de acesso à internet.

Por outra perspectiva, o trabalho de Aribre Jr. et al. (2019) buscou desenvolver um aplicativo móvel para sistema Android, chamado Ma-Ease, para atender as necessidades dos produtores de milho na Filipinas. O estudo foi feito em parceria com o Departamento da Agricultura da Filipinas combinando o UTAUT com o método *Modified Waterfall Model* (MWM) para o desenvolvimento do aplicativo. Os testes de eficácia foram feitos por meio de entrevistas com os agricultores e sua interação e envolvimento com o produto acabado, sendo ao fim, o vsesoftware formalmente aceito e recomendado para uso e implantação pelo governo.

Na Alemanha, Diekmann e Theuvsen (2019) entrevistaram 1.139 consumidores sobre o interesse de participar de *Community Supported Agriculture* (CSA). Os resultados revelaram que a expectativa de esforço e - surpreendentemente - a expectativa de desempenho, associadas ao CSA, inibem a adoção ao fenômeno. Por outro lado, os resultados indicam que a motivação hedônica dos consumidores, seus pares sociais, seus hábitos e interesses pessoais na agricultura orgânica, têm uma influência positiva no interesse dos consumidores pela CSA.

Na pesquisa de Ibrahim, Hassan e Gusau (2018) foram identificados os fatores que afetam a adoção e o uso de Tecnologias de Comunicação e Informação (TICs) por Pequenas e Médias empresas (PMEs) agrícolas na Malásia. A pesquisa constatou que a Expectativa de Desempenho, a Gestão criativa e inovadora e o Tamanho da organização influenciam significativamente o uso de inovações tecnológicas. Ademais, as PMEs alocam tempo, esforço e recursos para questões empresariais com bom custo-benefício e, portanto, não priorizavam a adoção das TICs, a menos que isso oferecesse ganhos reais.

Islam e Grönlund (2011) investigaram os fatores de adoção de celulares entre os agricultores em Bangladesh. Com base no UTAUT e em outros modelos de aceitação, os autores desenvolveram o modelo de Aceitação de Tecnologia Rural (RUTAM) pertinentes ao contexto de um país rural em desenvolvimento. Com base em uma série de modelos de aceitação da literatura, um modelo conceitual de Aceitação de Tecnologia Rural (RUTAM) foi desenvolvido para analisar os argumentos pertinentes ao contexto de um país rural em desenvolvimento. Os autores adicionaram três constructos (Promoção de serviço técnico, Fatores Externos e “Fatores Individuais”) como antecedentes da intenção de adoção. Os resultados apontaram que a Influência Social é um fator com maior influência, em comparação com os modelos anteriores, e desempenha um papel maior nos estágios iniciais de adoção.

O estudo de Kahenya, Sakwa e Iravo (2014), realizado no Quênia, teve como objetivo investigar os fatores que influenciam o uso de TICs por funcionários de extensão agrícola do governo. O

modelo de pesquisa explicou 56% da variação no uso de TICs pelos extensionistas, e apontou correlações fortes entre Expectativa de desempenho, Condições Facilitadoras e Expectativa de esforço no uso de TICs.

Por meio de uma abordagem qualitativa, o estudo de Rusere et al. (2020) avaliou a intenção comportamental de agricultores sul-africanos de aceitação e utilização de tecnologias de intensificação ecológica. Foram realizados grupos focais com 97 agricultores familiares em diferentes regiões. Os resultados indicaram uma gama de oferta de tecnologias, mas com uma baixa adesão e aceitação, devido à falta de conscientização, de conhecimento das necessidades do local e de suporte técnico.

O estudo de Wu (2012) buscou identificar a utilização de um sistema de informação agrícola (Tobacco) por agricultores da província de Ghuizou na China. O “Tobbacco” é um equipamento terminal especialmente concebido para os agricultores obterem informações sobre o tabaco, principal cultura de fonte de renda de agricultores da região. Foram coletados 288 questionários e os resultados indicaram que os quatros constructos do UTAUT original influenciam a adoção do sistema.

Na pesquisa de Lee e Heo (2020) foi adicionado o constructo “Benefícios percebidos” como mediador no UTAUT, para examinar os fatores que afetam a intenção comportamental para o serviço de drones agrícolas na Coreia do Sul. Os resultados da pesquisa tiveram efeitos positivos sobre os benefícios percebidos e a intenção comportamental para o serviço de drones agrícolas.

Beza et al. (2018) explorou a aceitação da tecnologia de *Short Message Service* (SMS) móvel por pequenos agricultores na Etiópia. Os resultados demonstraram que as intenções de adotar a tecnologia SMS móvel para o fornecimento de informações agrícolas foram confirmadas pela Expectativa de desempenho, Expectativa de Esforço, Custo e a Confiabilidade.

Na Uganda, Mulugo et al. (2020) buscaram identificar os fatores de aceitação de tecnologia que influenciam as intenções dos agricultores de usar materiais de plantio de cultura de tecido de banana no controle da espécie de banana *Xanthomonas Wilt*. Para isso, o UTAUT foi estendido e adicionado o constructo Perfil Inovador. Os resultados mostraram que as intenções do agricultor em usar materiais de plantio de cultura de tecidos dependem de dois construtos: Influência social e Perfil inovador.

No estudo de Nampijja e Birevu (2016) na Uganda foram realizados estudos de caso múltiplos com agricultores utilizando o UTAUT, com o objetivo de identificar a intenção de adoção de tecnologias móveis para aprendizado (M-learning). Os resultados indicaram que a Influência

social é um fator chave para adoção da tecnologia, bem como as Condições Facilitadoras do ambiente.

O trabalho de Narine, Harder e Roberts (2019) explorou a disposição dos agricultores de usar mensagens de texto móveis para interações bidirecionais com oficiais de extensão do governo em Trinidad. Para isso, foram coletados dados de 200 agricultores trindadenses e os dados foram analisados por regressão logística. As descobertas mostraram influência positiva dos constructos do UTAUT na intenção de usar mensagens de texto móveis e disposição dos agricultores de se comunicar com os extensionistas por meio de mensagens de texto.

A pesquisa de Krumpel (2019) teve como objetivo encontrar fatores de influência para o uso de smartphones para gerenciamento de dados e informações pelos agricultores. O autor utilizou uma revisão de literatura para gerar um modelo adaptado do UTAUT. As principais constatações foram de que Condições Facilitadoras (recursos como um dispositivo móvel, Internet e conhecimento) têm o impacto mais significativo para adoção. A Expectativa de Desempenho também tem um impacto significativo, entretanto, o constructo da expectativa de esforço, não foi significativo.

Um trabalho realizado no Irã por Nejadrezael et al. (2018) identificou os fatores que afetam a adoção da tecnologia de irrigação pressurizada entre os olivicultores. Foram coletados dados de 210 gerentes de fazendas de oliva. Os achados apontaram uma relação significativa entre Expectativa de desempenho e Influência social com a intenção de comportamento. Além disso, as condições facilitadoras tiveram relação significativa com o comportamento de uso.

Em seu estudo, Rose et al. (2016) modificaram o UTAUT para investigar o uso da tecnologia de ferramentas de suporte à decisão por agricultores britânicos. A variável moderadora de voluntariedade foi removida do modelo e foram adicionados novos constructos. Por meio de entrevistas qualitativas, os resultados apontaram que quinze fatores são influentes para convencer os agricultores e consultores a usar ferramentas de apoio à decisão, entre eles: usabilidade, custo-benefício, desempenho, relevância para o usuário e compatibilidade.

Nota-se que apesar da aplicação do modelo UTAUT em diferentes países, nenhum estudo foi aplicado no Brasil. Os autores Rose et al. (2016) apontam a importância de estudar tecnologias digitais no contexto de países em desenvolvimento.


3 MODELO TEÓRICO PROPOSTO

A discussão teórica que foi construída a partir da revisão de literatura sobre os modelos de adoção de tecnologias e fatores que influenciam a adoção e o uso de tecnologias no contexto da agricultura fundamenta o modelo conceitual proposto para esta pesquisa. Para Kerlinger (1980), modelos teóricos são tentativas de explicar um fenômeno por meio de variáveis formuladas de modo sistemático.

A estrutura do modelo proposto é baseada nos constructos do modelo UTAUT, com o diferencial da inclusão de variáveis consideradas determinantes de adoção no contexto da agricultura tradicional, bem como fatores que podem afetar a adoção das tecnologias no contexto da agricultura digital. Tais relações serão justificadas doravante.

O modelo é composto pelos constructos principais: Expectativa de Desempenho, Expectativa de Esforço, Influência Social (IS), Condições Facilitadoras (CF), Custo Percebido (CP) e Pressão Externa (PE). As seguintes variáveis de controle foram consideradas: idade, educação, experiência e hábito, tamanho da propriedade e tipo de cultura. Os construtos acima mencionados são visualizados no quadro conceitual desenhado na Figura 15. Na próxima seção são explicados os constructos e definidos as hipóteses de pesquisa.

Figura 15 - Modelo da Pesquisa.



Fonte: Elaborado pelo autor.

3.1. Expectativa de Desempenho

A Expectativa de Desempenho é definida como o grau em que um indivíduo acredita que usar uma tecnologia o ajudará a obter ganhos no desempenho no trabalho (VENKATESH et al., 2003). Ele é o constructo central que determina a adoção de novas tecnologias no modelo UTAUT e tem um efeito positivo na intenção comportamental de um indivíduo de usar uma tecnologia (VENKATESH et al., 2003). Diversos estudos confirmam que é um dos constructos mais influentes em relação à intenção comportamental (ARFI et al., 2020; SLADE et al., 2015; WILLIAMS; RANA; DWIVEDI 2014).

A ED é reconhecida de maneira diferente em diversas teorias de adoção de tecnologias, e pode ser medida por: Utilidade percebida (TAM, C-TAM-TPB), Motivação extrínseca (MM), Adequação ao trabalho (MPCU), Vantagem relativa (IDT) e Expectativas de resultado (SCT) (VENKATESH et al., 2003). No contexto dessa pesquisa, a ED irá avaliar se os agricultores percebem que as tecnologias digitais contribuem para a realização de tarefas e a obtenção de ganhos de produtividade.

O trabalho de Rose et al., (2016) ressalta que se um agricultor não “percebe um benefício” então é provável que a tecnologia não seja usada. Segundo os autores, a adoção da nova tecnologia será facilitada pela percepção de utilidade em uma tarefa ou possíveis lucros ou economias que ela possa gerar. Pierpaoli et al. (2013), por meio de uma revisão da literatura, identificaram que o aumento da produtividade é a principal motivação para os agricultores implementarem tecnologias de AP.

Da mesma forma, Spaulding, Tudor e Mahatanankoon. (2015) descobriram que as expectativas de desempenho influenciam positivamente o uso contínuo de dispositivos móveis na agricultura. Na Alemanha, Bonke et al. (2018) demonstraram um efeito positivo nas expectativas dos agricultores alemães de que aplicativos de smartphones para proteção de culturas possam reduzir efeitos negativos e custos ambientais externos. Além disso, os resultados demonstraram uma disposição dos agricultores em pagar um prêmio (valor superior), caso esta tecnologia ofereça uma performance superior.

Concomitantemente, outros trabalhos destacaram a importância da ED na adoção de novas tecnologias e serviços digitais, como: *Smart home* (BAUDIER; AMMI; DEBOEUF-ROUCHON, 2020), *IoT* (MITAL et al., 2018), *M-commerce* (CHONG; CHAN; OOI, 2012) e *Blockchain* (ALAZAB et al. 2020). Por isso, defende-se que na medida em que os agricultores percebem a tecnologia digital como sendo melhor do que o uso da tecnologia precursora, eles

estarão suscetíveis a ter intenções positivas de uso da tecnologia. Portanto, pode-se enunciar a primeira hipótese da tese:

H1: A expectativa de desempenho influencia positivamente a intenção comportamental dos agricultores de utilizarem FMIS.

3.2. Expectativa de Esforço

A Expectativa do Esforço (EE) é definida como o grau de facilidade associado ao uso de uma tecnologia (VENKATESH et al., 2003). Assim, sua finalidade é identificar se o usuário percebe a tecnologia como algo que facilita suas tarefas, fator que irá influenciar sua intenção comportamental positivamente (VENKATESH; THONG; XU, 2012). Venkatesh (2003) elaborou esse constructo a partir das variáveis oriundas de outros modelos: Facilidade de uso percebida (TAM/ TAM2); Complexidade (MPCU) e Facilidade de uso (TDI).

Estudos anteriores afirmaram que a Expectativa de Esforço é um determinante significativo das intenções comportamentais em relação às tecnologias (DAVIES; BAGOZZI; WARSHAW, 1989; FOON; FAH, 2011). No contexto deste estudo, a Expectativa de Esforço mede a facilidade associada ao uso dos FMIS pelos agricultores. Para que elas sejam utilizadas, os usuários precisam perceber que são fáceis de usar e livres de esforço físico ou mental (VENKATESH, 2003).

Estudos apontam que algumas tecnologias digitais possuem uma interface “não intuitiva” ou excessivamente complicada (HABERLI; OLIVEIRA; YANAZE, 2017; ROSE et al., 2016). Além disso, algumas incluem muitos recursos quando comparados às necessidades reais dos agricultores, tornando-as difíceis de implementar, entender e usar (VERDOUW; ROBBEMOND; WOLFERT, 2015).

Um exemplo foi o trabalho de Rose et al. (2016) que realizou entrevistas qualitativas com os agricultores na Inglaterra. Os agricultores enfatizaram que tecnologias para smartphone com fins agrícolas devem ser simples e fáceis de usar. Da mesma forma, Michels, Bonke e MUßHOFF (2019) mostraram que a facilidade de uso percebida pelos produtores de leite tem um efeito positivo na frequência do uso de aplicativos para smartphones de gerenciamento de rebanhos leiteiros.

Além disso, a tecnologia deve: gerar informações fáceis de entender; fornecer dados instantâneos; ser mais fácil de usar do que as soluções existentes e ajustável para fins específicos

da fazenda (ROSE et al., 2016; ROSE; CHILVERS, 2018). Então, neste estudo, presume-se uma relação positiva entre a Expectativa de Esforço e a Intenção comportamental de adoção das tecnologias digitais por parte dos agricultores. Esses fatores levam à segunda hipótese:

***H2:** A expectativa de esforço (facilidade de uso) para usar a tecnologia influencia positivamente a intenção comportamental dos agricultores de utilizarem FMIS.*

Venkatesh et al. (2003) definem a Influência Social (IS) como o grau em que um indivíduo acredita que pessoas importantes em seu ambiente acreditam que ele deve usar uma nova tecnologia para a realização de uma tarefa. Logo, o comportamento do indivíduo é influenciado pela maneira como ele acredita que os outros os julgarão por usar a tecnologia (VENKATESH, 2003). Nesse sentido, este fator representa uma maneira de conquistar reconhecimento ou status social (VENKATESH et al., 2003; VENKATESH; THONG; XU, 2012).

Este fator é advindo das seguintes variáveis: Norma Subjetiva (TRA, TAM2, TPB e C-TAM/TPB) Fatores sociais (MPCU) e Imagem (IDT). Estudos apontam que a Influência social tem maior relevância quando a adoção da tecnologia acontece de modo mandatório (AGARWAL; PRASAD, 1997; VENKATESH; THONG; XU, 2012). Em ambientes de adoção voluntária, o efeito é mais sensível e vai diminuindo com o conforme o passar do tempo (VENKATESH; DAVIS, 2000)

No contexto deste estudo, o constructo é definido como o grau em que os agricultores percebem que pessoas importantes acreditam que eles devem usar uma tecnologia específica (VENKATESH et al., 2012). O pressuposto subjacente desse constructo é que os indivíduos tendem a consultar sua rede social, especialmente amigos e familiares, sobre novas tecnologias e podem ser influenciados pela percepção da pressão social (VENKATESH et al., 2003).

Agricultores pertencentes a um grupo social aprendem uns com os outros os benefícios e o uso de uma nova tecnologia, sendo mais sujeitos a adotar uma nova tecnologia segundo o comportamento do próprio grupo (MWANGI; KARIUKI, 2015). Além disso, estudos anteriores de tecnologias de PA, atribuem um papel importante à troca de informações e experiências entre os agricultores contribuindo para o aumento do capital social (KUCZERA, 2006; MIGNOUNA et al., 2011; MWANGI; KARIUKI, 2015; WALTON et al., 2010).

O estudo de Manson et al. (2014) demonstrou que a participação do produtor em organizações, como associações e cooperativas de produtores, influencia positivamente na adoção de tecnologias da AP. Em outro estudo, Michels, Bonke e Mußhoff (2019) ficou demonstrado a importância da opinião dos pares frente a uma nova tecnologia. Os resultados apontaram que

se os pares de um agricultor acreditarem que os aplicativos para smartphones são benéficos, ele é mais suscetível a adotá-la.

Estudando o efeito de uma organização de produtores de banana no Uganda, Katungi e Akankwasa (2010) descobriram que os agricultores que participaram mais ativamente da organização, se envolveram em aprendizado social sobre a tecnologia, aumentando assim sua probabilidade de adotá-la. Assim, a recomendação por pares pode ajudar a espalhar a mensagem sobre a disponibilidade e a utilidade de uma tecnologia, o que pode, por sua vez, encorajar a aceitação (ROSE et al., 2016). Esses fatores levam a terceira hipótese:

H3: A influência social influencia positivamente a intenção comportamental dos agricultores de utilizarem FMIS.

3.3. Condições facilitadoras

As Condições Facilitadoras são o grau em que um indivíduo acredita que existe uma infraestrutura e fácil acesso aos recursos necessários para a utilização de uma nova tecnologia (VENKATESH et al., 2003). Isso está relacionado com uma infraestrutura técnica e um ambiente tecnológico que colabore removendo as restrições para utilização de uma nova tecnologia (CABRERA-SANCHEZ; VILLAREJO-RAMOS, 2019).

Elas são favoráveis quando há fácil acesso aos recursos necessários para a utilização de uma nova tecnologia e o suporte subsequente (VENKATESH et al., 2003). Em estudos posteriores, utilizando o UTAUT2, Venkatesh et al. (2012) descobriram que esse construto tem um efeito significativo sobre a intenção comportamental de usar uma nova tecnologia.

Este construto capta conceitos incorporados por três variáveis diferentes: Controle comportamental percebido (TPB, C-TAM-TPB), Condições facilitadoras (MPCU) e Compatibilidade (IDT). No presente estudo, as condições facilitadoras são definidas como o grau em que um agricultor percebe uma infraestrutura institucional e acesso a recursos para adoção de tecnologias digitais.

San Martín e Herrero (2012) apontam que o aspecto subjacente a esse construto é a inclusão de perspectivas tecnológicas e do ambiente organizacional que estariam disponíveis para apoiar a adoção de adotar uma tecnologia ou diminuir as barreiras à adoção. No caso dos agricultores, para impulsionar um comportamento de uso de uma tecnologia, requisitos básicos de infraestrutura de tecnologia da informação devem estar disponíveis de forma adequada (KYOBE, 2011).

Simultaneamente, a falta desses requisitos seria uma barreira para a adoção e implementação bem-sucedidas de tecnologias digitais, especialmente fatores como: indisponibilidade de internet em áreas rurais, largura de banda de internet limitada, eletricidade, assistência técnica, entre outros (SOUZA FILHO et al., 2011; TEY; BRYNDAL, 2012).

A literatura sobre a adoção mostra que uma infraestrutura tecnológica suficiente na propriedade estimula os agricultores a adotar tecnologias agrícolas (MICHELS; BONKE; MUßHOFF, 2019). O estudo de Rose et al. (2016) demonstrou que o acesso ruim (móvel) à internet pode resultar em um descompasso entre a ferramenta (tecnologia) e o fluxo de trabalho do agricultor. Além disso, segundo os autores, a conexão perdida pode limitar o acesso dos agricultores ao banco de dados para recuperar as informações necessárias.

Outro fator relevante é a compatibilidade. A diversidade de softwares e hardwares de tecnologias digitais foi analisada como um fator significativo na adoção de novas tecnologias em um estudo de adoção de tecnologias digitais em organizações agrícolas na Coreia do Sul (YOON; LIM; PARK, 2020). Especialmente porque elas podem diferir na medida em que são compatíveis e gerar problemas relacionados à interoperabilidade ou integração do sistema entre seus componentes, o que dificultaria a “intercambialidade” entre aplicativos e plataformas, reduzindo sua aplicabilidade e, portanto, a futura adoção dessa tecnologia (KRUIZE et al., 2016).

Corroborando, o estudo de Rosskopf e Wagner (2003) apontou que um requisito importante expresso por alguns agricultores é a possibilidade de adaptar e/ou integrar softwares novos e antigos. Kruize et al. (2016) ressalta que questões de compatibilidade estão ligadas aos padrões de dados, uma vez que a falta de protocolos de troca de dados em toda a indústria causa dificuldades na troca de dados entre sistemas. Além disso, uma integração fácil de uma nova tecnologia aumenta a probabilidade de adoção (PIGNATTI; CARLI; CANAVARI, 2015).

Por fim, estudos utilizando o UTAUT, apontaram que as Condições facilitadoras afetam também positivamente o Comportamento de Uso (RONAGHI; FOROURHARFAR, 2020; WILLIANS; RANA; DWIVEDI, 2015). Esses fatores nos levam a construção de duas hipóteses:

H4: *As condições facilitadoras influenciam positivamente a intenção comportamental dos agricultores de utilizarem FMIS.*

H5: *As condições facilitadoras influenciam positivamente o comportamento de uso dos agricultores de utilizarem FMIS.*

3.4. Custo Financeiro Percebido

O custo financeiro percebido é definido como o grau em que um usuário acredita que tem disponibilidade financeira para adquirir uma tecnologia (LUARN; LIN, 2005; SRIPALAWAT; THONGMAK; NGRAMYARN, 2011). Para Premkumar, Ramamurthy e Crum (1997) o custo percebido se refere a todos os tipos de gastos incorridos pelas empresas para a adoção de novas tecnologias, como equipamentos de *hardware*, *software* e gastos com integração de sistemas. Estudos apontam que a variável do custo financeiro percebido tem um efeito adverso na intenção de adoção de novas tecnologias (CHONG; CHAN, 2012; TU, 2018). Logo, os indivíduos podem relutar em adotar a tecnologia se acharem que a adoção custaria uma grande quantia ou ocasionaria um fardo financeiro (RECKER, 2016).

No contexto deste estudo, o custo financeiro percebido é definido como o grau em que um agricultor acredita que tem disponibilidade financeira para arcar com os custos financeiros da aquisição e manutenção de uma tecnologia digital. Em um mercado agrícola em que a margem bruta e a lucratividade estão ficando mais apertadas, os agricultores procuram tecnologias que reduzam os custos sem diminuir a produção (ABDULLAHI; MAHIEDDINE; SHERIFF, 2015).

Um determinante chave da adoção de uma nova tecnologia é o ganho líquido para o agricultor com a adoção, incluindo todos os custos de uso da nova tecnologia (FOSTER; ROSENZWEIG, 2010). Yoon, Lim e Park (2020) evidenciaram que o custo financeiro pode ser um fator de decisão importante para pequenas empresas agrícolas, onde a introdução de fazendas inteligentes será um investimento de custo relativamente alto. Os resultados do estudo mostraram que o custo financeiro afeta negativamente a adoção de fazendas inteligentes nas organizações agrícolas coreanas. Em geral, inovações com grandes custos de transação fixos têm menos probabilidade de serem adotadas por fazendas menores (PIVOTO, 2018).

O estudo de Rose et al. (2016) mostrou que mesmo uma pequena quantia de dinheiro poderia inibir o uso de aplicativos móveis por agricultores ingleses, pois mesmo pequenos custos poderiam ser um fardo significativo para pequenas propriedades. Para Anselmi (2012) o principal para viabilizar o crescimento da adoção, é reduzir os custos de aquisição das máquinas e equipamentos, para que elas ofereçam maior rentabilidade e mais vantagens relativas. Kaloxyloset al. (2014) corroboram relatando que algumas preocupações sobre o custo de outras tecnologias de agricultura inteligente relacionadas à sua implementação, podem ser ainda mais proibitivos no caso de pequenos proprietários agrícolas. Muangprathub et al. (2019) relatam

que para implementação de dispositivos IoT, outros custos são necessários, como: software de processamento de dados, custos de aprendizagem e manutenção.

Steenefeld et al. (2015) demonstraram que após o investimento em sensores e sistemas de ordenha automática (AMS) na Holanda, os custos de capital totais aumentaram significativamente de € 9,72 para € 13,97 por 100 kg de leite. Esse aumento foi devido ao crescimento significativo na depreciação de edifícios e despesas com máquinas e equipamentos digitais.

Um estudo realizado por Makokha et al. (2001) sobre os determinantes do uso de fertilizantes e esterco na produção de milho no Quênia, relataram alto custo de mão-de-obra e outros insumos como uma das principais restrições à adoção de fertilizantes. Pivoto (2018) aponta que a tendência é o surgimento de um setor de serviços (ou seja, um serviço de crédito ou um consultor) que pode transformar uma tecnologia indivisível em uma divisível, como ocorreu com a AP.

O custo da mão-de-obra contratada também foi relatado por O'Grady e O'Hare (2017) como um dos outros fatores que restringem a adoção de tecnologias digitais. Supõe-se que a mão de obra não atrapalhe a adoção da agricultura digital, porque geralmente é realizada por empresas especializadas de TI (YOON; LIM; PARK, 2020).

Por fim, Recker (2016) relata que percepções negativas dos custos de uso podem ter uma influência negativa no comportamento de uso de uma tecnologia. Esses fatores levam às seguintes hipóteses:

H6: *O custo percebido influencia negativamente a intenção comportamental dos agricultores de utilizarem FMIS.*

H7: *O custo percebido influencia negativamente o comportamento de uso de FMIS pelos agricultores.*

3.5. Pressão externa

A pressão externa se refere ao grau em que um setor ou parceiros de negócios influenciam a adoção de uma nova tecnologia (PREMKUMAR; RAMAMURTHY; CRUM, 1997; TU, 2017). Para Matta, Koonce e Jeyaraj (2012) esse fator contempla a influência dos parceiros da cadeia de abastecimento, a competição social externa e outros ambientes sociais de uma organização.

Nesta pesquisa, a pressão externa se refere ao grau em que o setor agrícola e o ambiente em que o agricultor está inserido influenciam a adoção de tecnologias. O advento da Agricultura digital modificou os processos e atividades de todas as organizações participantes da cadeia agroindustrial (PIERPAOLI et al., 2013; YOON; LIM; PARK, 2020). Isso ocorre porque as organizações da cadeia de suprimentos estão tipicamente inseridas em uma rede de relacionamentos de parceria e são impactadas pelas estratégias e práticas de suas organizações parceiras (LAMBERT; COOPER; PAGH, 1998).

O estudo de Yoon, Lim e Park (2020) identificou que os agricultores percebem uma pressão externa em direção a uma mudança para um ambiente digital, o qual estabelece uma necessidade do uso da internet e de tecnologias de informação avançadas na agricultura. Segundo os autores, com o advento da quarta revolução industrial e o surgimento de fazendas inteligentes baseadas em tecnologias de informação, a percepção dos agricultores é a da inevitabilidade do uso de tecnologias de informação de alta tecnologia no campo.

No estudo de Hossain e Quaddus (2010) foram estudados os fatores de demanda e da pressão do mercado que levaram a adoção de tecnologia de Identificação por Radiofrequência (RFID) por agricultores australianos. Os resultados apontaram que muitos dos entrevistados percebiam uma pressão externa pela adoção que emanava de vários *stakeholders* e do ambiente de negócios da organização.

No trabalho de Annosi et al (2018) foi realizado uma *survey* com gestores de pequenas e médias empresas agrícolas na Itália acerca da percepção subjetiva sobre as tecnologias digitais. Os resultados demonstraram que pressões externas, como serviços de aconselhamento negocial, são mais relevantes do que preocupações econômicas ou a crença de que a tecnologia possui um custo-benefício positivo.

Portanto, são propostas a oitava e a nona hipóteses:

H8: A pressão externa influencia positivamente a intenção comportamental dos agricultores de utilizarem FMIS.

H9: A pressão externa influencia positivamente o comportamento de uso de FMIS pelos agricultores.

3.6. Intenção Comportamental

A Intenção Comportamental é definida como o grau de prontidão dos indivíduos para agir de acordo com o comportamento esperado. Segundo TAM e TPB, é o principal construto que leva uma pessoa a realizar um comportamento de uso de uma tecnologia (DAVIS et al., 1989). Os principais modelos de aceitação tecnológica (TRA, TPB, TAM, UTAUT) apontam para uma relação direta entre intenção comportamental e uso de tecnologias (DAVIS, 1985; AJZEN, 1985; VENKATESH et al., 2003, 2012).


Como um modelo psicológico, o comportamento individual é previsível e influenciado pela intenção comportamental individual (YU, 2012). Assim, esta pesquisa propõe a seguinte hipótese:

H10: A intenção comportamental influencia positivamente o comportamento de uso de FMIS pelos agricultores.

4 MÉTODO

Neste capítulo serão apresentados os aspectos metodológicos seguidos nesta tese. A elaboração foi composta por três etapas até a obtenção dos resultados, a saber: (i) Revisão Bibliográfica (ii) Elaboração do modelo e (iii) Aplicação da *survey*. Os detalhes de cada etapa são descritos nessa seção. A Figura 16 apresenta as etapas da pesquisa.

Figura 16 - Etapas da Pesquisa.



Fonte: Elaborado pelo autor.

4.1. Delineamento da pesquisa

Para Wilson (1995) o delineamento da pesquisa é o plano, estruturado e organizado, usado como guia para realização de uma pesquisa. Para o autor, um bom delineamento compreende escolhas fundamentadas e lógicas que darão suporte ao pesquisador durante todas as etapas. Malhotra (2006) compreende que existem três concepções básicas de pesquisa: exploratória, descritiva e causal. A pesquisa exploratória tem por objetivo descobrir ideias e percepções acerca de um fenômeno. A descritiva, por sua vez, busca descrever as características ou funções desse fenômeno. Por fim, a causal, visa determinar relações de causa e efeito. Esta pesquisa pode ser caracterizada como descritiva, pois busca identificar quais percepções e opiniões estão

latentes em um determinado grupo, além de ser operacionalizada pela formulação prévia de hipóteses específicas e pela concepção pré-planejada de um modelo estruturado (MALHOTRA, 2006).

Quanto a abordagem, segundo Creswell e Creswell (2017), uma pesquisa pode ser classificada como:

- **Quantitativa** - é uma abordagem para testar teorias objetivas examinando a relação entre as variáveis. Essas variáveis, por sua vez, podem ser medidas, normalmente em instrumentos, de forma que dados numerados possam ser analisados por meio de procedimentos estatísticos. Nesse cenário, o pesquisador testa uma teoria especificando hipóteses restritas e a coleta de dados para apoiar ou refutar as hipóteses. Um desenho experimental é usado em que as atitudes são avaliadas antes e depois de um tratamento experimental. Os dados são coletados em um instrumento que mede atitudes ou percepções, e as informações são analisadas por meio de procedimentos estatísticos e teste de hipóteses.
- **Qualitativa** - é uma abordagem para explorar e compreender o significado que indivíduos ou grupos atribuem a um problema social ou humano. O processo de pesquisa envolve questões e procedimentos emergentes, dados normalmente coletados no ambiente do participante, análise de dados construindo indutivamente de particulares a temas gerais, e o pesquisador fazendo interpretações do significado dos dados.
- **Mista** - é uma abordagem de investigação envolvendo a coleta de dados quantitativos e qualitativos, integrando as duas formas de dados e usando dados distintos que podem envolver suposições filosóficas e estruturas teóricas. O pressuposto central desta forma de investigação é que a combinação de abordagens qualitativas e quantitativas fornece uma compreensão mais completa de um problema de pesquisa do que qualquer abordagem sozinha.

Tendo em vista o problema de pesquisa, os objetivos do trabalho e seu caráter descritivo, a abordagem ideal foi a quantitativa. Inicialmente, foi realizada uma revisão da literatura sobre os modelos e fatores de adoção de tecnologias por agricultores, apontados no referencial teórico. A revisão da literatura identifica e organiza os conceitos relevantes, permitindo: i) apoiar a identificação de um tópico de pesquisa, questão ou hipótese; ii) identificar a literatura para a qual a pesquisa fará uma contribuição e contextualizar a pesquisa dentro dessa literatura, e; iii) construir uma compreensão dos conceitos teóricos e terminologia (ROWLEY; SLACK, 2004). Além disso, a revisão permitiu coletar dados secundários que dessem suporte à proposição das hipóteses de pesquisa e construção do modelo (apresentados anteriormente) a partir de estudos prévios (COOPER; SCHINDLER, 2003). Na sequência foi realizada uma pesquisa de levantamento do tipo *survey*.

4.2. O método Survey

Uma *survey* tem por objetivo a obtenção de informações de indivíduos sobre si mesmos ou sobre a unidade social a que pertencem (FORZA, 2002; MALHOTRA, 2006). É um método flexível, utilizado para uma vasta gama de tópicos, muito comum em pesquisas relacionadas às ciências sociais aplicadas (FOX; HUNN; MATHERS, 2009).


O processo de amostragem desse método permite determinar informações sobre grandes populações com um nível conhecido de precisão, sendo obtidas por meio de perguntas, estruturadas ou semiestruturadas (FORZA, 2002). Além disso, por meio da *survey* é possível comparar dados entre subconjuntos da amostra. Entre as vantagens de se optar pela *survey*, pode-se apontar: (i) sua versatilidade, uma vez que é possível identificar diversos tipos de dados, (ii) custo baixo, por meio de ferramentas digitais é possível contactar uma grande amostra, (iii) ampla cobertura geográfica, (iv) extrair conclusões, acerca de relações causa-efeito por meio de estatística inferencial (FORZA, 2002; MALHOTRA, 2006; MIGUEL; HO, 2010).

Por outro lado, como desvantagem do método, pode-se apontar as dificuldades dos respondentes em compreender determinadas perguntas. Por isso, Cooper e Schindler (2003) sugerem a elaboração de um questionário bastante simples, com vocabulário usual do perfil da amostra e enxuto.

Forza (2002) classifica o método *survey* em três tipos: exploratório, descritivo e explanatório. A *survey* tipo exploratória é utilizada nos estágios iniciais de um fenômeno, com o objetivo de fornecer subsídios para estudos mais específicos. A descritiva, por outro lado, busca identificar características do fenômeno e descrever a sua distribuição em uma população. Por fim, a explanatória busca confirmar uma teoria e buscar definir seus limites e restrições.

De acordo com o objetivo dessa tese, pode-se enquadrar essa *survey* como explanatório, devido a intenção de testar ligações hipotéticas de causalidade, identificadas na literatura, a partir da criação de um modelo. Quanto ao horizonte temporal, a coleta de dados foi feita em um único momento, podendo ser categorizada como corte-transversal (*cross-sectional*) (SAUNDERS; LEWIS; THORNHILL, 2009). Para garantir a confiabilidade do conteúdo da pesquisa, foi seguido as etapas do protocolo sugerido por Forza (2002), ilustrado na Figura 17.

Figura 17 - Protocolo de uma survey.



Fonte: Adaptado de Forza (2002).

4.3. Operacionalização da survey

Na sequência, os questionários de modelos anteriores (VENKATESH, 2003; 2007; 2012) foram traduzidos e/ou adaptados para o contexto da agricultura digital, para se adequar ao perfil da

amostra. Ressalta-se ainda, a adição de fatores de adoção de tecnologia, identificados na literatura.

O questionário foi dividido em três subseções: na primeira foram apresentadas uma breve descrição de FMIS solicitando para os respondentes identificarem quais tecnologias de gestão conheciam; na segunda seção foram apresentadas as afirmativas do questionário (Quadro 6); e por fim, na última seção foram coletados dados sociodemográficos.

Quadro 6 - Questionário da Pesquisa.

Constructo	Variável	Origem
Expectativa de Desempenho	Eu acredito que esta tecnologia será útil nas minhas tarefas diárias	Venkatesh et al (2003)
	Utilizar esta tecnologia possibilitaria eu realizar minhas tarefas diárias mais rapidamente	
	Utilizar esta tecnologia aumentaria minha produtividade	
	Se eu usasse esta tecnologia, aumentaria minhas chances de expandir minha renda bruta	
Expectativa de Esforço	Eu acredito que esta tecnologia será fácil e simples de usar	Venkatesh et al (2003)
	Acredito que será fácil para eu me tornar habilitado no uso desta tecnologia	
	Eu acredito que será fácil usar o sistema desta tecnologia	
	Aprender a utilizar esta tecnologia será fácil para mim.	
Influência Social	Outros agricultores concordam que eu deveria usar esta tecnologia	Venkatesh et al (2003)
	Familiares acham que eu deveria utilizar esta tecnologia	
	Agricultores do meu convívio, me ajudariam a usar esta tecnologia	
	Consultores técnicos me ajudariam a aprender a utilizar esta tecnologia	
Condições Facilitadoras	Eu acredito que eu tenho os recursos técnicos e ambientais (acesso e banda larga de internet) necessários para utilizar esta tecnologia.	Venkatesh et al (2003)
	Eu acredito que eu tenho o conhecimento necessário para utilizar esta tecnologia.	
	Eu acredito que esta tecnologia é compatível com outros aparelhos que utilizo na fazenda.	
	Eu acredito que consigo obter suporte para me auxiliar no uso desta tecnologia.	
Custos	Acredito que esta tecnologia tenha um preço elevado	Luar e Linn (2005) Allem e Wolfert (2011)
	Eu percebo que esta tecnologia não possui um bom custo benefício	
	Eu me endividaria caso adquirisse esta tecnologia.	
Pressão Externa	A pressão do setor e do mercado agrícola seria um fator em minha decisão de adotar esta tecnologia	Premkumaret al, (1997) Matta, Koonce e Jeyaraj (2012)
	Dependo de outras empresas e parceiros que já estão utilizando esta tecnologia.	
	Eu acredito que se adquirir esta tecnologia vou ficar mais competitivo frente a meus concorrentes	
Intenção Comportamental	Eu pretendo começar a usar esta tecnologia nos próximos meses	Venkatesh et al (2003)
	Eu acredito que usarei esta tecnologia nos próximos meses	
	Eu planejo começar a usar esta tecnologia nos próximos meses	

Fonte: Elaborado pelo autor.

Nesta pesquisa, optou-se pela aplicação do questionário presencial e por um questionário eletrônico, que foi disponibilizado em um *site* e divulgado em e-mails de cooperativas, associações e empresas com contatos de agricultores que se adequaram ao perfil da amostra esperada. Nesse tipo de *survey* autoadministradas, os respondentes decidem se vão ou não participar da pesquisa (COOPER; SCHINDLER, 2003).

Seguindo a sugestão de DeVellis (2016), o questionário foi agrupado por tópicos lógicos e organizados de modo estruturado. As perguntas do modelo são fechadas, uma vez que o objetivo do estudo era realizar testes estatísticos na amostra. Foi adotado a escala Likert de 7 pontos, usualmente utilizada em pesquisas de adoção. Para Newman (2006) a utilização de escalas é adequada quando se deseja mensurar a opinião de um indivíduo sobre determinado assunto, pois ela permite a produção de medidas quantitativas que podem ser utilizadas para testar hipóteses.

Nesse ponto, Forza (2002) aconselha a realização de um pré-teste (conforme ilustrado na Figura 18) para o refinamento do instrumento de pesquisa, da confiabilidade e dos procedimentos de aplicação. De acordo com Malhotra (2006) o pré-teste é a oportunidade que o pesquisador tem, para verificar e excluir problemas que poderiam se apresentar na aplicação definitiva do questionário, como incompreensão ou ambiguidade de algumas perguntas.

Por fim, antes da aplicação definitiva, foi realizada a definição do tamanho da amostra, por meio do software G*Power 3.1., com os parâmetros para a área de ciências sociais (RINGLE; DA SILVA; BIDO, 2014). Além disso, foram seguidas as recomendações de Hair Junior et al. (2009) que sugerem que o tamanho da amostra deve ter no mínimo 5 vezes a quantidade de variáveis incluídas na pesquisa. Neste estudo, devido à natureza dos dados que serão coletados, foram utilizadas técnicas estatísticas descritivas e multivariadas para o tratamento dos dados. As análises foram executadas com o auxílio dos softwares SPSS (*Statistical Package for the Social Sciences*), Microsoft Excel e Adanco *Composite Modeling* 2.3.

4.4. Técnica de Análise de Dados

O procedimento estatístico utilizado para análise dos dados coletados e teste das hipóteses é a Modelagem de Equações Estruturais (do inglês, *Structural Equation Modeling* ou SEM/MEE), cujo uso é recorrente nas ciências humanas e sociais aplicadas. A MEE combina dois componentes: (i) análise fatorial confirmatória que examina relações de dependência entre os construtos e seus indicadores e; (ii) análise de regressão múltipla, a qual testa relações de causalidade entre os construtos que não observados diretamente (NEVES, 2018).

Para Hair et al. (2009) a principal diferença da MEE para outras técnicas multivariadas, é a possibilidade de inclusão de constructos latentes, que são hipóteses teorizadas não observáveis diretamente, mas que podem ser medidos por meio de variáveis. Por meio da qual é possível analisar a relação entre um conjunto de variáveis preditoras e uma variável dependente,

examinando múltiplas relações de dependência entre as variáveis de um estudo simultaneamente (HAIR et al, 2009).

A abordagem PSL tem como vantagem: (i) confiabilidade em amostras menores, (ii) adequada para estudos em fenômenos recentes, (iii) possibilidade de trabalhar simultaneamente com mais de uma variável dependente (HAIR et al. (2017). Além disso, a MEE-PLS é uma técnica utilizada em diversas pesquisas que utilizam o modelo UTAUT, além de ser recomendada na literatura para modelos de aceitação e adoção (TARHINI et al. 2017; SALLOUM; SHAALAN, 2018).


Hair et al. (2010) denotam que mesmo que existam diferentes análises para os modelos utilizados na MEE, há três características que são intrínsecas a todos: (i) possibilidade de estimar as múltiplas relações dependência que estão inter-relacionadas; (ii) possibilidade de caracterizar concepções não observáveis nas relações constituídas, considerando também os erros de mensuração na estimação e; (iii) possibilidade de delinear um modelo que explique todas as relações observadas.

Hair et al. (2017) afirmam que a MEE pode ser feita por duas diferentes abordagens: a de covariância baseada (*Covariance-Based* - CB) e a de método de mínimos quadrados (*Partial Least Squares* – PLS). Nesta pesquisa, foi utilizada a abordagem PLS, que utiliza critérios de avaliação quanto a discrepância entre os valores observados nas variáveis indicadoras e os compara com os valores preditos pelo modelo em questão.

A MEE é executada por meio de duas diferentes abordagens: (a) a baseada em covariância (*Covariance-Based* - CB) que é a mais usual e; (b) método de mínimos quadrados (*Partial Least Squares* – PLS). Enquanto o método CB tem como objetivo a explicação de modelos causais, o método PLS é baseado na variância e tem por objetivo a predição (HAIR et al., 2013).

Diante da flexibilidade na distribuição dos dados, para esta pesquisa foi utilizada a abordagem PLS, a qual num primeiro momento utiliza um algoritmo iterado, delinea os segmentos do modelo de mensuração isoladamente, e em seguida, no modelo estrutural, prediz os coeficientes de caminho. Os critérios de avaliação se dão quanto à discrepância entre os valores observados nas variáveis indicadoras que são comparadas com os valores preditos pelo modelo em questão (HAIR et al., 2017).

Além disso, a abordagem PSL tem como vantagem: (i) confiabilidade em amostras menores, (ii) adequada para estudos em fenômenos recentes, (iii) possibilidade de trabalhar simultaneamente com mais de uma variável dependente (HAIR et al. (2017). As etapas seguidas são as recomendadas por Hair et al. (2016), ilustradas na Figura 18.

Figura 18 - Etapas da MEE-PLS.

Fonte: Adaptado de Hair et al. (2016).

A primeira etapa para a execução da MEE, diz respeito ao desenvolvimento de um modelo conceitual por meio da teoria – o modelo desta pesquisa foi construído com base no Modelo UTAUT e adotada variáveis consideradas determinantes no contexto da agricultura tradicional, bem como fatores que podem afetar a adoção das tecnologias no contexto da agricultura digital - que foi abordado no capítulo 3. Na segunda etapa, ocorre a representação gráfica do modelo conceitual ocorreu por meio do diagrama de caminhos, o qual apresenta por convenções, os indicadores por meio de quadrados ou retângulos, as variáveis latentes por meio de elipses ou círculos e o relacionamento entre eles por meio de setas.

As variáveis latentes são hipóteses teorizadas que não podem ser mensuradas diretamente, mas que podem ser medidas por meio de indicadores, cujo agrupamento ocorre por meio de coleta de dados. Tais variáveis, também denominadas construtos, quando influenciadas por outras variáveis latentes são classificadas como endógenas ou “dependentes”, enquanto as variáveis exógenas, ou “independentes”, são aquelas que não são influenciados por um ou mais construtos latentes (HAIR et al., 2009).

Já os indicadores se classificam em reflexivos e formativos. No caso dos indicadores reflexivos, cada indicador se refere a um efeito do construto latente, assim, o conjunto de indicadores que mensuram um único conceito fundamental, devem ser altamente correlacionados, de modo que a variação em qualquer um destes indicadores, causará uma variação nos outros indicadores.

Em contrapartida, são os indicadores formativos que causam variações nos construtos latentes, portanto, não há necessidade de apresentarem alta consistência interna (HAIR et al., 2009).

Conforme já abordado, por se originar de duas técnicas estatísticas diferentes - análise fatorial e análise de regressão - a MEE é avaliada em duas fases, terceira e quarta etapa respectivamente. A terceira etapa, denominada **avaliação do modelo de mensuração**, relaciona as variáveis mensuráveis com os construtos latentes; já a quarta etapa, denominada **avaliação do modelo estrutural**, relaciona os construtos latentes com outros construtos latentes, o que permite o tratamento separado dos modelos, além de considerar os erros de mensuração. Os subitens 4.41 e 4.42 tratam sobre os critérios utilizados para a avaliação do modelo de mensuração e do modelo estrutural, respectivamente.

Por fim, na quinta etapa ocorre a interpretação dos resultados. Nela as hipóteses, que foram apresentadas por meio do modelo teórico conceitual, foram avaliadas a partir dos resultados atingidos por meio do modelo estatístico PLS e analisados a partir da literatura. Tal avaliação foi realizada a partir dos coeficientes de caminho (β).

4.4.1. Avaliação do modelo de mensuração

Os critérios utilizados para avaliação do modelo de mensuração na abordagem PLS são consistência interna, validade convergente e validade discriminante.

4.4.1.1. Consistência interna

O objetivo da consistência interna é avaliar a confiabilidade do instrumento de medição. Para a pesquisa são considerados três critérios, que são: i) Alfa de Cronbach (α); ii) Confiabilidade composta (ρ_c) e. (iii) Dijkstra-Hensler's ρ (ρ_A). Não existe um consenso quanto ao melhor critério para mensurar a homogeneidade dos indicadores, portanto, o uso dos três critérios se justifica pela possibilidade de poder melhor avaliar a consistência interna.

Embora o Alfa de Cronbach (α) seja o critério mais amplamente utilizado, apresenta bastante sensibilidade quanto à quantidade de indicadores da escala, o que pode afetar a consistência interna. A confiabilidade composta, por sua vez, apesar de apresentar menor sensibilidade à quantidade de indicadores e considerar a correlação entre indicador e o construto, podendo até mesmo inflar a confiabilidade

Em relação aos valores de referência, por se tratar da mensuração de traços de maneira indireta, valores acima de 0,7 são considerados satisfatórios, enquanto valores acima de 0,90 indicam a possibilidade de estar sendo medido um mesmo fenômeno e valores abaixo de 0,6 apresentam baixa consistência interna.

4.4.1.2. Validade convergente

O intuito da validade convergente é assegurar que o construto explique a variância dos indicadores. Sua avaliação é realizada levando em consideração as cargas padronizadas que indicam a confiabilidade do indicador, enquanto a variância média extraída - em inglês, *Average Variance Extracted* (AVE) - diz respeito à comunalidade do construto, ou seja, o valor médio das cargas elevadas ao quadrado dos indicadores correlacionados a uma determinada variável. Os valores de referência adotados para AVE e cargas padronizadas foram de $\geq 0,5$ e $\geq 0,7$, respectivamente.

4.4.1.3. Validade discriminante

A validade discriminante é a medida que certifica que os fenômenos representados por determinado construto não são demonstrados por nenhum outro construto do modelo, sendo que a avaliação da validade discriminante ocorre nos níveis das variáveis latentes e dos indicadores. Os três critérios utilizados para avaliação da validade discriminante são: o de cargas cruzadas (*cross loadings*) Critério de Fornell-Larcker e o critério *Heterotrait-Monotrait Ratio of Correlations* (HTMT).

O critério de cargas cruzadas verifica se a carga padronizada de um determinado indicador em seu construto é maior que todas suas cargas em outros construtos. O critério de Fornell-Larcker verifica se cada variável latente possui mais variância junto a seus indicadores relacionados do que com outras variáveis latentes do modelo. Por fim, o critério HTMT verifica a correlação entre indicadores de um mesmo construto (*monotrait-heteromethod*) e também a correlação dos indicadores de um construto com indicadores de outro construto (*heterotrait-heteromethod*).

4.4.2. Avaliação do modelo estrutural

Essa etapa é realizada após o estabelecimento de um método de mensuração confiável. Nesse sentido, a avaliação do modelo estrutural ocorre por meio de quatro etapas: variância explicada

(R^2); Coeficientes de caminho (β); Coeficientes de determinação (f^2) e Relevância preditiva (Q^2).

4.4.2.1. Variância explicada

Trata-se do coeficiente de determinação R^2 , que é a medida mais utilizada para avaliação do modelo estrutural. Este coeficiente denota o quanto as variáveis exógenas explicam a variância das variáveis endógenas. O poder de predição da variável endógena, se dá pelo valor de R^2 , ou seja, quanto maior esse valor, maior seu poder de predição. Os valores de referência utilizados para R^2 foram de: 0,25 – baixo; 0,50 - moderado e; 0,75 - substancial (HAIR et al., 2013).

4.4.2.2. Coeficientes de caminho

Em relação ao modelo estrutural, os coeficientes de caminho (β) são os coeficientes padronizados que resultam da regressão de mínimos quadrados ordinários. A padronização dos indicadores varia entre +1 que indica um forte relacionamento positivo entre as variáveis e -1 que indica forte relacionamento negativo, já coeficientes próximos a zero indicam relações fracas e/ou inexistentes entre as variáveis.

A significância dos relacionamentos ocorre a partir de um procedimento denominado *bootstrapping* que, por meio da geração de um número expressivo de sub-amostras aleatórias baseadas nos dados iniciais, permite o cálculo do valor empírico da estatística *t student*. A significância do coeficiente de caminho do modelo, ocorre quando o valor *t* apresenta um valor maior que o valor crítico, cuja representação é por meio do valor *p*, ou *p-value*, assim, quanto maior o valor de *t*, maior a significância do coeficiente (HAIR et al., 2013).

Usualmente um nível de significância de 10% é um valor mínimo aceitável para determinado coeficiente de caminho. Nesta pesquisa, o processo *bootstrapping* foi executado com 5000 subamostras e os coeficientes de caminho com baixa significância estatística ou com sinal contrário à hipótese levantada foram desconsiderados para comprovação empírica da relação entre os construtos latentes (HAIR et al., 2009; HENSELER; RINGLE; SINKOVICS, 2009).

4.4.2.3. Coeficientes de determinação

O tamanho do efeito (f^2) é utilizado para demonstrar a relevância de uma variável na explicação de uma segunda variável, ou seja, quanto determinada variável pode impactar uma outra

variável endógena do modelo, caso seja omitida. Os valores de referência adotados para categorizar os coeficientes de determinação foram 0,02 - pequeno; 0,15 médio e; 0,35 grande (HAIR et al., 2013).

4.4.2.4. *Relevância preditiva*

Por fim, o último critério, a relevância preditiva, também chamado de critério de Stone-Geisser ou Q^2 , expressa a capacidade de previsão do modelo em relação aos valores observados inicialmente. Para apresentar relevância preditiva de um determinado construto, Q^2 deve apresentar valor maior que zero.

5 RESULTADOS DA PESQUISA

Este capítulo, que é composto de três seções, apresenta os resultados obtidos a partir dos procedimentos descritos na metodologia. A seção 5.1 denota as características da amostra em que é evidenciado o perfil dos respondentes. Na seção 5.2 é demonstrada a análise descritiva das variáveis do modelo. Já a seção 5.3 apresenta os resultados modelo estatístico que foi construído a partir do diagrama de caminhos e sua comparação com a teoria.

5.1. Característica da amostra

Esta seção faz uma caracterização da amostra, explicita a análise da taxa de respostas e as características dos respondentes. Os 158 questionários que compõem a amostra foram coletados em um período de cinco meses, mais precisamente entre os meses de agosto e dezembro de 2021. O *survey* foi aplicado de duas formas: via *on line* e presencial. Um total de 71 questionários foram preenchidos de forma remota, por meio do formulário do *Google Forms*. Estes questionários foram enviados para agricultores da base de dados da Embrapa. Os 87 questionários restantes foram respondidos presencialmente, via entrevistas realizadas com os agricultores de cooperativas nas cidades de Itápolis, Caconde e Monte Alto, no estado de São Paulo, e na cidade de Nova Resende, no estado de Minas Gerais.

A amostra é composta por 69% de agricultores com idade superior a 41 anos. Ademais, somente 1% dos respondentes da pesquisa tem menos de 20 anos, como demonstra a Tabela 1. Os dados da amostra são semelhantes aos do Censo Agropecuário (2017), no qual 70,63% dos agricultores respondentes relataram possuir idade superior a 45 anos.

Tabela 1 - Faixa etária dos respondentes.

Faixa etária	Frequência absoluta (respondente)	Frequência relativa (%)
Até 20 anos	2	1%
De 21 a 30 anos	20	13%
De 31 a 40 anos	28	18%
De 41 a 50 anos	47	30%
De 51 a 60 anos	33	21%
Acima de 61 anos	28	18%
Total	158	100%

Fonte: Dados da pesquisa (2022).

Já em relação ao nível de escolaridade dos respondentes, a Tabela 2 revela que 27% dos respondentes possuem graduação e 18% apresentam algum tipo de pós-graduação. A amostra diverge significativamente do Censo Agropecuário (2017) onde apenas 5,6% dos chefes dos estabelecimentos realizaram curso superior e 0,3% pós-graduação.

Tabela 2 - Nível de escolaridade dos respondentes.

Escolaridade	Frequência	%
Ensino Fundamental Incompleto	21	13%
Ensino Fundamental Completo	16	10%
Ensino Médio Incompleto	6	4%
Ensino Médio Completo	30	19%
Ensino Superior Incompleto	13	8%
Ensino Superior Completo	43	27%
Pós Graduação Completa	29	18%
Total	158	100%

Fonte: Dados da pesquisa (2022).


No que diz respeito ao tempo de atuação como produtor rural, quase metade dos respondentes (49%) atuam na agricultura há mais de vinte anos, como é possível observar na Tabela 3, o que denota experiência na área de atuação e tem relação com o perfil de faixa etária da amostra. Por outro lado, 25% dos respondentes indicaram atuar como produtor rural a menos de 5 anos.

Tabela 3 - Tempo como produtor rural.

Tempo atuando como produtor rural	Frequência	%
Menos de 1 ano	12	8%
Entre 1 e 5 anos	20	13%
Entre 6 e 10 anos	20	13%
Entre 11 e 15 anos	20	13%
Entre 16 e 20 anos	9	6%
Mais de 20 anos	77	49%
Total	158	100%

Fonte: Dados da pesquisa (2022).

Quanto à distribuição geográfica, embora se observe respondentes de 17 estados brasileiros, a maioria deles concentram-se nas regiões Sudeste (109 respondentes, totalizando 69% da amostra) e Sul (21 respondentes, 13%), o que perfaz 82% do total. No que corresponde à região Sudeste, 73 (46%) dos respondentes pertencem ao estado de São Paulo, 35 (22%) ao estado de Minas Gerais e 1 (1%) ao estado do Rio de Janeiro, conforme demonstra a Figura 19.

Figura 19 - Distribuição Geográfica dos respondentes.

Fonte: Dados da pesquisa (2022).

Quanto ao tamanho da área de cultivo (Tabela 4), comparando com o Censo Agropecuário 2017 no qual 2,1% dos produtores relataram atuar em áreas acima de 500 hectares, verifica-se que a amostra possui uma porcentagem superior de agricultores que atuam em grandes áreas de cultivo (8%). Na outra ponta, 21% dos respondentes atuam em áreas entre 0 a 5 ha, sendo 16,3% menor que os dados nacionais (37,3%). Em consonância com o Censo (2017), 27% dos respondentes possuem áreas de cultivo entre 5 a 20 hectares frente aos 27,2% observados no dado censitário.

Tabela 4 - Área cultivada/utilizada em hectares.

Área cultivada/utilizada em hectares	Frequência	(%)
0 a 5	33	21%
5 a 20	43	27%
20 a 50	29	18%
50 a 100	15	9%
100 a 500	25	16%
500 a 1000	7	4%
Acima de 1000	6	4%
Total	158	100%

Fonte: Dados da pesquisa (2022).

A Tabela 5 aponta o setor principal de atuação informado pelos respondentes. Verifica-se que a agricultura (lavouras temporárias) corresponde a mais da metade da área de atuação dos respondentes (58%), seguido da pecuária (23%) e da fruticultura ou cultivos permanentes (8%).

Tabela 5 - Setor predominante de atuação do agricultor.

Setor	Frequência	%
Agricultura	92	58%
Aquicultura/Piscicultura	2	1%
Fruticultura/Cultivos Permanentes	12	8%
Fungicultura	2	1%
Horticultura	5	3%
Pecuária	37	23%
Silvicultura	2	1%
Outros	6	4%
Total	158	100%

Fonte: Dados da pesquisa (2022).

Quanto ao conhecimento sobre algum tipo de sistema e/ou aplicativo de gestão, 67% dos respondentes informaram que têm conhecimento acerca da tecnologia, enquanto 33% informaram não ter conhecimento sobre aplicativos ou sistemas (Tabela 6).

Tabela 6 - Conhecimento prévio do agricultor acerca de sistemas de gestão.

Conhecimento de sistemas de gestão	Frequência	(%)
Sim	106	67%
Não	52	33%
Total	158	100%

Fonte: Dados da pesquisa (2022).

Quanto à plataforma de sua preferência para controlar um aplicativo ou sistema de gestão, 53% dos respondentes informaram ser importante ter acesso ao dispositivo em suas propriedades de duas formas, via computador e celular; 42% informaram precedência apenas pelo celular, enquanto 6% mencionaram a utilização primaz apenas via computador, demonstrado na Tabela 7.

Tabela 7 - Plataforma de preferência para controlar um aplicativo ou sistema de gestão.

Uso de dispositivos na propriedade	Frequência	(%)
Ambos (Computador e Celular)	83	53%
Celular	66	42%
Computador	9	6%
Total	0	100%

Fonte: Dados da pesquisa (2022).


Por fim, a Tabela 8 aponta que 47% dos agricultores nunca utilizaram um sistema de gestão agrícola. Na contramão, 3% mencionaram utilizá-los anualmente, 1% informaram acessar tal sistema a cada seis meses, enquanto 14% dos respondentes afirmaram utilizar sistemas de gestão agrícola semanalmente e 30% diariamente.

Tabela 8 - Frequência de uso de sistemas de gestão agrícola.

Frequência de uso sistemas de gestão agrícola	Frequência	%
Nunca utilizei	74	47%
Uma vez ao ano	4	3%
Uma vez a cada seis meses	2	1%
Uma vez ao mês	8	5%
Semanalmente	22	14%
Uso diário	48	30%
Total	158	100%

Fonte: Dados da pesquisa (2022).

O Gráfico 1 apresenta quais as principais finalidades de um aplicativo ou sistema de gestão na propriedade na visão dos respondentes. As aplicações mais citadas foram: Gestão técnica e operacional das atividades de produção e/ou da criação e Gestão de vendas e/ou informações de mercado. Na sequência, foram citados Gestão econômico-financeira (26), Gestão de insumos e suprimentos (23) e Gestão de qualidade de produto/ rastreabilidade (12).

Gráfico 1 - Atividades principais dos sistemas dos respondentes.

Fonte: Dados da pesquisa (2022).

5.2. Análise dos Dados Descritivos

A Tabela 9 apresenta a análise descritiva das variáveis. Em relação à variável Expectativa de Desempenho, as assertivas ED_1 (*Eu acredito que esta tecnologia seria útil nas minhas tarefas diárias*) e ED_4 (*O uso desta tecnologia aumentaria as chances de eu expandir minha renda*) foram as que apresentaram maior frequência de concordância por parte dos respondentes, 71,52% e 62,03%, respectivamente. As respostas evidenciam que os agricultores acreditam na utilidade da tecnologia e também na possibilidade de ampliação de renda com sua utilização. No contexto de utilidade e expansão, a agilidade do processo também é um fator de interesse dos agricultores, entretanto, somente 43% dos respondentes acreditam que os FMIS possibilitam que suas atividades sejam realizadas mais rapidamente (ED_2 - *Utilizar esta tecnologia possibilitaria realizar minhas tarefas diárias mais rapidamente*). O processo de realizar as tarefas de forma mais ágil pode estar associado a dinâmica de trabalho já desenvolvida e diariamente utilizada pelos mesmos. A implementação de novas tecnologias é de grande valia, entretanto, é necessário levar em consideração os mecanismos de produtividade que já são utilizados pelos agricultores (EMBRAPA, 2017).

No que se refere ao contexto de Expectativa de Esforço, uma frequência baixa de respondentes (<50%) concordam fortemente com as assertivas associadas com a facilidade de utilização dos FMIS. A assertiva EE_1 (*Eu acredito que esta tecnologia seria fácil e simples de usar*) demonstrou que apenas 34,81% acreditam na facilidade da utilização dessas tecnologias. A assertiva EE_4 (*Aprender a utilizar esta tecnologia seria fácil para mim*) correspondeu um percentual baixo de aceitação (43,04%), indicando que os entrevistados tendem a não apresentar uma visão de facilidade na aprendizagem de utilização dos FMIS. Associando essas duas vertentes (EE_1 e EE_4), é notório que a visão de dificuldade está interligada com a resistência de aprender algo novo. Desta forma, é possível compreender que a complexidade da tecnologia ainda é um fator que impede o fomento tecnológico no País. Pivoto et al (2018; 2019) abordam como barreiras para a aceitação e compreensão de tecnologias, a baixa escolaridade e a idade dos agricultores - neste estudo 54% dos agricultores não possuem ensino superior e 69% têm idade maior de 40 anos. A instrução ofertada aos agricultores contribui para que eles possam atuar de forma inovadora, bem como, preparados para fazer as mudanças pertinentes para adoção de novas técnicas e tecnologias (KNOWLER; BRADSHAW, 2007).

Quanto à variável Influência Social, observou-se que os respondentes concordam mais fortemente com as assertivas IS_1 (*Familiares acham que eu deveria utilizar esta tecnologia*) e IS_4 (*Consultores técnicos e extensionistas acham que eu deveria usar esta tecnologia*), ambas as assertivas apresentam uma frequência de aceitação superior a 50%. Neste ponto, demonstra-se a importância da assistência técnica nas lavouras para fomentar a adoção tecnológica. Petry et al. (2019) relatam em sua pesquisa que a maioria dos entrevistados desconhecem iniciativas associadas a empresas de extensão rural e de outros segmentos que visam fomentar a inovação e a difusão na agricultura. Corroborando com essa perspectiva, o estudo desenvolvido por Pivoto et al. (2018) evidencia a escassez de assistência técnica nas lavouras brasileiras, sendo uma barreira significativa na adoção de tecnologias. Perosa, Newton e Carrer (2021) reforçam a necessidade da participação dos agricultores em redes de fluxos de informações compostas por instituições voltadas à assistência técnica, sendo este um fator de grande valia na adoção de novas tecnologias.

A variável Condições Facilitadoras busca demonstrar se os agricultores acreditam terem os recursos e tecnologias necessárias para a aquisição dos FMIS. Assim, os resultados apontam que 54,43% dos respondentes acreditam obter o suporte necessário para auxiliá-los no uso de uma tecnologia (CF_4 - *Eu acredito que consigo obter suporte técnico para me auxiliar no uso desta tecnologia*). Contudo, somente 29,75% dos respondentes acreditam na compatibilidade entre a tecnologia obtida e os aparelhos eletrônicos já disponíveis em sua lavoura (CF_3 - *Eu acredito que esta tecnologia é compatível com outros aparelhos que utilizo na propriedade*) o que corrobora o estudo de Pivoto et al. (2018) que indicam a necessidade de integração entre sistemas na agricultura brasileira. Souza filho et al. (2011) relatam que determinadas tecnologias são complexas e seu uso eficiente requer um quantitativo de área que na maioria das vezes não é compatível com a realidade de muitos agricultores.

Já a variável Custo Percebido indica que quase metade dos agricultores (49,37%) acreditam que não se endividariam caso adquirissem os FMIS (CP_3 - *Eu me endividaria caso adquirisse esta tecnologia*). Não houve uma unanimidade nas vertentes relacionadas ao alto custo de adquirir a tecnologia (CP_1 - *Acredito que esta tecnologia seja muito cara*), bem como, em relação ao custo-benefício associado à utilização da tecnologia na agricultura (CP_2 - *Eu acho que esta tecnologia não possui um bom custo-benefício*). Com uma baixa frequência (<25%) é possível elucidar que os respondentes não apresentam uma concordância com a percepção do custo. O quantitativo poderia ser mais expressivo levando em consideração as respostas relacionadas aos outros constructos, entretanto, muitos estudos sugerem que embora os agricultores relacionem o uso de tecnologias com o aumento de produtividade, o alto custo

para adotá-las ainda é uma barreira importante para efetivar a ampliação tecnológica nas lavouras brasileiras (PIVOTO et al., 2018; 2019; MEDINA et al., 2020). Novas tecnologias que demandam expressivos investimentos podem gerar uma resistência de adoção pelos agricultores, principalmente em localidades de baixa renda (PEROSA; NEWTON; CARRER, 2021). Petry et al. (2019) ressaltam que a perspectiva de inovação tecnológica não é universal na agricultura, ou seja, cada indivíduo pode ter uma visão diferente e própria de custo-benefício a curto e longo prazo.

No cenário da Pressão Externa, cerca de 50,63% dos agricultores acreditam que ficarão mais competitivos frente à concorrência se adquirirem FMIS (PE_3 - *Eu acredito que se adquirir esta tecnologia vou ficar mais competitivo frente aos meus concorrentes*). Consonante com essa frequência, muitos estudos indicam que os agricultores tendem a associar os benefícios da tecnologia com competitividade, rentabilidade e melhor gerenciamento da área (BOLFE et al., 2020; SILVEIRA et al., 2021).

Quanto à variável Intenção de Comportamento, 70,89% dos respondentes afirmam que usariam FMIS se tivessem acesso a ela (IC_2 - *Eu usaria esta tecnologia se tivesse acesso a ela*) e 67,09% afirmam gostarem de experimentar novas tecnologias (IC_1 - *Eu gosto de experimentar novas tecnologias*). Isto sugere que a vertente de maior dificuldade em relação a adoção de tecnologias pelos agricultores é o acesso, e que ainda há muitos gargalos que precisam ser resolvidos a fim de garantir que as lavouras brasileiras sejam de fato, tecnificadas. Tal afirmação, pode ser corroborada pela variável Comportamento de Uso, na qual somente 30,38% dos agricultores afirmaram que irão de fato utilizar FMIS nos próximos meses (CU_1 - *Eu pretendo utilizar usar esta tecnologia nos próximos meses*). Na próxima subseção é realizada a validação do modelo teórico e a análise dos resultados.

Tabela 9 - Análise descritiva das variáveis.

Constructo		Variáveis	Frequência (%)								Média	D. P.
			N	1	2	3	4	5	6	7		
Expectativa de Desempenho	ED_1	Eu acredito que esta tecnologia seria ÚTIL nas minhas tarefas diárias	158	1,27	0,00	0,63	7,59	4,43	14,56	71,52	6,44	1,12
	ED_2	Utilizar esta tecnologia possibilitaria realizar minhas tarefas diárias MAIS RAPIDAMENTE	158	0,63	3,80	3,80	17,72	13,29	17,72	43,04	6,20	1,34
	ED_3	Utilizar esta tecnologia AUMENTARIA MINHA PRODUTIVIDADE	158	3,16	3,80	1,90	8,86	8,86	18,99	54,43	5,91	1,60
	ED_4	O uso desta tecnologia aumentaria as chances de eu EXPANDIR MINHA RENDA	158	3,16	0,63	3,80	6,96	6,33	17,09	62,03	6,12	1,48
Expectativa de Esforço	EE_1	Eu acredito que esta tecnologia seria FÁCIL E SIMPLES DE USAR	158	5,06	4,43	5,06	17,72	16,46	16,46	34,81	5,25	1,76
	EE_2	Acredito que seria FÁCIL PARA EU ME TORNAR HABILIDOSO no uso desta tecnologia	158	3,80	5,70	2,53	13,92	13,29	17,09	43,67	5,53	1,74
	EE_3	Eu acredito que seria FÁCIL DE USAR o sistema desta tecnologia	158	5,06	2,53	3,80	17,72	10,13	17,72	43,04	5,51	1,74
	EE_4	APRENDER A UTILIZAR esta tecnologia seria fácil para mim.	158	8,23	1,27	3,16	17,72	12,03	14,56	43,04	5,40	1,86
Influência Social	IS_1	FAMILIARES acham que eu deveria utilizar esta tecnologia	158	5,70	3,16	1,27	13,92	6,33	13,29	56,33	5,77	1,79
	IS_2	AGRICULTORES AMIGOS E PRÓXIMOS acham que eu deveria usar esta tecnologia	158	11,39	1,90	7,59	18,35	9,49	10,13	41,14	5,08	2,06

		PESSOAS das minhas REDES SOCIAIS										
	IS_3	Facebook, WhatsApp, Instagram, etc.) falam que eu deveria usar esta tecnologia	158	15,19	2,53	3,16	15,82	12,03	15,82	35,44	4,96	2,13
		CONSULTORES TÉCNICOS e										
	IS_4	EXTENSIONISTAS acham que eu deveria usar esta tecnologia	158	1,90	1,27	1,27	8,86	13,29	13,92	59,49	6,10	1,37
Condições Facilitadoras		Eu acredito que TENHO OS RECURSOS										
	CF_1	TÉCNICOS (acesso à internet rápida) necessários para utilizar esta tecnologia.	158	8,23	5,70	4,43	13,29	10,13	15,19	43,04	5,29	1,99
		Eu acredito que TENHO O CONHECIMENTO										
	CF_2	necessário para utilizar esta tecnologia.	158	5,06	5,70	4,43	11,39	14,56	12,03	46,84	5,48	1,84
		Eu acredito que esta tecnologia é COMPATÍVEL										
	CF_3	COM OUTROS APARELHOS que utilizo na propriedade.	158	20,25	5,06	5,70	17,72	8,86	12,66	29,75	4,47	2,27
		Eu acredito que CONSIGO OBTER SUPORTE										
	CF_4	TÉCNICO para me auxiliar no uso desta tecnologia.	158	8,23	3,16	3,80	7,59	8,86	13,92	54,43	5,65	1,94
Custo Percebido	CP_1	Acredito que esta tecnologia SEJA MUITO CARA	158	18,35	6,96	8,23	26,58	10,76	6,96	22,15	4,14	2,10
	CP_2	Eu acho que esta tecnologia NÃO POSSUI UM BOM CUSTO-BENEFÍCIO	158	36,71	14,56	6,33	13,29	8,23	2,53	18,35	3,23	2,29
	CP_3	Eu ME ENDIVIDARIA caso adquirisse esta tecnologia.	158	49,37	12,03	6,33	18,35	3,16	3,16	7,59	2,54	1,93

Pressão Externa	PE_1	A PRESSÃO DO SETOR E DO MERCADO AGRÍCOLA influencia minha decisão de adotar esta tecnologia	158	22,78	3,80	4,43	19,62	8,86	8,86	31,65	4,41	2,32
	PE_2	DEPENDERIA DE OUTRAS EMPRESAS E PARCEIROS que já estão utilizando esta tecnologia.	158	25,32	6,33	5,70	20,25	10,76	9,49	22,15	4,02	2,26
	PE_3	Eu acredito que se adquirir esta tecnologia VOU FICAR MAIS COMPETITIVO FRENTE AOS MEUS CONCORRENTES	158	7,59	2,53	1,90	10,13	12,66	14,56	50,63	5,64	1,85
Intenção de Comportamento	IC_1	Eu gosto de experimentar novas tecnologias	158	4,43	0,00	0,63	12,03	3,80	12,03	67,09	6,15	1,53
	IC_2	Eu usaria esta tecnologia se tivesse acesso a ela	158	3,16	1,27	0,63	10,76	2,53	10,76	70,89	6,24	1,47
	IC_3	Eu usaria esta tecnologia se ela estivesse disponível para mim.	158	9,49	1,27	2,53	10,13	6,33	12,66	57,59	5,71	1,95
Comportamento de Uso	CO_1	Eu pretendo utilizar usar esta tecnologia nos próximos meses	158	46,84	2,53	1,27	0,00	5,06	13,92	30,38	3,77	2,77

Fonte: Dados da pesquisa (2022).

*D. V = Desvio padrão


5.3. Modelagem de Equações Estruturais

Após a coleta dos dados de entrada do modelo, a MEE ocorreu por meio da construção do diagrama de caminhos no *software* Adanco 2.3 (*Composite Modeling* - CM). Nesse sentido, a Figura 20 apresenta o diagrama de caminhos que foi construído com base no modelo teórico UTAUT e na literatura. Os círculos simbolizam as variáveis latentes, os retângulos representam os indicadores e os caminhos que ligam as variáveis endógenas e exógenas, refletem as relações preditivas entre os construtos²

Conforme já abordado na seção de métodos e procedimentos da pesquisa, a estimação da MEE é subdividida em duas fases: (i) validação do modelo de mensuração que demonstra a relação de cada variável latente com seus indicadores por meio da análise fatorial confirmatória e; (ii) avaliação do modelo estrutural a qual demonstra relações de causalidade entre as variáveis latentes por intermédio da aplicação de múltiplas equações de regressão multivariadas, permitindo o tratamento separado dos modelos, além de considerar os erros de mensuração. Os resultados das fases serão abordados nas subseções 5.3.1 e 5.3.2, respectivamente.

² Construtos do modelo teórico compreendem as variáveis latentes e seus respectivos indicadores.

Figura 20 - Modelo e relacionamentos entre as variáveis.



Fonte: Adanco 2.3 (2022).

5.3.1. Avaliação do modelo de mensuração

A avaliação do modelo de mensuração no modelo reflexivo ocorre por meio de três passos: consistência interna, da validade convergente e da validade discriminante. A Tabela 10 apresenta os critérios utilizados para avaliar cada passo, seus respectivos valores e também autores de referência.

Tabela 10 - Critérios do modelo de Mensuração.

MODELO DE MENSURAÇÃO			
Etapas	Critério Utilizado	Valor de Referência	Autores
1. Consistência interna	Alfa de Cronbach (α)	>0,70	Henseler (2017)
	Confiabilidade composta (ρ_c)	>0,70	
	Henseler's rho (ρ_A)	>0,70	
2. Validade convergente	Cargas padronizadas	>=0,70	
	AVE	>=0,50	
3. Validade discriminante	Cargas cruzadas	Valor das cargas maiores nas variáveis latentes de origem do que em todas suas cargas em outras variáveis	Chin (1998)
	Fornell-Larcker	Raiz Quadrada da AVE de cada variável deve ser maior que sua correlação com outra variável	Fornell e Larcker (1981)
	HTMT	<0,85	Kline (2011)

Fonte: Elaborado pelo autor.

5.3.1.1. Consistência interna e validade convergente

Conforme abordado na seção metodológica, a consistência interna é determinada pelo Alfa de Cronbach(α), confiabilidade composta (ρ_c) e Dijkstra-Henseler's rho (ρ_A) e a validade convergente é determinada pela variância média extraída (AVE) A Tabela 11 apresenta os resultados de estimação inicial do modelo de mensuração. Nota-se que as variáveis latentes que apresentaram alfa de Cronbach (α) menor que 0,70 foram “Condições Facilitadoras” (CF) com valor de (α)=0,5996; “Custo Percebido” (CP) com valor de α = 0,5776 e “Pressão Externa” (PE) com valor de α = 0,6614. As variáveis CF e CP também apresentam Henseler's rho menor que 0,7, ρ_A = 0,6776 e ρ_A =0,6203, respectivamente. Ademais, em relação à validade convergente,

nota-se que a variável CF apresenta um AVE=0,4387, ou seja, menor que o valor aceitável que é 0,5. Um AVE de 0,4387 significa que aproximadamente 44% da variação da variável endógena é explicada pelas variáveis exógenas no modelo.

Tabela 11 – Valores de Consistência Interna e validade convergente (AVE) do modelo proposto.

Variável Latente	Henseler's rho (ρ_A)	Confiabilidade composta (ρ_c)	Alfa de Cronbach (α)	AVE
Influência Social	0,7877	0,8441	0,7552	0,5786
Intenção de Comportamento	0,8931	0,9301	0,8876	0,8161
Comportamento de Uso	1,0000	1,0000		1,0000
Condições Facilitadoras	0,6780	0,7505	0,5996	0,4385
Expectativa de Desempenho	0,8675	0,9099	0,8677	0,7165
Expectativa de Esforço	0,9299	0,9391	0,9142	0,7942
Custo Percebido	0,6202	0,7659	0,5776	0,5288
Pressão Externa	0,7260	0,8038	0,6614	0,5794

Fonte: Dados da pesquisa (2022).

Outro aspecto importante, demonstrado na Tabela 12, é avaliar as cargas padronizadas para provar a validade convergente em que os valores de indicadores devem ser maiores que 0,7. Nesse contexto, os indicadores que apresentaram resultados inferiores foram “IS_1 = 0,618 do constructo “Influência Social”; CF_1 = 0,616; CF_3 = 0,494 e CF_4 = 0,641 do constructo “Condições Facilitadoras”; CP_1 = 0,545 do constructo “Custo Percebido” e PE_2 = 0,666 do constructo “Pressão Externa”.

Tabela 12 – Valores das cargas padronizadas.

Indicador	IS	IC	CO	CF	ED	EE	CP	PE
IS_1	0,6184							
IS_2	0,8236							
IS_3	0,8497							
IS_4	0,7290							
IC_1		0,9056						
IC_2		0,9289						
IC_3		0,8749						
CO_1			1,0000					
CF_1				0,6154				
CF_2				0,8493				
CF_3				0,4933				
CF_4				0,6409				
ED_1					0,8167			
ED_2					0,8234			
ED_3					0,8702			
ED_4					0,874			
EE_1						0,8519		
EE_2						0,9250		
EE_3						0,8862		
EE_4						0,9002		
CP_1							0,5452	
CP_2							0,7871	
CP_3							0,8181	
PE_1								0,7708
PE_2								0,6655
PE_3								0,8374

Fonte: Dados da pesquisa (2022).

Embora seja permitida a retirada de indicadores em que as cargas padronizadas estejam abaixo de 0,7 para melhorar o ajuste do modelo, Hair et al (2009) apontam que pelo fato da MEE se

basear na análise fatorial confirmatória, deve haver um aporte teórico que justifique a retirada dos indicadores do modelo. Deste modo, embora o indicador IS_1 tenha apresentado valor menor que 0,7, o alfa de Cronbach (α) e a AVE do constructo “Influência social” (IS) estão dentro dos limites considerados satisfatórios, portanto, não há justificativa para a retirada do indicador IS_1.

Uma possível justificativa para o valor baixo do indicador CP_1 (0,543) é a assertiva construída para mensuração da variável “Custo Percebido” ter ocorrido em sentido inverso e influenciado na resposta do produtor. Dalmoro e Vieira (2013) consideram que o uso de indicadores com sentido inverso tende a confundir os respondentes e assim reduzir a confiabilidade da pesquisa. Após analisar os indicadores acima mencionados, realizou-se uma nova rodada em que os indicadores mais problemáticos de cada variável foram retirados do modelo: CF_3, CP_1, e PE_2. Os novos resultados podem ser visualizados na Tabela 13.

Tabela 13 - Segunda Rodada - – Valores de Consistência Interna e validade convergente (AVE) do modelo proposto.

Variável latente	Henseler's rho (ρ_A)	Confiabilidade composta (ρ_c)	Alfa de Cronbach (α)	AVE
IS	0,7877	0,8441	0,7552	0,5786
IC	0,8919	0,9302	0,8876	0,8163
CO	1,0000	1,0000		1,0000
CF	0,6120	0,7524	0,5444	0,5102
ED	0,8675	0,9099	0,8677	0,7165
EE	0,9299	0,9391	0,9142	0,7942
CP	0,5136	0,8042	0,5131	0,6725
PE	0,6353	0,8121	0,5594	0,6285

Fonte: Dados da pesquisa (2022).

Em relação aos novos resultados, notou-se que embora o AVE das variáveis CF, CP e PE tenham melhorado em relação à primeira rodada, o Alfa de Cronbach diminuiu ainda mais. A explicação se deve ao fato que este critério é bastante sensível à quantidade de indicadores e pelo fato de terem sido retirados os valores ainda menores. A Tabela 14 apresenta os novos resultados das cargas padronizadas após a retirada dos indicadores acima indicados.

Tabela 14 - Segunda Rodada - Valores das cargas padronizadas.

Indicador	IS	IC	CO	CF	ED	EE	CP	PE
IS_1	0,6184							
IS_2	0,8236							
IS_3	0,8498							
IS_4	0,729							
IC_1		0,9066						
IC_2		0,9293						
IC_3		0,8737						
CO_1			1,0000					
CF_1				0,5721				
CF_2				0,8588				
CF_4				0,6825				
ED_1					0,8167			
ED_2					0,8235			
ED_3					0,8701			
ED_4					0,8739			
EE_1						0,8518		
EE_2						0,9250		
EE_3						0,8862		
EE_4						0,9002		
CP_2							0,8123	
CP_3							0,8277	
PE_1								0,7429
PE_3								0,9054

Fonte: Dados da pesquisa (2022).

Em relação à variável CF notou-se uma melhora pouca expressiva nas cargas, o que não justifica a retirada do indicador CF_ 3. Embora as cargas das variáveis CP e PE tenham ficado acima de 0,7, não melhoraram a consistência interna do modelo. Portanto, sua retirada também não é justificada, visto que a permanência desses indicadores no modelo é sustentada pela teoria previamente estabelecida. Assim sendo, o restante da análise dos dados ocorrerá a partir dos resultados da primeira rodada.

5.3.1.2. *Validade discriminante*

Existem três critérios utilizados para verificar a validade discriminante: cargas cruzadas (*cross loadings*); critério de Fornell-Larcker e *Heterotrait-Monotrait Ratio of Correlations* (HTMT).

Os resultados apresentados na Tabela 15 demonstram que valores dos construtos de origem - destacados em negrito - apresentaram valores maiores quando comparados com os outros construtos do modelo, o que indica a validade discriminante do modelo seguindo as premissas de tal critério.

Tabela 15 - Valores dos *Cross Loadings*.

Indicador	IS	IC	CO	CF	ED	EE	CP	PE
IS_1	0,6184	0,192	0,0847	0,2266	0,1015	0,0893	0,0043	0,1783
IS_2	0,8236	0,3209	0,2999	0,4424	0,5225	0,2598	-0,1115	0,2547
IS_3	0,8497	0,3376	0,2941	0,4446	0,4184	0,3590	-0,2074	0,2814
IS_4	0,7290	0,2753	0,2060	0,4659	0,2931	0,2915	-0,2114	0,1088
IC_1	0,2552	0,9056	0,0758	0,4719	0,3595	0,5457	-0,2100	0,3873
IC_2	0,2394	0,9289	0,1259	0,4794	0,3436	0,6296	-0,2840	0,4193
IC_3	0,5028	0,8749	0,2961	0,5489	0,4283	0,5309	-0,284	0,4193
CO_1	0,3084	0,1923	1,0000	0,1747	0,1983	0,0451	-0,3109	0,0901
CF_1	0,1571	0,3205	-0,1880	0,6154	0,1136	0,4058	-0,0817	0,2304
CF_2	0,5081	0,5110	0,2724	0,8493	0,3562	0,5233	-0,2762	0,2389
CF_3	0,0943	0,2479	-0,2410	0,4943	0,1166	0,4306	0,0128	0,0927
CF_4	0,4404	0,3285	0,2573	0,6409	0,5238	0,2659	-0,1582	0,2887
ED_1	0,3546	0,3555	0,1083	0,3643	0,8167	0,2696	-0,1853	0,1717
ED_2	0,4359	0,3641	0,1583	0,4464	0,8234	0,3000	-0,0750	0,2277
ED_3	0,3698	0,3518	0,2137	0,4191	0,8702	0,1785	-0,1197	0,2773
ED_4	0,4285	0,3507	0,1915	0,3570	0,874	0,1712	-0,1684	0,3093
EE_1	0,4016	0,4049	0,0312	0,5278	0,3378	0,8519	-0,1766	0,1425
EE_2	0,2403	0,6017	0,0452	0,5152	0,1943	0,9250	-0,2173	0,2315
EE_3	0,3090	0,5873	0,0637	0,5444	0,2488	0,8862	-0,2876	0,3119
EE_4	0,3196	0,6066	0,0190	0,5322	0,2253	0,9002	-0,1964	0,2041
CP_1	-0,0563	-0,0762	-0,1184	-0,1108	0,0233	-0,0695	0,5452	0,0270
CP_2	-0,1680	-0,1771	-0,3018	-0,1841	-0,2274	-0,1229	0,7873	-0,1007
CP_3	-0,1516	-0,2890	-0,2191	-0,2176	-0,0790	-0,3006	0,8181	-0,0708
PE_1	0,1748	0,2924	0,0473	0,1669	0,2167	0,2131	-0,0796	0,7708
PE_2	0,1411	0,2281	0,0343	0,0515	0,0676	0,0618	0,0513	0,6655
PE_3	0,2775	0,4554	0,1022	0,4181	0,3107	0,2581	-0,1203	0,8374

Fonte: Dados da pesquisa (2022).

O segundo critério de validade discriminante é o de Fornell-Larcker. Esse critério indica que a raiz quadrada de cada AVE deve ser maior que a correlação com qualquer outro construto

pertencente ao modelo. A Tabela 16 demonstra os valores das raízes quadradas AVE destacados em negrito na diagonal principal, bem como suas correlações com as variáveis latentes. Nota-se que o critério de Fornell-Larcker também é atendido em todas as variáveis latentes, o que confirma a validade discriminante.

Tabela 16 - Valores do Critério de Fornell-Larcker.

Indicador	IS	IC	CO	CF	ED	EE	CP	PE
IS	0,5786							
IC	0,1419	0,8161						
CO	0,0951	0,0364	1,0000					
CF	0,2834	0,3099	0,0303	0,4385				
ED	0,2208	0,1768	0,0393	0,2204	0,7165			
EE	0,1203	0,3963	0,0020	0,3512	0,0743	0,7942		
CP	0,0351	0,0747	0,0966	0,0600	0,0261	0,0621	0,5288	
PE	0,0766	0,2073	0,0081	0,1102	0,0847	0,0656	0,0077	0,5794

Fonte: Dados da pesquisa (2022).

O terceiro critério de validade discriminante, HTMT, refere-se a média das correlações de indicadores em construtos que medem fenômenos diferentes em relação à média das correlações de indicadores dentro de um mesmo construto. A Tabela 17 apresenta os resultados que demonstram que os valores do HTMT são menores que 0,85, também confirmando a validade discriminante por meio deste critério.

Tabela 17 - Valores do Critério de *Heterotrait-Monotrait Ratio of Correlations* (HTMT).

Indicador	IS	IC	CO	CF	ED	EE	CP	PE
IS								
IC	0,4400							
CO	0,3352	0,1949						
CF	0,6473	0,7135	0,0483					
ED	0,5426	0,4753	0,2131	0,5699				
EE	0,4060	0,6845	0,0467	0,8150	0,3156			
CP	0,2407	0,3394	0,3808	0,3028	0,1819	0,3039		
PE	0,3567	0,5478	0,0976	0,4043	0,3397	0,2868	0,0662	

Fonte: Dados da pesquisa (2022).

5.3.1.3. *Considerações sobre a avaliação do modelo de mensuração*

Conforme já relatado, a fase de avaliação do modelo de mensuração envolve a análise fatorial confirmatória. Nota-se nessa fase que durante a etapa da confiabilidade, três variáveis latentes apresentaram Alfa de Cronbach menor que 0,7 (“CF”, “CP” e, “PE”), cujos valores eram $\alpha=0,5996$; $\alpha=0,5776$ e; $\alpha=0,6614$, respectivamente. Além disso, as variáveis CF e CP também apresentaram Henseler’s rho menor que 0,7, apresentando valores de $\rho_A = 0,6776$ e $\rho_A=0,6203$, respectivamente. Além disso, a variável CF ainda apresentou AVE=0,4387, ou seja, menor que 0,5.

Em relação às cargas padronizadas, os seguintes indicadores apresentaram valores menores que 0,7: IS_1: 0,6184; CF_1: 0,6161; CF_3: 0,4943; CF_4: 0,6405; CP_1: 0,5453; PE_2: 0,6655. Por não influenciar a consistência interna e validade convergente, manteve-se o indicador IS_1 e retirou-se os indicadores mais problemáticos de cada variável, ou seja, CF_3, CP_1 e PE_2 efetuando uma nova análise de consistência interna. Mesmo com a retirada destes indicadores, o modelo não apresentou melhora significativa nos valores calculados e, com base no aporte teórico da literatura disponível, tais indicadores foram mantidos.

No que se refere à validade discriminante, notou-se que todos os valores ficaram de acordo em todos os critérios utilizados para garantir tal verificação: cargas cruzadas, em que valor das cargas foram maiores nas variáveis latentes de origem do que em todas as suas cargas associadas; critério de Fornell-Larcker em que a raiz Quadrada de AVE de cada variável apresentaram-se maiores do que em sua correlação com outra variável e o HTMT em que os valores foram maiores que 0,85.

5.3.2. *Avaliação do modelo estrutural*

O modelo estrutural é avaliado a partir das seguintes métricas: variância explicada (R^2); coeficientes do modelo estrutural; poder de explicação dos construtos exógenos (f^2); relevância preditiva (Q^2) e poder de predição dos construtos exógenos (q^2). A Tabela 18 apresenta os critérios utilizados para avaliar cada passo e os seus respectivos valores de referência.

Tabela 18 - Critérios do Modelo Estrutural.

MODELO ESTRUTURAL		
PASSOS	VALOR DE REFERÊNCIA	AUTORES
1. Avaliação da variância explicada (R^2)	0,19: pequeno 0,33: moderado 0,67 substancial	Chin (1998)
2. Avaliação dos coeficientes de caminho (β)	1,65 - Significância = 10% 1,96 - Significância = 5% 2,57- Significância = 1%	
3. Avaliação do efeito do tamanho (f^2)	f^2 : 0,02 - pequeno f^2 : 0,15 - médio f^2 : 0,75 - grande	
4. Avaliação da relevância preditiva (Q^2)	$Q^2 > 0$	


Fonte: Elaborado pelo autor.

5.3.2.1. Variância explicada (R^2)

A precisão preditiva do modelo é representada por meio do coeficiente de determinação (R^2), em que as variáveis exógenas explicam a quantidade de variância das variáveis endógenas às quais estão ligadas. Um aspecto notável, é que o coeficiente de determinação (R^2) pode ser inflado por existir uma quantidade maior de variáveis exógenas que explicam as variáveis endógenas, tendendo a gerar vieses em modelos mais complexos. Assim, o cálculo do R^2 ajustado permite o aprimoramento do R^2 de acordo com a quantidade de variáveis endógenas relacionadas ao tamanho da amostra.

A Figura 21 demonstra os coeficientes de determinação (R^2) e os coeficientes de determinação ajustados (R^2 adj.) das variáveis endógenas do modelo estrutural. Nesse sentido, o coeficiente de determinação da variável mediadora IC é de 0,5428, apresentando moderado poder explicativo, enquanto o coeficiente de determinação da variável endógena CO é 0,1079, o que expressa baixo poder explicativo. Nas demais variáveis, não foram notadas diferenças significativas entre o R^2 e o R^2 ajustado.

Figura 21 - Resultado da avaliação do modelo estrutural. Avaliação do modelo estrutural proposto: resultado dos coeficientes de determinação (R^2) e os coeficientes de determinação ajustados (R^2 adj.) das variáveis endógenas.



Fonte: Adanco 2.3 (2022).

5.3.2.2. Coeficientes de caminho (β)

Os coeficientes de caminho (β), que dizem respeito ao segundo passo da avaliação do modelo estrutural, referem-se aos valores empregados para avaliar as hipóteses do modelo teórico, na qual foi utilizado o método *bootstrapping* (HAIR et al., 2009) para verificar a significância estatística. A Tabela 19 apresenta os resultados que indicam que dos dez caminhos apresentados no modelo estrutural, três apresentaram significância estatística no nível de 10%: (i) Expectativa de Esforço $\rightarrow$ Intenção do Comportamento (0,4259); (ii) Custo Percebido $\rightarrow$ Comportamento de Uso (-0,2851); e (iii) Pressão Externa $\rightarrow$ Intenção do Comportamento (0,2507).

Tabela 19 - Valores dos coeficientes de caminho.

Relação	Média	Desvio padrão	Coeficientes de caminho (β)	Estatística t	Valor p
IS $\rightarrow$ IC	0,0098	0,0858	0,0052	0,0611	0,4756
CF $\rightarrow$ IC	0,1342	0,0990	0,1237	0,0990	0,1059
CF $\rightarrow$ CO	0,0986	0,1561	0,0928	0,1561	0,2761
ED $\rightarrow$ IC	0,1532	0,0837	0,1575	0,0837	0,0302
EE $\rightarrow$ IC	0,4214	0,0720	0,4259***	0,0720	0,0000
CP $\rightarrow$ IC	-0,0855	0,0548	-0,0889	0,0548	0,0525
CP $\rightarrow$ CO	-0,2868	0,0780	(-) 0,2851***	0,0780	0,0001
PE $\rightarrow$ IC	0,2470	0,0627	0,2507***	0,0627	0,000
PE $\rightarrow$ CO	0,0366	0,0830	0,0343	0,0830	0,3397
IC $\rightarrow$ CO	0,0720	0,0905	0,0794	0,8777	0,1903

Fonte: Dados da pesquisa (2022).

*Significante nível $p < 0,01$

**Significante nível $p < 0,05$

***Significante nível $p < 0,10$

5.3.2.3. Avaliação do efeito do tamanho (f^2)

O terceiro passo diz respeito ao poder de explicação dos construtos exógenos. Mais precisamente, ele é determinado ao avaliar o valor de R^2 de uma variável endógena no momento em que uma variável exógena é retirada do modelo. A Tabela 20 ilustra os valores de f^2 para as variáveis endógenas do modelo, no qual foi observado que as variáveis “Expectativa de

Esforço” e “Pressão Externa” tem impacto mediano na variável endógena “Intenção de Comportamento.”

Tabela 20 - Avaliação do efeito do tamanho (f^2).

Relação	Efeito f^2	Intensidade do efeito (f^2)
ED → IC	0,0375	Pequeno
ED → CO	--	
CF → IC	0,0193	Irrelevante
CF → CO	--	
CP → IC	0,0148	Irrelevante
CP → CO	0,0840	Pequeno
EE → IC	0,2610	Médio
EE → CO	--	
IS → IC	0,0000	Irrelevante
IS → CO	--	
PE → IC	0,1136	Médio
PE → CO	0,0001	Irrelevante
IC → CO	0,0062	Irrelevante

Fonte: Dados da pesquisa (2022).

5.3.2.4. Avaliação da relevância preditiva (Q^2)

O quarto passo refere-se à avaliação da relevância preditiva dos construtos endógenos reflexivos (Q^2). A estimação do valor de Q^2 ocorreu por meio do procedimento denominado *Blindfolding* do software "SmartPLS", o qual permite estimar uma medida que informe o quão bem o modelo prediz os valores originalmente observados (HAIR et al., 2017). Conforme apresenta a Tabela 21, a variável endógena IC apresentou valor de $Q^2 = 0,413$ e a variável endógena CO obteve $Q^2 = 0,0490$. Deste modo, os valores maiores que zero encontrados asseguram ao modelo relevância preditiva para as variáveis endógenas.

Tabela 21 - Indicador de Relevância Preditiva (Q^2) para variáveis endógenas.

Variável	Q^2
IC	0,413
CO	0,049

Fonte: Dados da pesquisa (2022).

5.3.3. Validação das hipóteses: análise e discussão dos resultados

As hipóteses estabelecidas para o modelo conceitual no capítulo 3 desta pesquisa foram testadas por meio do *software* Adanco, o qual permitiu realizar os cálculos dos coeficientes de caminho e verificar o nível de significância para as relações de causalidade. A Tabela 22 apresenta a validação das hipóteses formuladas no modelo proposto. Evidências estatísticas que suportam as relações estabelecidas entre as variáveis no modelo proposto foram observadas em três das dez hipóteses formuladas. A seguir, os resultados para cada hipótese formulada obtidos pela pesquisa de campo são apresentados e discutidos com base na literatura existente. A partir da aplicação da *Unified Theory of Acceptance and Use of Technology* (UTAUT), foram analisadas as respostas dos agricultores para descobrir se os fatores contextuais previstos na UTAUT levam o indivíduo à intenção de usar um sistema de informação agrícolas.

Tabela 22 - Resultado das hipóteses e coeficientes de caminho.

Relação	Hipótese	Coeficientes de caminho (β)	Estatística t	Valor p	Resultado
ED → IC	H1	0,1575	0,0837	0,0302	Não suportada
EE → IC	H2	0,4259***	0,0720	0,0000	Suportada
IS → IC	H3	0,0052	0,0833	0,4849	Não suportada
CF → IC	H4	0,1237	0,0990	0,1059	Não suportada
CF → CO	H5	0,0928	0,1561	0,2761	Não suportada
CP → IC	H6	(-) 0,0889	0,0548	0,0525	Não suportada
CP → CO	H7	(-) 0,2851***	0,0780	0,0001	Suportada
PE → IC	H8	0,2507***	0,0627	0,0000	Suportada
PE → CO	H9	0,0343	0,0830	0,3397	Não suportada
IC → CO	H10	0,0794	0,8777	0,1903	Não suportada

Fonte: Elaborado pelo autor

*Significante nível $p < 0,01$

**Significante nível $p < 0,05$

***Significante nível $p < 0,10$

A **hipótese H1** previa que a expectativa de desempenho (ED) influenciaria positivamente a intenção comportamental (IC) dos agricultores de aceitação de FMIS. Presumia-se que a medida que os agricultores percebessem que a tecnologia estudada melhoraria o desempenho de suas atividades diárias, eles aumentariam suas intenções de aceitação. Na agricultura a ED

pode ser expressa como a visão que agricultores têm sobre quanto uma determinada tecnologia pode ajudá-los no monitoramento de suas atividades, na análise dos dados, na verificação do rendimento, na mensuração da produtividade, previsões meteorológicas, na expansão de sua rentabilidade, etc.

Venkatesh et al. (2003) indicam que a ED é o constructo mais importante para a determinação da adoção de tecnologias no modelo UTAUT. Os efeitos positivos da ED, quanto à adoção de uma nova tecnologia, vêm sendo abordada em muitos estudos, visto que seu papel é considerado um aspecto central no que se refere a difusão de novas tecnologias (LOWENBERG-DEBOER et al., 2020; RIAL-LOVERA, 2018; RONAGHI; FOROUHARFAR, 2020; SALIMI; POURDARBANI; NOURI, 2020; VENKATESH, 2003).

Diversos estudos de análise de tecnologias digitais apontam nesta direção. Em sua pesquisa, Shi et al. (2022) apontam que a ED afeta de forma significativa a vontade de usar internet sem fio em um ambiente agrícola e que o benefício percebido de seu uso resulta em uma maior probabilidade de aceitação da tecnologia. A pesquisa de Molina-Maturano et al. (2021) revelou que quando a ED é elevada, seus utilizadores apresentam uma atitude positiva quanto ao uso de uma tecnologia e direciona os agricultores na adoção de tecnologias móveis para obter informações. Ou seja, a intenção dos agricultores em utilizar aplicativos é reforçada, à medida que eles acreditam que o desempenho de suas atividades será superior. Antony et al. (2020) reforçam que o fornecimento de informações e de comunicação rápida influencia os agricultores na adoção de IoT.

Entretanto, não foram encontradas evidências estatísticas que suportem a relação positiva entre ED e IC ($\beta=0,1575$; $t=0,0837$; $p=0,0302$). Os estudos de Van Biljon and Kotze (2008), Sambasivan et al. (2010), Tibenderana et al. (2010) e Tan and Wu (2010) apresentaram semelhante situação.

Diversas suposições podem ser levantadas, tal como a relacionada à percepção subjetiva dos benefícios e custos da tecnologia em análise. Rübcke von Veltheim e Heise (2021) analisando o uso de robôs autônomos apontaram que só há impactos positivos na ED quanto os agricultores percebem os benefícios financeiros provenientes de seu uso. Sun et al (2021) ao analisar a intenção dos agricultores em adotar tecnologias de rastreabilidade de IoT, mencionam que a maioria dos agricultores acreditava que a tecnologia pode garantir maior lucratividade e melhoria nos seus processos de Marketing.

Uma outra conjectura pode ser relacionada a falta de experiência quanto ao uso de uma determinada tecnologia no campo ou tecnologias similares. A falta de referências em relação a tecnologias digitais e, em especial a FMIS, tende a influenciar a ED, como averiguado por

Lowenberg-DeBoer et al (2020). No caso do grupo de entrevistados, 47% nunca fizeram uso de algum tipo de aplicativo ou sistema de gestão de dados.

A percepção de altos custos decorrentes da adoção de tecnologias podem ter impactado os resultados da pesquisa, visto que 48% dos respondentes da *survey* atuam em propriedades pequenas, com menos de 20 de hectares. À medida que a ED quanto ao uso de uma determinada tecnologia aumenta, a vontade de pagar por uma determinada tecnologia também deve aumentar. Entretanto, Shi et al. (2022) observaram que a ED não afeta necessariamente a disposição dos agricultores em pagar pela IoT na agricultura.

Logo, é importante considerar as características dos respondentes da pesquisa e a forma como a ED é percebida pelo agricultor. Se ele não for capaz de perceber benefícios como aumento de rentabilidade, produtividade e facilidade em suas operações, a tendência é que ele não utilize a tecnologia.

A **hipótese H2** estabelecia que a Expectativa de Esforço (EE) para usar a tecnologia influencia positivamente na intenção de comportamento dos agricultores. Assim, a aceitação de uma nova tecnologia se dará quando a EE é mínima, ou então, menor do que os ganhos futuros gerados por sua adoção (VENKATESH et al., 2003). Conforme previsto, a hipótese apresentou significância estatística ($\beta=0,4259$; $t=0,0720$; $p=0,000$), tornando-a suportada.

Esse resultado é corroborado por outros estudos. O estudo de Faridi, Kavoosi-Kalashami e El Bilali (2020) demonstrou que a EE é o construto mais importante para explicar a IC na adoção de medidas de conservação da água e solo. Adicionalmente, o estudo de Michels, Bonke e Musshoff (2020) demonstrou o efeito positivo da EE na intenção comportamental dos agricultores de utilizarem aplicações para proteção de culturas em smartphones. Em consonância, o estudo de Ronaghi e Forouharfar (2020) também apontou que a EE tem uma influência positiva na IC de uso de IoT.

A EE também tem sido apontada como um dos principais fatores que influenciam na IC de aceitar uma nova tecnologia. Shi et al. (2022) indicou que quanto maior a facilidade de uso da tecnologia de IoT na agricultura, maior a possibilidade de seu uso pelo usuário final. Da mesma maneira, os estudos de adoção de AP (LI et al., 2020) SMS na agricultura (BEZA et al., 2018), TIC's (WU, 2012) indicaram a influência da variável latente.

A **hipótese H3** afirma que a influência social (IS) afeta positivamente a intenção comportamental dos agricultores de aceitarem as FMIS. No contexto agrícola, a IS é descrita como a medida que os agricultores percebem que outras pessoas de seu convívio concordam com suas escolhas tecnológicas, sendo elas seus pares, familiares, outros agricultores,

cooperados, etc. Quanto maior for a IS, maior é a expectativa e a confiança no desempenho e na rentabilidade decorrentes do uso de uma tecnologia (ALAM et al., 2020).

Entretanto, não foram encontradas evidências estatísticas que suportem esta relação ($\beta=0,0032$; $t=0,0833$; $p=0,4849$). Os resultados indicam que a IS não é fator discriminante para a aceitabilidade de FMIS e vão ao encontro dos estudos de Faridi, Kavooosi-Kalashamia e El Bilali (2020); Alazab et al. (2020); Molina-Maturano et al. (2021) e Ullah e Al-turjman (2021).

No contexto do comportamento do consumidor, o estudo desenvolvido por Zeng; Tan e Li (2016), buscava identificar se a intenção de comprar produtos agrícolas por meio da internet é forte quando os consumidores percebem que seus amigos e familiares demonstram uma relação positiva em relação a isso. Contudo, os resultados apontaram que a IS não afeta significativamente a intenção de compra de produtos agrícolas por parte dos consumidores mulheres e tampouco os consumidores pouco familiarizados com a tecnologia. Os resultados também demonstraram que a IS afeta negativamente e significativamente pessoas com alto grau de inovação, já que estas perseguem sua individualidade e consequentemente por coisas diferenciadas e que também, o ambiente social é bastante pluralista.

Nessa mesma linha, o estudo de Ullah e Al-turjman (2021) não identificou impacto substancial da IS na IC quanto à adoção de *blockchain* na agricultura paquistanesa. Embora o modelo teórico da pesquisa tenha sugerido o impacto positivo da IS na IC dos agricultores, não foram identificadas evidências estatísticas significativas na amostra pesquisada.

Por outro lado, outros trabalhos identificaram uma relação positiva entre a intenção comportamental e a aceitabilidade ou adoção de tecnologias no contexto agrícola (DIEKMANN; THEUVSEN, 2019; RONAGHI; FOROUHARFAR, 2020; MICHELS; BONKE; MUSSHOFF, 2020; HAN; XIONG; ZHAO, 2021; GIUA; MATERIA; CAMANZI, 2022). O estudo de Giua, Materia e Camanzi (2022) identificou que as pessoas em quem os agricultores confiam parecem ter um efeito crucial e mais forte do que os colegas agricultores e outros indivíduos.

Por sua vez, o estudo de Sun et al. (2021) constatou que os agricultores não obtêm conhecimentos sobre tecnologias digitais de rastreamento por meio da internet. Isso se deve ao fato de que, frequentemente, utilizam a internet para fins de entretenimento e, ademais, possuem acesso limitado a estudos ou meios de comunicação social. Portanto, os resultados sugerem que o conhecimento que os agricultores possuem sobre essa tecnologia é adquirido por meio de suas experiências e convívio social.

A pesquisa de Shi et al. (2022) demonstrou que a influência social de familiares também apresenta grande influência no que se refere à adoção de tecnologias digitais, no caso a IoT.

Nesse sentido, o ambiente social que uma pessoa está inserida funciona como um grande referencial e incentiva o uso de um determinado sistema. Tais resultados corroboram os estudos de Alam et al. (2020) que indicam que, no que se refere ao uso de tecnologias digitais como a IoT, quanto maior a IS, maior a possibilidade de um determinado agricultor adotar determinada tecnologia agrícola.

O estudo de Rübcke Von Veltheim, Theuvsen e Heise (2021) indicou que tanto a opinião de colegas profissionais, quanto da sociedade, influencia a decisão do agricultor de utilizar tecnologias digitais robóticas em suas propriedades. Bakar et al. (2021) identificaram que os agricultores concordam sobre a importância dos amigos, familiares, governo e extensionistas na adoção de tecnologias de pós-colheita.

Logo, as descobertas da literatura vêm apresentando resultados divergentes acerca do fator. Uma possível justificativa para o resultado desta hipótese é o fato de os respondentes serem bem instruídos pois, em sua maioria, possuem o nível superior ou ensino médio completo, conforme anteriormente discutido. Pode-se argumentar que se os agricultores são bem instruídos e capazes de buscar informações sobre determinada tecnologia por conta própria, não precisam recorrer a amigos, consultores ou outros agricultores para esclarecer suas dúvidas.

As **hipóteses H4 e H5** previam que as condições facilitadoras (CF) influenciam positivamente a intenção comportamental e o comportamento de uso dos agricultores de aceitarem FMIS, respectivamente. No estudo original de Venkatesh et al. (2003), o construto CF reflete tanto o suporte organizacional quanto de infraestrutura para a decisão de uso de uma tecnologia. No contexto das tecnologias agrícolas digitais, a existência de infraestruturas, como banda larga, é fundamental, bem como outros recursos técnicos.

Todavia, não foram encontradas evidências estatísticas que suportem tais relações ($(\beta=0,1237; t=0,0990; p=0,1059)$; $(\beta=0,0928; t=0,1561; p=0,2761)$). Vários estudos examinaram o impacto das CF na IC de adoção de uma tecnologia e chegaram a diferentes conclusões, que podem refletir a maneira pelas quais essas condições foram operacionalizadas (MICHELS; BONKE; MUSSHOF, 2020).

Por exemplo, Giua et al. (2022) afirmam que a existência de condições organizacionais facilitadoras, capazes de apoiar igualmente diferentes tipos de agricultores, pode ser particularmente importante para incluir fazendas menos tecnológicas e estruturadas na transição para a digitalização. Corroborando, Shang et al. (2021) identificaram, por meio de uma revisão de literatura, que a indisponibilidade e acessibilidade de recursos tecnológicos, como dispositivos móveis, acesso à internet e softwares agrícolas específicos, dificultam a adoção de tecnologias pelos agricultores.

Para modificar essa situação, Barnes et al. (2019) sugerem que os fabricantes e fornecedores de tecnologia comecem a oferecer testes e treinamentos pré-adoção aos agricultores, consultoria sobre sistemas agrícolas e suporte técnico pós-instalação. Em consonância, o estudo de Michels, Bonke e Musshoff (2020) identificou que mais suporte técnico e treinamento dos fornecedores de tecnologia promovem um efeito positivo nas decisões de adoção dos agricultores.

Além disso, Silveira et al. (2021) considera que a incompatibilidade dos componentes são fatores que podem impedir a aquisição de equipamentos e maquinários, além da falta de usabilidade, alto consumo de energia, baixo alcance de comunicação e adaptação de tecnologias que não foram concebidas para a agricultura. Maruping et al. (2017) ressaltam que a disponibilidade destes recursos também é considerada como condição facilitadora que leva a intenção de adoção pelos agricultores.

Quanto a influência das condições facilitadoras no comportamento de uso, a literatura mostra que uma infraestrutura tecnológica adequada incentiva os agricultores a adotarem tecnologias digitais no campo (FARIDIA; KAVOOSI-KALASHAMIA; EL BILALI, 2020; GIUA, MATERIA; CAMANZI, 2022). Alazab et al. 2021 apontam que os adotantes da tecnologia, ao perceberem um nível de apoio tecnológico, organizacionais, de rede e humano na utilização do *blockchain*, terão uma experiência mais agradável e terão maior propensão em se envolver com a tecnologia.

O estudo de Rose et al. (2016) identificou que a falta de conexão pode limitar o acesso dos agricultores às informações necessárias armazenadas no banco de dados. Assim sendo, mesmo que o agricultor esteja interessado em uma nova tecnologia, se houver uma incompatibilidade entre a ferramenta e o fluxo de trabalho do agricultor, isso pode resultar na sua não adoção.

Uma justificativa para o resultado desta hipótese é o contexto agrícola brasileiro. Por exemplo, Michels, Bonke e Mushof (2020) apontam que as condições facilitadoras, na forma de infraestrutura técnica, desempenham um papel ainda maior nos países em desenvolvimento. No contexto brasileiro, Bolfe et al. (2020) afirmam que apesar do censo agropecuário brasileiro de 2017 relatar que o acesso à internet cresceu 1.900% em relação a 2006, cerca de 3,5 milhões de estabelecimentos rurais não possuíam acesso à internet, ou seja 70%.

À medida que os sistemas e aplicativos se tornam mais complexos e demandam maiores capacidades computacionais ou acesso a bancos de dados para executar simulações, a presença de uma cobertura de internet é fundamental. Portanto, a baixa aceitação e adoção de sistemas e aplicativos móveis continuarão sendo um desafio no Brasil enquanto não houver uma cobertura adequada de internet disponível.

As **hipóteses H6 e H7** estipulavam que os custos percebidos (CP) influenciam negativamente na intenção comportamental e no comportamento de uso dos agricultores de aceitarem FMIS, respectivamente. O custo percebido se refere à percepção do agricultor sobre os recursos necessários para adotar e utilizar uma tecnologia, bem como os benefícios que ele espera obter em troca. Embora, não tenham sido encontradas evidências estatísticas que suportem a relação da hipótese H6 ($\beta=-0,0889$; $t=0,0548$; $p=0,0525$), os resultados da hipótese H7 demonstraram que os custos percebidos estão negativamente relacionados com o comportamento de uso ($\beta=-0,2851$; $t=0,0780$; $p=0,001$), o que torna essa hipótese suportada.

Os resultados vão ao encontro do estudo de Chen e Li (2010) que examinou a adoção de uma tecnologia de reconhecimento de fala em chinês. Os resultados mostraram que a percepção dos custos não teve impacto significativo na intenção comportamental dos usuários, mas teve um impacto significativo no comportamento de uso em relação ao uso da tecnologia.

Uma hipótese plausível para esse resultado é que os agricultores brasileiros podem inicialmente perceber que os FMIS têm um custo baixo, mas depois de experimentar a tecnologia, podem constatar que o custo de utilização real não compensa o benefício obtido. Ademais, a maioria dos participantes da amostra consiste em pequenos agricultores, representativos da maioria dos agricultores brasileiros, os quais podem observar que o custo dos FMIS se configura como um elemento restritivo para a adoção e para a intenção de uso da referida tecnologia.

Por exemplo, o estudo de Hossain e Quaddus (2011) teve como objetivo identificar os fatores de adoção de identificação por radiofrequência (RFID) e sua intenção de permanência em ambientes obrigatórios e voluntários. Os autores realizaram um estudo de campo, entrevistando oito organizações agrícolas na Austrália. Os resultados indicaram que o custo percebido é o principal fator na adoção, especialmente para as pequenas propriedades.

As **hipóteses H8 e H9** estabeleciam que a pressão externa (PE) impacta positivamente a intenção comportamental e o comportamento de uso, respectivamente. No âmbito desta pesquisa, entende-se que a PE se refere ao nível de influência exercido por um determinado setor ou parceiros comerciais na adoção de uma nova tecnologia pelos agricultores.

Consoante com o que foi previsto, os resultados demonstram que a pressão externa está positivamente relacionada com a intenção comportamental ($\beta=-0,2507$; $t=0,0627$; $p=0,000$), o que torna essa hipótese totalmente suportada.

O estudo anterior de Lima et al. (2018) explorou os fatores que influenciam a aceitação da Tecnologia da Informação Eletrônica (EID) pelos agricultores na Inglaterra e no País de Gales. Os resultados indicaram que os agricultores que se sentem pressionados a adotar a EID são significativamente menos propensos a fazê-lo do que aqueles que não se sentem pressionados

a adotar a tecnologia. Além disso, o trabalho sugeriu que a competição dentro do setor é considerada um importante fator determinante para a adoção da inovação. Corroborando, Low et al. (2011) afirmaram que as organizações que sentem a pressão das rápidas mudanças tecnológicas e a pressão externa devido a essas mudanças, tendem a adotar mais rapidamente as novas tecnologias para manter sua competitividade. Pois, tais fatores, podem exercer uma forte influência sobre os agricultores, que muitas vezes têm que se adaptar às mudanças nas demandas do mercado, às condições climáticas e às restrições regulatórias.

Contudo, não foram encontradas evidências estatísticas que suportem que a pressão externa está positivamente relacionada com o comportamento de uso ($\beta=0,0343$; $t=0,0830$; $p=0,3397$). Uma possibilidade para este resultado é que, embora os agricultores percebam a pressão do mercado para adotar FMIS, a amostra, por ser bem instruída, ao conhecer a tecnologia e avaliar a situação, pode encontrar alternativas para atender à necessidade latente.

Segundo Wang, Deng e Diao (2018), agricultores com alto nível de acesso à informação tendem a ser mais racionais e objetivos diante dos retornos do mercado e das pressões externas. Além disso, o estudo evidenciou que com um baixo nível de acesso à informação, os agricultores estarão propensos à enorme variabilidade subjetiva de seu julgamento sobre os retornos do mercado.

No contexto australiano, a identificação de gado por meio de tecnologia RFID é uma exigência legal. O estudo realizado por Hossain e Quaddus (2011) demonstrou que em ambientes regulamentados, sujeitos à pressão regulatória governamental, os agricultores adotavam a tecnologia RFID, sendo a conformidade legal o fator determinante para a adoção da mesma. Logo, pressupõe-se que a PE pode aumentar a intenção dos agricultores em adotar FMIS para manter a competitividade e atender às demandas do mercado. No entanto, os agricultores podem optar por adotar a tecnologia apenas se for um requisito obrigatório.

Por fim, a **hipótese H10** estabelecia que a intenção comportamental impacta positivamente no comportamento de uso. Porém, não foram encontradas evidências estatísticas que suportem a relação ($\beta=-0,0794$; $t=0,877$; $p=0,1903$). Apesar da IC ser apontada como um forte preditor do comportamento de uso real, em certos casos ela pode não afetar o comportamento de uso real da tecnologia.

Isso pode ocorrer quando há fatores externos e internos que podem influenciar o comportamento do usuário e impedir que a intenção comportamental se traduza em comportamento de uso real (VENKATESH; DAVIS, 2020). Nesses casos, a intenção comportamental pode ser alta, mas há fatores externos que impedem o usuário de usar a tecnologia, como falta de acesso à tecnologia, limitações técnicas ou custo elevado.

Além disso, em algumas situações, pode haver fatores psicológicos ou emocionais que influenciam o comportamento de uso real da tecnologia, independentemente da intenção comportamental (BHATTACHERJEE, 2001). Por exemplo, um usuário pode ter uma intenção comportamental alta de usar uma tecnologia, mas pode sentir medo ou ansiedade em relação à tecnologia, o que pode levar a um comportamento de uso real limitado ou nulo.

6 CONSIDERAÇÕES FINAIS

O principal propósito deste estudo foi analisar a relação entre os fatores contextuais e a intenção de adoção FMIS por agricultores. Para tanto, foi estendido o modelo UTAUT e proposto um modelo baseado em uma versão modificada da Teoria Clássica de Aceitação e Uso de Tecnologia Unificada (UTAUT) com a inclusão de dois constructos: “Custo Percebido” e “Pressão Externa”. De maneira geral, esta pesquisa lança luz sobre o fenômeno de aceitabilidade de uma tecnologia no campo, em especial as tecnologias digitais que imputam uma nova relação de operacionalização e gestão e são recentes no contexto agropecuário brasileiro.

Para validação do modelo foi realizada pesquisa junto a 158 agricultores brasileiros. O modelo final foi testado usando Modelagem de Equações Estruturais (MEE) pelo método dos mínimos quadrados (PLS-SEM). A partir da análise quantitativa, verificou-se que a Expectativa de Esforço tem impacto direto e positivo na Intenção Comportamental. Demonstrou-se que as facilidades no uso de uma tecnologia favorecem a intenção dos agricultores em adotá-la.

Verificou-se também que o Custo Percebido impacta negativamente o Comportamento de Uso, ou seja, as chances de os agricultores adquirirem determinada tecnologia diminuem à medida que seu custo é visto como elevado. Além disso, a adoção de uma tecnologia também pode representar custos significativos no seu uso, tanto financeiramente quanto em termos de tempo e recursos humanos, o que pode exigir mudanças significativas nos processos e estruturas da organização.

Outro aspecto confirmado pela pesquisa foi que Pressão Externa impacta positivamente a Intenção Comportamental. Deste modo, pelo setor estar inserido em uma rede de relacionamentos extensa, à qual diversos *stakeholders* exigem a adoção de tecnologias no âmbito agrícola, a pressão de várias deles deixa menos opções para os agricultores, ou adotam tal tecnologia ou “ficam fora do negócio”.

As contribuições deste estudo podem ser divididas entre teóricas e práticas. No que diz respeito à primeira contribuição desta pesquisa, cuja natureza é conceitual, foi apresentado um modelo específico para a adoção de tecnologias - baseado no modelo UTAUT acrescentado de dois constructos - voltado para o setor do agronegócio, o qual apresenta extrema importância na economia brasileira. Os determinantes da adoção da tecnologia podem diferir de local para local, portanto, avaliar a validade desse modelo com agricultores de diferentes culturas, tanto em países desenvolvidos quanto em desenvolvimento, contribui para preencher uma lacuna da literatura.

A segunda contribuição do estudo indica a necessidade de maior esclarecimento acerca da utilidade das tecnologias para os agricultores. Tais utilidades, precisam ser visíveis aos usuários que possuem intenção em adotar tecnologias digitais e o ambiente que eles se inserem é fundamental para que eles identifiquem que os benefícios são muito maiores do que os esforços necessários para utilizá-las.

Como terceira contribuição, corroborando com a literatura de modelos comportamentais, o presente estudo indica que a decisão de adotar uma tecnologia também inclui fatores não-econômicos. Isso contrapõe com a visão neoclássica do agricultor como um maximizador de lucros agindo em um mundo de plena certeza.

Em termos práticos, essa pesquisa apresenta uma originalidade por adaptar e aplicar o Modelo UTAUT ao contexto agrícola no Brasil. Além disso, é evidente a demonstração da importância quanto ao apoio da agricultura digital tanto para os agricultores como para outras partes interessadas - extensão rural, governo, empreiteiros, engenheiros agrônomos, trabalhadores agrícolas, etc.

Os agricultores se beneficiam indiretamente dos resultados deste estudo, pois os achados podem ser usados para melhorar os serviços de pesquisa e extensão, mas, principalmente, apoiar o desenvolvimento de novos produtos agrícolas permitindo que engenheiros testem e aperfeiçoem as características dos produtos, como sua interface e aplicabilidade, antes de serem lançados no mercado. Além disso, pode ajudar os desenvolvedores a criar soluções que sejam mais atraentes e acessíveis para os agricultores, facilitando a percepção de benefícios e a confiança na tecnologia. Principalmente, em encontrar formas de superar as barreiras e tornar os FMIS mais acessíveis e fáceis de usar.

Os achados deste estudo também beneficiam fabricantes e empresas do setor de tecnologias agrícolas que podem usufruir de uma compreensão mais aprofundada dos determinantes que influenciam a adoção dessas tecnologias para projetar e desenvolver novos FMIS. Isso pode ajudá-los a compreender e atender de forma eficiente às necessidades de seus clientes.

Os resultados também podem colaborar com os *policy makers* no desenvolvimento de estratégias eficazes para a promoção da agricultura digital. Por meio da identificação das necessidades dos agricultores, é possível compreender como a tecnologia pode atender a essas necessidades, seja melhorando a eficiência, aumentando a produtividade ou reduzindo custos. Além disso, se os responsáveis pela política agrícola conhecem os determinantes da adoção de uma tecnologia, podem monitorar a fase de implementação, criando um ambiente facilitador que promova a efetiva utilização da tecnologia pelos agricultores e não somente a intenção de utilizá-la.

Concomitantemente, os agentes de difusão de tecnologia, como assistência técnica privada e/ou governamental, cooperativas e associações, consultores independentes e empresas especializadas (privadas) ou organizações rurais e departamentos de extensão agrícola (públicos), podem enfatizar os determinantes de adoção na promoção da utilização das tecnologias entre os agricultores através de atividades como treinamentos, visitas técnicas e outras que os ajudem a usar as tecnologias e a superar eventuais barreiras para a adoção.

Além disso, tendo em vista a variedade de FMIS disponíveis no mercado, cada um com suas próprias características e recursos específicos, e a heterogeneidade dos agricultores, é importante que sejam implementadas políticas públicas que sejam condizentes com as diferentes realidades dos agricultores, bem como medidas econômicas, de treinamento e de apoio para fomentar o acesso às tecnologias aos agricultores, principalmente os pequenos e médios. Destaca-se também a importância da colaboração entre associações de agricultores, cooperativas, extensionistas e outros agentes da cadeia de suprimento que podem contribuir de maneira direta para a digitalização do setor.

Quanto as limitações do estudo, a primeira é que o estudo atual não inclui moderadores do UTAUT (ou seja, sexo, idade, experiência e voluntariedade de uso). Essas deficiências provavelmente serão superadas por estudos futuros. Além disso, é interessante que se busque incorporar outras variáveis que reflitam melhor essas características individuais e se busquem avaliá-las sob outros aspectos e em diferentes contextos.

Destaca-se ainda que a ausência da confirmação de alguns constructos ao proposto no modelo UTAUT original não indica, necessariamente, que tal constructo não influencia na adoção. Fatores como características da amostra, tradução do questionário e número de respondentes podem influenciar nos resultados. No entanto, isso deve ser investigado em maior profundidade por novos estudos.

O modelo desenvolvido acabou não identificando o impacto direto e positivo da Expectativa de Desempenho na Intenção Comportamental quanto à adoção de uma tecnologia, não tendo sido possível verificar se o agricultor é capaz de perceber os benefícios provenientes da adoção de uma tecnologia. Ao ser levada em consideração as características da propriedade e também dos agricultores, subentende-se que agricultores de grandes propriedades tendem a ter maior propensão na adoção de tecnologias, visto que elas impactam significativamente suas operações ao longo da cadeia de suprimentos.

O mesmo pode-se dizer dos construtos Influência Social e Condições Facilitadoras quanto sua influência direta na Intenção de Comportamento. O fato de que no primeiro os resultados sugerirem que os agricultores tomam decisões de adoção por conta própria e não consideram a

opinião de familiares, amigos ou profissionais nessas decisões pode significar que a pesquisa e a extensão devem se concentrar principalmente nos agricultores, e não em seus familiares. Entretanto, sugere-se novos estudos para corroborar tal afirmação.

Uma limitação empírica desta pesquisa diz respeito a natureza da amostra, mais precisamente a falta de uma amostra mais estratificada tanto geograficamente - 82% dos respondentes pertencem às regiões Sudeste e Sul - quanto em tamanho da lavoura - 66% dos agricultores atuam em áreas de até 50 hectares. Logo, suas atitudes no que consiste a aceitação de tecnologia podem diferir dos agricultores que atuam em áreas maiores.

Além disso, a amostra possui um nível de escolaridade bem superior à média nacional, já que 27% dos respondentes possuem graduação e 18% apresentam algum tipo de pós-graduação. O Censo Agropecuário (2017) afirma que no Brasil somente 5,6% dos chefes dos estabelecimentos realizaram curso superior e 0,3% pós-graduação.

Quanto às recomendações, sugere-se que pesquisadores que estudam modelos de adoção de tecnologias e o processo de tomada de decisão dos agricultores devem levar em consideração o tipo e a natureza da(s) tecnologia(s) sendo modelada(s), para que as teorias sobre como esses fatores influenciam na seleção de determinados critérios de decisão se tornem mais robustas e considerem as especificidades da referida tecnologia.

Sugere-se também que pesquisas futuras possam realizar a análise da moderação entre os construtos; bem como estudos que realizem comparações entre as regiões brasileiras, cuja população pode apresentar peculiaridades culturais, étnicas e sociais diferentes, como também entre os países desenvolvidos e em desenvolvimento. No entanto, o progresso tecnológico na agricultura digital é tão acelerado que os FMIS podem mudar consideravelmente suas características e, como consequência, alguns de seus determinantes de adoção.

Por fim, recomenda-se que os próximos estudos da temática realizem uma abordagem mista, de modo a analisar dados qualitativos como estudos de casos, para que sejam fornecidas visões mais aprofundadas acerca dos resultados encontrados. Sugere-se também que sejam acrescentados outros construtos para identificar os motivos pelos quais os agricultores desejam ou não adotar uma tecnologia.

REFERÊNCIAS

ABDULLAH, F. A.; SAMAH, B. A. Factors Impinging Farmers' Use of Agriculture Technology. *Asian Social Science*, v. 9, n. 3, p. 120-124, fev. 2013. Disponível em: <https://www.ccsenet.org/journal/index.php/ass/article/view/25282>. Acesso em: 09 jan. 2020.

ABDULLAHI, H. S.; MAHIEDDINE, F.; SHERIFF, R. E. Technology Impact on Agricultural Productivity: A Review of Precision Agriculture Using Unmanned Aerial Vehicles. *Wireless and Satellite Systems*, p. 388-400, dez. 2015. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-25479-1_29. Acesso em: 05 fev. 2020.

ACOSTA SALGADO, L. S. **Améliorations des modèles et méthodes d'évaluation de l'acceptabilité des solutions innovantes**. Applications dans le contexte du maintien à domicile des personnes âgées. 2021. Tese (Doutorado em Engenharia de Processos) - École Doctorale Sciences et Ingénierie des Molécules des Produits des Procédés et de l'Énergie, Université de Lorraine, Lorraine, 2021. Disponível em: <https://hal.archives-ouvertes.fr/tel-03229603/>. Acesso em: 08 fev. 2020.

ADANCO. **Compositemodeling**. Disponível em: <https://www.composite-modeling.com/>. Acesso em: 05 dez. 2022.

AGARWAL, R.; KARAHANNA, E. Time flies when you're having fun: Cognitive absorption and beliefs about information technology usage. **MIS quarterly**, v. 24, n. 4, p. 665-694, dez. 2000. Disponível em: <https://www.jstor.org/stable/3250951>. Acesso em: 10 dez. 2020.

AGARWAL, R.; PRASAD, J. The Role of Innovation Characteristics and Perceived Voluntariness in the Acceptance of Information Technologies. **Decision Sciences**, v. 28, n. 3, p. 557-582, jul. 1997. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1540-5915.1997.tb01322.x>. Acesso em: 11 mai. 2022.

AJZEN, I. From intentions to actions: A theory of planned behavior. In: Kuhl, J.; Beckmann, J. **SSSP Springer Series in Social Psychology**. Berlin: Action Control, 1985. p. 11-39.

Disponível em: https://link.springer.com/chapter/10.1007/978-3-642-69746-3_2. Acesso em: 02 mai. 2021.

AJZEN, I.; FISHBEIN, M. The prediction of behavioral intentions in a choice situation. **Journal of Experimental Social Psychology**, v. 5, n. 4, p. 400-416, out. 1969. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/002210316990033X>. Acesso em: 18 mar. 2021.

ALAM, M. Z. et al. Factors influencing the adoption of mHealth services in a developing country: A patient-centric study. **International journal of information management**, v. 50, p. 128-143, fev. 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0268401218310223>. Acesso em: 23 jan. 2022.

ALAZAB, M. et al. Blockchain technology in supply chain management: an empirical study of the factors affecting user adoption/acceptance. **Cluster Computing**, v. 24, n. 1, p. 83-101, nov. 2020. Disponível em: <https://link.springer.com/article/10.1007/s10586-020-03200-4>. Acesso em: 11 dez. 2020.

ANDRITOIU, D. et al. Agriculture autonomous monitoring and decisional mechatronic system. *In: 2018 19th International carpathian control Conference (ICCC)*. Szilvasvarad, IEEE, 2018. p. 241-246. Disponível em: <https://ieeexplore.ieee.org/document/8399635>. Acesso em: 11 jan. 2020.

ANNOSI, M. C. et al. Is the trend your friend? An analysis of technology 4.0 investment decisions in agricultural SMEs. **Computers in Industry**, v. 109, p. 59-71, ago. 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0166361518305992>. Acesso em: 01 dez. 2020.

ANSELM, A. A. **Adoção da agricultura de precisão no Rio Grande do Sul**. 2012. Dissertação (Mestrado em Agronegócios) – Centro de Estudos e Pesquisas em Agronegócios, Universidade Federal do Rio Grande do Sul, 2012. Disponível em: <https://lume.ufrgs.br/handle/10183/40495>. Acesso em: 28 nov. 2020.

ANTOLINI, L. S. **Condicionantes de adoção de agricultura de precisão por produtores de grãos**. 2015. Dissertação (Mestrado em Ciências) - Departamento de Administração, Universidade de São Paulo, 2015. Disponível em: <https://www.teses.usp.br/teses/disponiveis/96/96132/tde-22022016-170917/pt-br.php>. Acesso em: 05 nov. 2021.

ARFI, W. B. et al. Understanding acceptance of eHealthcare by IoT natives and IoT immigrants: An integrated model of UTAUT, perceived risk, and financial cost. *Technological Forecasting and Social Change*, v. 163, p. 120437, fev. 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0040162520312634>. Acesso em: 10 dez. 2022.

ARIBE JR, S. G. et al. Ma-Ease: An Android-Based Technology for Corn Production and Management. **Pertanika Journal of Science & Technology**, v. 27, n. 1, p. 49-68, jan. 2019. Disponível em: https://www.researchgate.net/profile/Sales-Arife-Jr-2/publication/331061298_MaEase_An_AndroidBased_Technology_for_Corn_Production_and_Management/links/5c63853645851582c3e415ff/Ma-Ease-An-Android-Based-Technology-for-Corn-Production-and-Management.pdf. Acesso em: 29 ago. 2022.

ARMENTA-MEDINA, D. et al. Trends on advanced information and communication technologies for improving agricultural productivities: A bibliometric analysis. **Agronomy**, v. 10, n. 12, p. 1989, dez. 2020. Disponível em: <https://www.mdpi.com/2073-4395/10/12/1989>. Acesso em: 12 out. 2022.

BALAFOUTIS, A. T. et al. Smart Farming Technologies - Description, Taxonomy and Economic Impact. In: **Precision agriculture: Technology and economic perspectives**. Springer, 2017. p. 21-77. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-68715-5_2. Acesso em: 18 jan. 2022.

BANDURA, A. The explanatory and predictive scope of self-efficacy theory. **Journal of social and clinical psychology**, v. 4, n. 3, p. 359-373, 1986. Disponível em: <https://guilfordjournals.com/doi/10.1521/jscp.1986.4.3.359>. Acesso em: 29 nov. 2021.

BASSOI, L. H. et al. Agricultura de precisão e agricultura digital. **Revista digital de tecnologia cognitivas**, n. 20, p. 17-36, dez. 2019. Disponível em: <https://revistas.pucsp.br/teccogs/article/view/48542>. Acesso em: 25 fev. 2022.

BATALHA, M. O.; SILVA, A. L. Gerenciamento de sistemas agroindustriais: definições, especificidades e correntes metodológicas. In: BATALHA, M. O. **Gestão Agroindustrial**. São Paulo: Atlas, 2021 p. 1-62. Disponível em: [https://www.bdpa.cnptia.embrapa.br/consulta/busca?b=ad&id=859185&biblioteca=vazio&busca=autoria:%22BATALHA,%20M.%20O.%20\(Coord.\).%22&qFacets=autoria:%22BATALHA,%20M.%20O.%20\(Coord.\).%22&sort=&paginacao=t&paginaAtual=1](https://www.bdpa.cnptia.embrapa.br/consulta/busca?b=ad&id=859185&biblioteca=vazio&busca=autoria:%22BATALHA,%20M.%20O.%20(Coord.).%22&qFacets=autoria:%22BATALHA,%20M.%20O.%20(Coord.).%22&sort=&paginacao=t&paginaAtual=1). Acesso em: 10 abr. 2020.

BAUDIER, P.; AMMI, C.; DEBOEUF-ROUCHON, M. Smart home: Highly-educated students' acceptance. **Technological Forecasting and Social Change**, v. 153, p. 119355, abr. 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0040162518300192> . Acesso em: 25 abr. 2022.

BAUMGART-GETZ, A.; PROKOPY, L. S.; FLORESS, K. Why farmers adopt best management practice in the United States: A meta-analysis of the adoption literature. **Journal of Environmental Management**, v. 96, n. 1, p. 17-25, abr. 2012. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0301479711003598>. Acesso em: 3 jan. 2022.

BELANCHE, A. et al. Optimizing management of dairy goat farms through individual animal data interpretation: A case study of smart farming in Spain. **Agricultural Systems**, v. 173, p. 27-38, jul. 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0308521X17311319>. Acesso em: 16 out. 2020.

BEZA, E. et al. Exploring farmers' intentions to adopt mobile Short Message Service (SMS) for citizen science in agriculture. **Computers and Electronics in Agriculture**, v. 151, p. 295-310, ago. 2018. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0168169916311279>. Acesso em: 4 fev. 2022.

BIRCH, D.; BURNETT, B. Bringing academics on board: Encouraging institution-wide diffusion of e-learning environments. **Australasian Journal of Educational Technology**, v. 25, n. 1, p. 117-134, fev. 2009. Disponível em: <https://ajet.org.au/index.php/AJET/article/view/1184>. Acesso em: 29 dez. 2021.

BOBILLIER-CHAUMON, M.; DUBOIS, M. L'adoption des technologies en situation professionnelle: quelles articulations possibles entre acceptabilité et acceptation? **Le travail humain**, v. 72, n. 4, p. 355-382, set. 2019. Disponível em: <https://www.cairn.info/revue-le-travail-humain-2009-4-page-355.htm>. Acesso em: 12 ago. 2021.

BOLFE, E. L. et al. **Agricultura digital no Brasil: tendências, desafios e oportunidades: resultados de pesquisa online**. Campinas: Embrapa, 2020. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1127064/agricultura-digital-no-brasil-tendencias-desafios-e-oportunidades-resultados-de-pesquisa-online>. Acesso em: 10 mar. 2021.

BOLFE, E. L. et al. Desafios, tendências e oportunidades em agricultura digital no Brasil. In: MASSRUHÁ; S. M. F. S et al. **Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas**. Brasília, DF: Embrapa, 2020. p. 380-406. Disponível em: <https://www.alice.cnptia.embrapa.br/handle/doc/1126283>. Acesso em: 13 ago. 2021.

BONABANA-WABBI, J. **Assessing factors affecting adoption of agricultural technologies: The case of Integrated Pest Management (IPM) in Kumi District Eastern Uganda**. 2002. Dissertação (Doutorado em Economia agrícola aplicada) - Virginia Polytechnic Institute and State University, 2002. Disponível em: <https://vtechworks.lib.vt.edu/handle/10919/36266>. Acesso em: 19 mar. 2021.

BONKE, V. et al. Willingness to pay for smartphone apps facilitating sustainable crop protection. **Agronomy for Sustainable Development**, v. 38, n. 5, set. 2018. Disponível em: <https://link.springer.com/article/10.1007/s13593-018-0532-4>. Acesso em: 12 jul. 2022.

BORGIA, E. The Internet of Things vision: Key features, applications and open issues. **Computer Communications**, v. 54, p. 1-31, dez. 2014. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0140366414003168>. Acesso em: 29 out. 2020.

BOURSIANIS, A. D. et al. Internet of Things (IoT) and Agricultural Unmanned Aerial Vehicles (UAVs) in smart farming: A comprehensive review. **Internet of Things**, v. 18, p. 100187, mai. 2022. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S2542660520300238>. Acesso em: 30 nov. 2022.

BRASIL. Ministério da Ciência, Tecnologia, Inovações e Comunicações (MCTIC). **Estratégia Brasileira de Transformação Digital: E-digital**. mar. 2018. Disponível em: <https://www.gov.br/governodigital/pt-br/estrategia-de-governanca-digital/eDigital.pdf>. Acesso em: 19 mai. 2021

BRAUN, A.-T.; COLANGELO, E.; STECKEL, T. Farming in the Era of Industrie 4.0. **Procedia CIRP**, v. 72, p. 979–984, 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2212827118303342>. Acesso em: 12 mar. 2020.

BYRNE, B. M. **Structural equation modeling with LISREL, PRELIS, and SIMPLIS: Basic concepts, applications, and programming**. 1 ed. Nova York, 1998. Disponível em: <https://www.taylorfrancis.com/books/mono/10.4324/9780203774762/structural-equation-modeling-lisrel-prelis-simplis-barbara-byrne>. Acesso em: 29 out. 2020.

CABRERA-SÁNCHEZ, J.-P.; VILLAREJO-RAMOS, Á. F. Factors affecting the adoption of big data analytics in companies. **Revista de Administração de Empresas**, v. 59, n. 6, p. 415-429, dez. 2019. Disponível em: <https://www.scielo.br/j/rae/a/KxjtdnnkmCDL4FZs3q6psFQ/?lang=en>. Acesso em: 13 dez. 2022.

CAFFARO, F. et al. Drivers of farmers' intention to adopt technological innovations in Italy: The role of information sources, perceived usefulness, and perceived ease of use. **Journal of Rural Studies**, v. 76, p. 264-271, mai. 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0743016719308149>. Acesso em: 28 ago. 2021.

CAROLAN, M. Publicising Food: Big Data, Precision Agriculture, and Co-Experimental Techniques of Addition. **Sociologia Ruralis**, v. 57, n. 2, p. 135-154, fev. 2016. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/soru.12120>. Acesso em: 16 jan. 2022.

CARRER, M. J.; DE SOUZA FILHO, H. M.; BATALHA, M. O. Factors influencing the adoption of Farm Management Information Systems (FMIS) by Brazilian citrus farmers. **Computers and Electronics in Agriculture**, v. 138, p. 11-19, jun. 2017. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169916302629>. Acesso em: 16 dez. 2021.

CARRIERI, A. de P. **A racionalidade administrativa: os sistemas de produção e o processo de decisão-ação em unidades de produção rural**. 1992. Dissertação (Mestrado em Administração Rural) - Escola Superior de Agricultura de Lavras, 1992. Disponível em: <http://repositorio.ufla.br/jspui/handle/1/29724?locale=en>. Acesso em: 12 dez. 2021.

CAVALLO, E. et al. Strategic management implications for the adoption of technological innovations in agricultural tractor: the role of scale factors and environmental attitude. **Technology Analysis & Strategic Management**, v. 26, n. 7, p. 765-779, 2014. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/09537325.2014.890706>. Acesso em: 22 jun. 2021.

CHHACHHAR, A. R.; CHEN, C.; JIN, J. Mobile phone impact on agriculture and price information among farmers. **Indian Journal of Science and Technology**, v. 9, n. 39, p. 1-11, 2016. Disponível em: <https://sciresol.s3.us-east-2.amazonaws.com/IJST/Articles/2016/Issue-39/Article52.pdf>. Acesso em: 17 nov. 2020.

CHIH-PEI, H. U.; CHANG, Y.Y. John W. Creswell, research design: Qualitative, quantitative, and mixed methods approaches. **Journal of Social and Administrative Sciences**, v. 4, n. 2, p. 205-207, 2017. Disponível em: <http://www.kspjournals.org/index.php/JSAS/article/view/1313/1341>. Acesso em: 15 set. 2022.

CHIN, W. W. **Overview of the PLS Method**. University of Houston, 1997.

CHONG, A. Y.-L.; CHAN, F. T. S.; OOI, K.-B. Predicting consumer decisions to adopt mobile commerce: Cross country empirical examination between China and Malaysia. **Decision Support Systems**, v. 53, n. 1, p. 34-43, abr. 2012. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0167923611002302>. Acesso em: 14 fev. 2022.

COMPEAU, D. R.; HIGGINS, C. A. Computer self-efficacy: Development of a measure and initial test. **MIS quarterly**, v. 19, n. 2, p. 189-211. Disponível em: <https://www.jstor.org/stable/249688>. Acesso em: 13 fev. 2022.

COOPER, D.R.; SCHINDLER, P.S. **Business Research Methods**. Boston: McGraw-Hill Irwin, 2003.

CULLEN, R.; FORBES, S. L.; GROUT, R. Non-adoption of environmental innovations in wine growing. New Zealand. **Journal of Crop and Horticultural Science**, v. 41, n. 1, p. 41-48, 2013. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/01140671.2012.744760>. Acesso em: 8 dez. 2021.

DA SILVEIRA, F.; LERMEN, F. H.; AMARAL, F. G. An overview of agriculture 4.0 development: Systematic review of descriptions, technologies, barriers, advantages, and disadvantages. **Computers and Electronics in Agriculture**, v. 189, p. 106405, out. 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169921004221>. Acesso em: 13 dez. 2022.

DALMORO, M.; VIEIRA, K. M. Dilemas na construção de escalas Tipo Likert: o número de itens e a disposição influenciam nos resultados?. **Revista gestão organizacional**, v. 6, n. 3, p. 161-174, mar. 2013. Disponível em: <https://bell.unochapeco.edu.br/revistas/index.php/rgo/article/view/1386>. Acesso em: 12 abr. 2022.

DAVIS, F. D. **A technology acceptance model for empirically testing new end-user information systems**: Theory and results. 1985. Tese. (Doutorado em Gerenciamento) - School of Management, Massachusetts Institute of Technology, 1985. Disponível em: <https://dspace.mit.edu/handle/1721.1/15192>. Acesso em: 9 dez. 2021.

DAVIS, F. D.; BAGOZZI, R. P.; WARSHAW, P. R. Extrinsic and Intrinsic Motivation to Use Computers in the Workplace1. **Journal of Applied Social Psychology**, v. 22, n. 14, p. 1111-1132, jul. 1992. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1559-1816.1992.tb00945.x>. Acesso em: 18 out. 2021.

DAVIS, F. D.; BAGOZZI, R. P.; WARSHAW, P. R. User acceptance of computer technology: a comparison of two theoretical models. **Management science**, v. 35, n. 8, p. 982-1003, ago. 1989. Disponível em: <https://www.jstor.org/stable/2632151>. Acesso em: 12 nov. 2020.

DEVELLIS, R. F. **Scale development**: Theory and applications. London: Sage publications, 2016.

DIAS, M. C.; ZWICKER, R.; VICENTIN, I. C. Análise do modelo de aceitação de tecnologia de Davis. **Revista Spei**, v. 4, n. 2, p. 15-23, dez. 2003. Disponível em: <https://repositorio.usp.br/item/001378215>. Acesso em: 21 set. 2020.

DIEKMANN, M.; THEUVSEN, L. Non-participants interest in CSA – Insights from Germany. **Journal of Rural Studies**, v. 69, p. 1-10, jul. 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0743016718306120>. Acesso em: 28 mar. 2022.

DOBRE, C.; DRAGOMIR, A.; PREDA, G. Consumer Innovativeness: A Marketing Approach. **Management & Marketing**, v. 4, n. 2, p. 19-34, 2009. Disponível em: <http://www.managementmarketing.ro/pdf/articole/133.pdf>. Acesso em: 19 abr. 2022.

EASTWOOD, C.; KLERKX, L.; NETTLE, R. Dynamics and distribution of public and private research and extension roles for technological innovation and diffusion: Case studies of the implementation and adaptation of precision farming technologies. **Journal of Rural Studies**, v. 49, p. 1-12, jan. 2017. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0743016716305903>. Acesso em: 20 dez. 2021.

EL BILALI, H.; ALLAHYARI, M. S. Transition towards sustainability in agriculture and food systems: Role of information and communication technologies. **Information Processing in Agriculture**, v. 5, n. 4, p. 456-464, dez. 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214317318301367>. Acesso em: 28 dez. 2020.

FAO. **Statistical Yearbook World Food And Agriculture**. Food and Agriculture Organization of the United Nations, Rome., 2022. Disponível em: <https://www.fao.org/documents/card/en/c/cc2211en>. Acesso em: 02 jan. 2023.

FAPESP. Revista Pesquisa. **A força das agtechs**: Startups orientadas ao agronegócio reforçam ecossistema de inovação do campo. Edição 287, 2020. Disponível em: <http://revistapesquisa.fapesp.br/quem-somos/>. Acesso em: 18 dez. 2021.

FARIDI, A. A.; KAVOOSI-KALASHAMI, M.; EL BILALI, H. Attitude components affecting adoption of soil and water conservation measures by paddy farmers in Rasht County, Northern Iran. **Land use policy**, v. 99, p. 104885, dez. 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0264837720308796> . Acesso em: 29 mai. 2022.

FEDDER, G.; JUST, E. R.; ZILBERMAN, D. Adoption of agricultural innovation in developing countries. **Economic Development and Cultural Change**, v. 33, n. 2, p. 255-298, jan. 1985. Disponível em: <https://www.jstor.org/stable/1153228>. Acesso em: 14 out. 2022.

FEDER, G.; UMALI, D. L. The adoption of agricultural innovations. **Technological Forecasting and Social Change**, v. 43, n. 3-4, p. 215-239, mai. 1993. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/004016259390053A>. Acesso em: 19 jan. 2022.

FEDERICO, G. **Feeding the world**: an economic history of agriculture. Princeton University Press, 2008.

FICHMAN, R. G. Information technology diffusion: a review of empirical research. In: **ICIS**. Cambridge: MIT Sloan School of Management, 1992. p. 195-206. Disponível em: <https://aisel.aisnet.org/icis1992/39/> . Acesso em: 21 jan. 2022.

FLEMING, A. et al. Is big data for big farming or for everyone? Perceptions in the Australian grains industry. **Agronomy for Sustainable Development**, v. 38, n. 3, abr. 2018. Disponível em: <https://link.springer.com/article/10.1007/s13593-018-0501-y>. Acesso em: 19 out. 2022.

FOON, Y.; FAH, B. C. Y. Internet banking adoption in Kuala Lumpur: an application of UTAUT model. **International Journal of Business and Management**, v. 6, n. 4, p. 161, 2011.

Disponível em: <https://ccsenet.org/journal/index.php/ijbm/article/view/10083>. Acesso em: 5 abr. 2022.

FORNELL, C.; LARCKER, D. F. Structural equation models with unobservable variables and measurement error: Algebra and statistic. **Journal of Marketing Research**, v. 18, n. 3, p. 382-388, ago. 1981. Disponível em: <https://www.jstor.org/stable/3150980>. Acesso em: 12 jul. 2022.

FORZA, C. Survey research in operations management: a process-based perspective. **International Journal of Operations & Production Management**, v. 22, n. 2, p. 152-194, 2022. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/01443570210414310/full/html>. Acesso em: 9 ago. 2021.

FOSTER, A. D.; ROSENZWEIG, M. R. Microeconomics of technology adoption. **Annu. Rev. Econ.**, v. 2, n. 1, p. 395-424, 2010. Disponível em: <https://www.annualreviews.org/doi/abs/10.1146/annurev.economics.102308.124433>. Acesso em: 28 mai. 2020.

FOSTER, A. D.; ROSENZWEIG, M. R. Technical change and human-capital returns and investments: evidence from the green revolution. **The American economic review**, v. 86, n.4, p. 931-953, set. 1996. Disponível em: <https://www.jstor.org/stable/2118312> Acesso em: 30 jun. 2020.

FOUNTAS, S. et al. Farm management information systems: Current situation and future perspectives. **Computers and Electronics in Agriculture**, v. 115, p. 40-50, jul. 2015. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169915001337>. Acesso em: 19 abr. 2020.

FOX, N.; HUNN, A.; MATHERS, N. **Sampling and sample size calculation**. East Midlands/Yorkshire: the National Institutes for Health Research. Research Design Service for the East Midlands/Yorkshire & the Humber, 2009.

FREEMAN, C.; PEREZ, C. **Structural crises of adjustment: business cycles**. Technical change and economic theory. Londres: Pinter, 1988.

FRESCO, R.; FERRARI, G. Enhancing precision agriculture by Internet of Things and cyber physical systems. **Suplemento**, v. 125, p. 53-60, 2018. Disponível em:

http://www.tlc.unipr.it/ferrari/Publications/Journals/FrFe_AST18.pdf. Acesso em: 18 set. 2021.

GARCÍA-CORTIJO, M. C.; CASTILLO-VALERO, J. S.; CARRASCO, I. Innovation in rural Spain. What drives innovation in the rural-peripheral areas of southern Europe? **Journal of Rural Studies**, v. 71, p. 114-124, out. 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0743016718308830>. Acesso em: 12 out. 2022.

GIUA, C.; MATERIA, V. C.; CAMANZI, L. Management information system adoption at the farm level: evidence from the literature. **British Food Journal**, v. 123, n. 3, p. 884-909, nov. 2020. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/BFJ-05-2020-0420/full/html>. Acesso em: 14 nov. 2022.

GIUA, C.; MATERIA, V. C.; CAMANZI, L. Smart farming technologies adoption: Which factors play a role in the digital transition?. **Technology in Society**, v. 68, p. 101869, fev. 2022. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0160791X22000100>. Acesso em: 10 jan. 2022.

GOODMAN, R. M.; HAUPTLI, H.; CROSSWAY, A.; KNAUF, V. C. Gene transfer in crop improvement. **Science**, v. 236, n. 4797, p. 48-54, abr. 1987. Disponível em: https://www.science.org/doi/10.1126/science.236.4797.48?url_ver=Z39.88-2003&rfr_id=ori:rid:crossref.org&rfr_dat=cr_pub%20%200pubmed. Acesso em: 18 jul. 2022.

GOULD, B. W.; SAUPE, W. E.; KLEMME, R. M. Conservation tillage: the role of farm and operator characteristics and the perception of soil erosion. **Land economics**, v. 65, n. 2, p. 167-182, mai. 1989. Disponível em: <https://www.jstor.org/stable/3146791>. Acesso em: 11 fev. 2022.

GRILICHES, Z. Hybrid corn: An exploration in the economics of technological change. *Econometrica*, **Journal of the Econometric Society**, v. 24, n. 4, p. 501-522, out. 1957. Disponível em: <https://www.jstor.org/stable/1905380>. Acesso em: 10 abr. 2022.

HABERLI JR, C.; OLIVEIRA, T.; YANAZE, M. Understanding the determinants of adoption of enterprise resource planning (ERP) technology within the agri-food context: the case of the Midwest of Brazil. **International Food and Agribusiness Management Review**, v. 20, n. 5,

p. 729-746, 2017. Disponível em: <https://econpapers.repec.org/article/agsifaamr/266414.htm>. Acesso em: 19 dez. 2021.

HAN, H.; XIONG, J.; ZHAO, K. Digital inclusion in social media marketing adoption: the role of product suitability in the agriculture sector. **Information Systems and e-Business Management**, v. 20, n. 4, p. 657-683, mai. 2021. Disponível em: <https://link.springer.com/article/10.1007/s10257-021-00522-7>. Acesso em: 10 jan. 2022.

HENSELER, J. Partial least squares path modeling. **Advanced methods for modeling markets**, p. 361-381, ago. 2017. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-53469-5_12. Acesso em: 05 jan. 2022.

HENSELER, J.; RINGLE, C. M.; SINKOVICS, R. R. The use of partial least squares path modeling in international marketing. In: New challenges to international marketing. **Emerald Group Publishing Limited**, v. 20, p. 277-319, mar. 2009. Disponível em: [https://www.emerald.com/insight/content/doi/10.1108/S14747979\(2009\)0000020014/full/html](https://www.emerald.com/insight/content/doi/10.1108/S14747979(2009)0000020014/full/html). Acesso em: 08 nov. 2022.

HAIR JR, J. F. et al. **A primer on partial least squares structural equation modeling**. (PLS-SEM). Sage publications, 2016.

HAIR JR, J. F. et al. **Advanced issues in partial least squares structural equation modeling**. Sage publications, 2017.

HAIR JR, J. F. et al. **Análise multivariada de dados**. Bookman editora, 2009.

HALL, B. H.; KHAN, B.; JONES, D. C. **New economy handbook**. Waltham. Academic Press, 2002.

HASHEM, I. A. T. et al. The rise of “big data” on cloud computing: Review and open research issues. **Information Systems**, v. 47, p. 98-115, jan. 2015. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0306437914001288>. Acesso em: 2 fev. 2021.

HOSSAIN, M. A.R; QUADDUS, M. **Impact of External Environmental Factors on RFID Adoption in Australian Livestock Industry: An Exploratory Study**. In: PACIS. 2010. p. 171. Disponível em: <https://espace.curtin.edu.au/handle/20.500.11937/19123>. Acesso em: 28 jan. 2021.

HÖTZEL, M. J.; SNEDDON, J. N. The role of extensionists in Santa Catarina, Brazil, in the adoption and rejection of providing pain relief to calves for dehorning. **Journal of Dairy Science**, v. 96, n. 3, p. 1535-1548, mar. 2013. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0022030213000362>. Acesso em: 16 fev. 2022.

HUH, J.-H.; KIM, K.-Y. Time-Based Trend of Carbon Emissions in the Composting Process of Swine Manure in the Context of Agriculture 4.0. **Processes**, v. 6, n. 9, p. 168, set. 2018. Disponível em: <https://www.mdpi.com/2227-9717/6/9/168>. Acesso em: 21 abr. 2022.

HUNT JR, E. R.; DAUGHTRY, C. S. T. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture?. **International journal of remote sensing**, v. 39, n. 15-16, p. 5345-5376, 2018. Disponível em: <https://www.tandfonline.com/action/showCitFormats?doi=10.1080%2F01431161.2017.1410300>. Acesso em: 13 mai. 2022.

IBGE. **Censo Agropecuário 2017**. Rio de Janeiro, 2018. Disponível em: <https://sidra.ibge.gov.br/pesquisa/censo-agropecuario/censo-agropecuario-2017>. Acesso em: 19 mar. 2021.

IBRAHIM, A. M.; HASSAN, M.; GUSAU, A. L. Factors influencing acceptance and use of ICT innovations by agribusinesses. **Journal of Global Information Management (JGIM)**, v. 26, n. 4, p. 113-134, 2018. Disponível em: <https://www.igi-global.com/gateway/article/210198>. Acesso em: 14 set. 2022.

ISLAM, M. S.; GRÖNLUND, A. Factors influencing the adoption of mobile phones among the farmers in Bangladesh: Theories and practices. **The International Journal on Advances in ICT for Emerging Regions**, v. 4, n. 1, p. 4-14, abr. 2011. Disponível em: <https://journal.icter.org/index.php/ICTer/article/view/95>. Acesso em: 20 jan. 2020.

JAFRY, T.; O'NEILL, D. H. The application of ergonomics in rural development: a review. **Applied Ergonomics**, v. 31, n. 3, p. 263-268, jun. 2000. Disponível em: https://www.sciencedirect.com/science/article/pii/S0003687099000514?casa_token=Pwzbokj8xNgAAAAA:CKaBXbLjb2MKwoKhPCQWbBPpVyj7c4oWjnLWhUozuHEQEmapVFHYZVZ8ttvo2uK9herK0NzYoNc. Acesso em: 5 ago. 2022.

JAKKU, E. et al. “If they don’t tell us what they do with it, why would we trust them?” Trust, transparency and benefit-sharing in Smart Farming. **NJAS: Wageningen Journal of Life Sciences**, v. 90-91, n. 1, p. 1-13, dez. 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1573521418301842>. Acesso em: 12 mar. 2022.

KAHENYA, W. D.; SAKWA, M.; IRAVO, M. Assessing use of information communication technologies among agricultural extension workers in Kenya Using Modified UTAUT Model. **International Journal of Sciences: Basic and Applied Research**, v. 16, n. 2, p. 11-22, jun. 2014. Disponível em: <https://gssrr.org/index.php/JournalOfBasicAndApplied/article/view/2378>. Acesso em: 06 mai. 2022.

KALOXYLOS, A. et al. A cloud-based Farm Management System: Architecture and implementation. **Computers and Electronics in Agriculture**, v. 100, p. 168-179, jan. 2014. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169913002846>. Acesso em: 2 jan. 2022.

KAMILARIS, A.; KARTAKOULLIS, A.; PRENAFETA-BOLDÚ, F. X. A review on the practice of big data analysis in agriculture. **Computers and Electronics in Agriculture**, v. 143, p. 23-37, dez. 2017. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169917301230>. Acesso em: 22 abr. 2021.

KATUNG, E.; AKANKWASA, K. Community-based organizations and their effect on the adoption of agricultural technologies in Uganda: a study of banana (*Musa spp.*) pest management technology. In: **IV International Symposium on Banana: International Conference on Banana and Plantain in Africa: Harnessing International**. 2008. p. 719-726. Disponível em: https://www.actahort.org/books/879/879_77.htm. Acesso em: 29 abr. 2021.

KERLINGER, F. N. Analysis Of Covariance Structure Tests Of A Criterial Referents Theory Of Attitudes. **Multivariate Behavioral Research**, v. 15, n. 4, p. 403-422, out. 1980. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/26810877/>. Acesso em: 13 fev. 2020.

KERNECKER, M. et al. Experience versus expectation: farmers' perceptions of smart farming technologies for cropping systems across Europe. **Precision Agriculture**, v. 21, n. 1, p. 34–50, 3 abr. 2019. Disponível em: <https://link.springer.com/article/10.1007/s11119-019-09651-z>. Acesso em: 28 nov. 2022.

KIM, D.; YAGI, H.; KIMINAMI, A. Exploring information uses for the successful implementation of farm management information system: A case study on a paddy rice farm enterprise in Japan. **Smart Agricultural Technology**, v. 3, p. 100119, fev. 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2772375522000843>. Acesso em: 01 jan. 2023.

KIM, W.-S.; LEE, W.-S.; KIM, Y.-J. A Review of the Applications of the Internet of Things (IoT) for Agricultural Automation. **Journal of Biosystems Engineering**, v. 45, n. 4, p. 385-400, nov. 2020. Disponível em: <https://link.springer.com/article/10.1007/s42853-020-00078-3>. Acesso em: 9 jul. 2020.

KLERKX, L.; JAKKU, E.; LABARTHE, P. A review of social science on digital agriculture, smart farming and agriculture 4.0: New contributions and a future research agenda. **NJAS: Wageningen Journal of Life Sciences**, v. 90-91, n. 1, p. 1-16, dez. 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1573521419301769>. Acesso em: 30 nov. 2020.

KLERKX, L.; ROSE, D. Dealing with the game-changing technologies of Agriculture 4.0: How do we manage diversity and responsibility in food system transition pathways? **Global Food Security**, v. 24, p. 100347, mar. 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2211912419301804>. Acesso em: 16 ago. 2021.

KLINE, R. B. **Principles and practice of structural equation modeling**. Guilford publications, 2015.

KNIERIM, A. et al. Smart farming technology innovations – Insights and reflections from the German Smart-AKIS hub. **NJAS: Wageningen Journal of Life Sciences**, v. 90-91, n. 1, p. 1-10, dez. 2019. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S157352141830232X>. Acesso em: 23 set. 2021.

KNOWLER, D.; BRADSHAW, B. Farmers' adoption of conservation agriculture: A review and synthesis of recent research. **Food policy**, v. 32, n. 1, p. 25-48, fev. 2007. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0306919206000224>. Acesso em: 10 out. 2022.

KOROTCHENYA, V. Digital agriculture and agricultural production efficiency: exploring prospects for Russia. **Revista ESPACIOS**, v. 40, n. 22, p. 22-35, jul. 2019. Disponível em: <https://ww.revistaespacios.com/a19v40n22/a19v40n22p22.pdf>. Acesso em: 2 mar. 2022.

KRUIZE, J. W. et al. A reference architecture for Farm Software Ecosystems. **Computers and Electronics in Agriculture**, v. 125, p. 12-28, jul. 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169916301296>. Acesso em: 15 set. 2020.

KRÜMPEL, J. **Factors influencing the use of mobile applications by farmers for data and information management**. 2019. Tese (Doutorado em estudos de negócios) - Wageningen University, 2019. Disponível em: <https://edepot.wur.nl/513068>. Acesso em: 10 set. 2020.

KUCZERA, G. A.; HARDY, M. J.; COOMBES, P. J. Embedded Hierarchical Network Modelling: A Means to Integrate Across Scales and Systems. *In: 7th International Conference on Urban Drainage Modelling and the 4th International Conference on Water Sensitive Urban Design; Book of Proceedings*. Monash University, 2006. p. 469. Disponível em: <https://search.informit.org/doi/abs/10.3316/informit.619651813185730>. Acesso em: 7 out. 2020.

KYOBÉ, M. Investigating the key factors influencing ICT adoption in South Africa | Emerald Insight. **Journal of Systems and Information Technology**, v. 13, n. 3, p. 255-267, ago. 2013. Disponível

em:<<https://www.emerald.com/insight/content/doi/10.1108/13287261111164844/full/html>>.

Acesso em: 30 mar. 2021.

LAJOIE-O'MALLEY, A. et al. The future(s) of digital agriculture and sustainable food systems: An analysis of high-level policy documents. **Ecosystem Services**, v. 45, p. 101183, out. 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S221204162030125X>. Acesso em: 28 ago. 2020.

LAMBERT, D. M.; COOPER, M. C.; PAGH, J. D. Supply chain management: implementation issues and research opportunities. **The international journal of logistics management**, v. 9, n. 2, p. 1-20, 1998. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/09574099810805807/full/html>. Acesso em: 19 abr. 2020.

LEE, J.; HEO, C. The Effect of Technology Acceptance Factors on Behavioral Intention for Agricultural Drone Service by Mediating Effect of Perceived Benefits. **Journal of Digital Convergence**, v. 18, n. 8, p. 151-167, ago. 2020. Disponível em: <http://koreascience.or.kr/article/JAKO202024852035956.page>. Acesso em: 20 jan. 2022.

LEZOCHE, M. et al. Agri-food 4.0: A survey of the supply chains and technologies for the future agriculture. **Computers in Industry**, v. 117, p. 103187, mai. 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0166361519307584>. Acesso em: 12 fev. 2022.

LIMA, A. P. et al. **Administração da unidade de produção familiar: modalidades de trabalho com agricultores**. 3 ed. Ijuí: Unijuí, 2005.

LIN, X. Factors Influencing the Chinese Consumers' Usage Intention of Korean Mobile Payment: UTAUT, ISS and TTF Integrated Model. In: **Proceedings of the 2019 3rd International Conference on E-commerce, E-Business and E-Government**. 2019. p. 40-44. Disponível em: <https://dl.acm.org/doi/10.1145/3340017.3340026>. Acesso em: 11 jan. 2020.

LIONBERGER, H. F. **Adoption of new ideas and practices**. 1960.

LIOUTAS, E. D. et al. Key questions on the use of big data in farming: An activity theory approach. **NJAS: Wageningen Journal of Life Sciences**, v. 90-91, n. 1, p. 1-12, dez. 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1573521418302197>. Acesso em: 14 out. 2020.

LIOUTAS, E. D.; CHARATSARI, C. Smart farming and short food supply chains: Are they compatible? **Land Use Policy**, v. 94, p. 104541, mai. 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0264837719320484>. Acesso em: 3 jan. 2021.

LOEVINSOHN, M. et al. Under What Circumstances and Conditions Does Adoption of Technology Result in Increased Agricultural Productivity? A Systematic Review. **Ids.ac.uk**, 2013. Disponível em: <https://opendocs.ids.ac.uk/opendocs/handle/20.500.12413/3208>. Acesso em: 18 jan. 2022.

LUARN, P.; LIN, H.-H. Toward an understanding of the behavioral intention to use mobile banking. **Computers in Human Behavior**, v. 21, n. 6, p. 873-891, nov. 2005. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0747563204000470>. Acesso em: 23 out. 2022.

MAHAMOOD, A. F.; MOHAMMED, R.; AHMAD, M. K.; et al. Applying diffusion of innovation theory and unified theory of acceptance and use of technology (UTAUT) on farmers' use of communication technology. **Journal of Human Development and Communication**, v. 5, p. 27-40, 2016. Disponível em: <http://dspace.unimap.edu.my/bitstream/handle/123456789/52962/Applying%20Diffusion%20of%20Innovation%20Theory%20and%20Unified%20Theory.pdf?sequence=1>. Acesso em: 21 mai. 2020.

MAKOKHA, S. et al. **Determinants of fertilizer and manure use for maize production in Kiambu District, Kenya**. Cimmyt, 2001. Disponível em:

<https://repository.cimmyt.org/bitstream/handle/10883/1025/74313.pdf?sequence=1&isAllowed=y>. Acesso em: 12 mai. 2021.

MALHOTRA, N. K. Questionnaire design and scale development. *In*: GROVER, R.; VRIENS, M. **The handbook of marketing research: Uses, misuses, and future advances**. SAGE Publications, Inc., 2006. p. 83-94. Disponível em: https://sk.sagepub.com/reference/hdbk_mktgresearch/n5.xml. Acesso em: 27 ago. 2022.

MARIA, K.; MARIA, B.; ANDREA, K. Exploring actors, their constellations, and roles in digital agricultural innovations. **Agricultural Systems**, v. 186, p. 102952, jan. 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0308521X20308131>. Acesso em: 29 nov. 2022.

MASSRUHÁ, S. M. F. S. et al. A transformação digital no campo rumo à agricultura sustentável e inteligente. *In*: MASSRUHÁ, S. M. F. S. et al. **Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas**. Embrapa Agricultura Digital, 2020. P. 21-45. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1126214/a-transformacao-digital-no-campo-rumo-a-agricultura-sustentavel-e-inteligente>. Acesso em: 18 abr. 2021.

MATTA, V.; KOONCE, D.; JEYARAJ, A. Initiation, Experimentation, Implementation of innovations: The case for Radio Frequency Identification Systems. **International Journal of Information Management**, v. 32, n. 2, p. 164-174, abr. 2012. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0268401211001228>. Acesso em: 18 abr. 2021.

MCKINSEY. **A mente do agricultor brasileiro na era digital 2021**. Palestra McKinsey & Company. Disponível em: <https://mente-do-agricultor.mckinsey.com/>. Acesso em: 18 mar. de 2021.

MCNAMARA, K. T.; WETZSTEIN, M. E.; DOUCE, G. K. Factors affecting peanut producer adoption of integrated pest management. **Applied Economic Perspectives and Policy**, v. 13,

n. 1, p. 129-139, jan. 1991. Disponível em: <https://www.jstor.org/stable/1349563>. Acesso em: 31 jan. 2022.

MD NOR, K.; PEARSON, J.M.; AHMAD, A. Adoption of internet banking theory of the diffusion of innovation. **International Journal of Management Studies (IJMS)**, v. 17, n. 1, p. 69-85, jun. 2010. Disponível em: <https://e-journal.uum.edu.my/index.php/ijms/article/view/9984>. Acesso em: 19 set. 2020.

MELESSE, B. A review on factors affecting adoption of agricultural new technologies in Ethiopia. **Journal of Agricultural Science and Food Research**, v. 9, n. 3, p. 1-4, mai. 2018. Disponível em: <https://www.longdom.org/open-access/a-review-on-factors-affecting-adoption-of-agricultural-new-technologiesin-ethiopia.pdf>. Acesso em: 25 abr. 2022.

MICHELS, M.; BONKE, V.; MUSSHOF, O. Understanding the adoption of smartphone apps in dairy herd management. **Journal of Dairy Science**, v. 102, n. 10, p. 9422-9434, out. 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0022030219306472>. Acesso em: 17 mai. 2022.

MICHELS, M.; BONKE, V.; MUSSHOF, O. Understanding the adoption of smartphone apps in crop protection. **Precision Agriculture**, v. 21, p. 1209-1226, abr. 2020. Disponível em: <https://link.springer.com/article/10.1007/s11119-020-09715-5>. Acesso em: 15 mar. 2022.

MIGNOUNA, D. B.; MANYONG, V. M.; RUSIKE, J. et al. Determinants of adopting imazapyr-resistant maize technologies and its impact on household income in Western Kenya. **AgBioForum**, v. 14, n. 3, p. 158-163, 2011. Disponível em: <https://agbioforum.org/wp-content/uploads/2021/02/AgBioForum-14-3-158.pdf>. Acesso em: 31 mai. 2022.

MIGUEL, P. A.; HO, L. L. Levantamento tipo survey. In: **Metodologia de pesquisa em engenharia de produção e gestão de operações**. Rio de Janeiro: Elsevier, 2010. p. 73-128. Disponível em: <https://repositorio.usp.br/item/001801543>. Acesso em: 20 mai. 2021.

MILLER, N. E.; DOLLARD, J. **Social learning and imitation**. New Haven: Yale University Press, 1941.

MIN, Q.; JI, S.; QU, G. Mobile commerce user acceptance study in China: A revised UTAUT model. **Tsinghua Science and Technology**, v. 13, n. 3, p. 257-264, jun. 2008. Disponível em: <https://ieeexplore.ieee.org/abstract/document/6071878>. Acesso em: 19 dez. 2021.

MITAL, M. et al. Adoption of internet of things in India: A test of competing models using a structured equation modeling approach. **Technological Forecasting and Social Change**, v. 136, p. 339-346, nov. 2018. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0040162517302949>. Acesso em: 10 jan. 2021.

MOLINA-MATURANO, J. et al. Understanding smallholder farmers' intention to adopt agricultural apps: The role of mastery approach and innovation hubs in Mexico. **Agronomy**, v. 11, n. 2, p. 194, jan. 2021. Disponível em: <https://www.mdpi.com/2073-4395/11/2/194>. Acesso em: 15 mar. 2022.

MUANGPRATHUB, J. et al. IoT and agriculture data analysis for smart farm. **Computers and Electronics in Agriculture**, v. 156, p. 467-474, jan. 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169918308913>. Acesso em: 29 out. 2022.

MULUGO, L. et al. Unravelling technology-acceptance factors influencing farmer use of banana tissue culture planting materials in Central Uganda. **African Journal of Science, Technology, Innovation and Development**, v. 12, n. 4, p. 453-465, 2020. Disponível em: <https://journals.co.za/doi/full/10.1080/20421338.2019.1634900>. Acesso em: 8 dez. 2022.

MWANGI, M.; KARIUKI, S. Factors determining adoption of new agricultural technology by smallholder farmers in developing countries. **Journal of Economics and sustainable development**, v. 6, n. 5, 2015. Disponível em: <https://core.ac.uk/download/pdf/234646919.pdf>. Acesso em: 12 set. 2021.

NALLY, D. Against food security: on forms of care and fields of violence. **Global Society**, v. 30, n. 4, p. 558-582, 2016. Disponível em:

<https://www.tandfonline.com/doi/abs/10.1080/13600826.2016.1158700>. Acesso em: 24 out. 2022.

NAMPIJJA, D.; BIREVU, P. **Adoption and use of mobile technologies for learning among smallholder farmer communities in Uganda**. In: 2016 International Conference on Interactive Mobile Communication, Technologies and Learning (IMCL). IEEE, 2016. p. 83-87. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7753777>. Acesso em: 19 fev. 2022.

NARINE, L.I. K.; HARDER, A.; ROBERTS, T. Grady. Farmers' intention to use text messaging for extension services in Trinidad. **The Journal of Agricultural Education and Extension**, v. 25, n. 4, p. 293-306, 2019. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/1389224X.2019.1629970>. Acesso em: 15 ago. 2022.

NEJADREZAEI, N. et al. Factors affecting adoption of pressurized irrigation technology among olive farmers in Northern Iran. **Applied Water Science**, v. 8, n. 6, p. 1-9, out. 2018. Disponível em: <https://link.springer.com/article/10.1007/s13201-018-0819-2>. Acesso em: 10 mar. 2021.

NEWMAN, G. D. El razonamiento inductivo y deductivo dentro del proceso investigativo en ciencias experimentales y sociales. **Laurus**, v. 12, p. 180-205, 2006. Disponível em: <https://www.redalyc.org/pdf/761/76109911.pdf>. Acesso em: 18 set. 2021.

NORTON, G. W.; ALSTON, J. M.; PARDEY, P. G. **Assessing Impacts of Agricultural Science and Technology**. jan. 1995. Disponível em: <https://ageconsearch.umn.edu/record/232550/files/agecon-vt-sp-95-04.pdf>. Acesso em: 15 abr. 2022.

NOWAK, P. J. The adoption of agricultural conservation technologies: Economic and diffusion explanations. **Rural sociology**, v. 52, n. 2, p. 208, 1987. Disponível em: <https://vtechworks.lib.vt.edu/handle/10919/68487>. Acesso em: 28 nov. 2022.

NURKKA, P. et al. Improving usability and user acceptance of information systems in farming. In: **EFITA/WCCA Joint Congress in IT in Agriculture**. 2007. Disponível em: <https://jukuri.luke.fi/handle/10024/465447>. Acesso em: 5 mar. 2021.

OECD/FAO. **Agricultural Outlook 2019-2028**, OECD Publishing, Paris, 2019. Disponível em: <https://www.oecd.org/agriculture/oecd-fao-agricultural-outlook-2019/>. Acesso em: 28 ago. 2022.

O'GRADY, M. J.; O'HARE, G. M. P. Modelling the smart farm. **Information processing in agriculture**, v. 4, n. 3, p. 179-187, set. 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214317316301287>. Acesso em: 15 nov. 2022.

OYE, N. D.; IAHAD, N. A.; RAHIM, N. Ab. The history of UTAUT model and its impact on ICT acceptance and usage by academicians. **Education and Information Technologies**, v. 19, n. 1, p. 251-270, fev. 2014. Disponível em: <https://link.springer.com/article/10.1007/s10639-012-9189-9>. Acesso em: 7 ago. 2021.

OZDOGAN, B.; GACAR, A.; AKTAS, H. Digital agriculture practices in the context of agriculture 4.0. **Journal of Economics Finance and Accounting**, v. 4, n. 2, p. 186-193, 2017. Disponível em: <https://dergipark.org.tr/en/pub/jefa/issue/32205/357506> . Acesso em: 18 dez. 2021.

PEDERSEN, S. M.; LIND, K. M. Precision agriculture—from mapping to site-specific application. In: **Precision agriculture: Technology and economic perspectives**. Springer, 2017. p. 1-20. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-68715-5_1. Acesso em: 12 nov. 2022.

PEROSA, B.; NEWTON, P.; CARRER, M. J. Access to information affects the adoption of integrated systems by farmers in Brazil. **Land Use Policy**, v. 106, p. 105459, jul. 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0264837721001824>. Acesso em: 12 nov. 2022.

PETRY, J. F. et al. Inovação e difusão de tecnologia na agricultura de várzea na Amazônia. **Revista de Administração Contemporânea**, v. 23, p. 619-635, out. 2019. Disponível em:

<https://www.scielo.br/j/rac/a/q49Z5wZhZs7zp3wJgpdXG4f/?lang=pt>. Acesso em: 12 dez. 2022.

PIERPAOLI, E. et al. Drivers of precision agriculture technologies adoption: a literature review. **Procedia Technology**, v. 8, p. 61-69, 2013. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2212017313000728>. Acesso em: 28 nov. 2020.

PIGNATTI, E.; CARLI, G.; CANAVARI, M. What really matters? A qualitative analysis on the adoption of innovations in agriculture. **Journal of Agricultural Informatics**, v. 6, n. 4, p. 73-84, 2015. Disponível em: <http://oro.open.ac.uk/50980/>. Acesso em: 13 jan. 2022.

PIVOTO, D. et al. Scientific development of smart farming technologies and their application in Brazil. **Information Processing in Agriculture**, v. 5, n. 1, p. 21-32, mar. 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214317316301184>. Acesso em: 12 jul. 2022.

PIVOTO, D. **Smart farming: concepts, applications, adoption and diffusion in southern Brazil**. 2018. Tese (Doutorado em Agronegócio) - Universidade Federal do Rio Grande do Sul, 2018. Disponível em: <https://www.lume.ufrgs.br/handle/10183/178439>. Acesso em: 23 mai. 2022.

PIVOTO, D. et al. Factors influencing the adoption of smart farming by Brazilian grain farmers. **International Food and Agribusiness Management Review**, v. 22, n. 4, p. 571-588, abr. 2019. Disponível em: <https://www.wageningenacademic.com/doi/10.22434/IFAMR2018.0086>. Acesso em: 25 out. 2022.

POPPE, K. J. et al. A European perspective on the economics of big data. **Farm Policy Journal**, v. 12, n. 1, p. 11-19, 2015. Disponível em: <https://research.wur.nl/en/publications/a-european-perspective-on-the-economics-of-big-data>. Acesso em: 1 dez. 2022.

PREMKUMAR, G.; RAMAMURTHY, K.; CRUM, M. Determinants of EDI adoption in the transportation industry. **European Journal of Information Systems**, v. 6, n. 2, p. 107-121, jun. 1997. Disponível em: <https://link.springer.com/article/10.1057/palgrave.ejis.3000260>. Acesso em: 14 nov. 2022.

QUEIROZ, M. M.; WAMBA, S. F. Blockchain adoption challenges in supply chain: An empirical investigation of the main drivers in India and the USA. **International Journal of Information Management**, v. 46, p. 70-82, jun. 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0268401218309447>. Acesso em: 18 mai. 2022.

RECKER, J. Reasoning about discontinuance of information system use. **Neuropsychology Review**, v. 17, n. 1, p. 2 41-66, 2016. Disponível em: <https://eprints.qut.edu.au/221019/>. Acesso em: 13 mar. 2021.

REDHEAD, F. et al. Bringing the farmer perspective to agricultural robots. *In: Proceedings of the 33rd Annual ACM Conference Extended Abstracts on Human Factors in Computing Systems*. 2015. p. 1067-1072. Disponível em: <https://dl.acm.org/doi/10.1145/2702613.2732894>. Acesso em: 05 fev. 2021.

REGAN, Á. ‘Smart farming’ in Ireland: A risk perception study with key governance actors. **NJAS: Wageningen Journal of Life Sciences**, v. 90, n. 1, p. 1-10, dez. 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1573521418302100>. Acesso em: 15 fev. 2022.

RIAL-LOVERA, K. Agricultural Robots: Drivers, barriers and opportunities for adoption. *In: Proceedings of the 14th International Conference on Precision Agriculture*. Montreal, QC, Canada. 2018. p. 24-27. Disponível em: <https://www.thefarmersclub.com/media/60/Dr%20Karen%20Rial-Lovera%20-%20FCCT%20Report%202017.pdf>. Acesso em: 09 jan. 2022.

RINGLE, C. M.; DA SILVA, D.; DE SOUZA BIDO, D. Modelagem de equações estruturais com utilização do SmartPLS. **Revista Brasileira de Marketing**, v. 13, n. 2, p. 56-73, mai. 2014. Disponível em: <https://periodicos.uninove.br/remark/article/view/12032>. Acesso em: 19 abr. 2021.

ROGERS, E. M. **Diffusion of innovations**. New York: Free Press, 1995.

ROGERS, E. M. **Elements of diffusion**. 5. ed. Diffusion of innovations, v. 5, n. 1.38, 2003.

ROGERS, E. M. New Product Adoption and Diffusion. **Journal of Consumer Research**, v. 2, n. 4, p. 290-301, mar. 1976. Disponível em: <https://www.jstor.org/stable/2488658>. Acesso em: 18 out. 2022.

RONAGHI, M. H.; FOROUHARFAR, A. A contextualized study of the usage of the Internet of things (IoTs) in smart farming in a typical Middle Eastern country within the context of Unified Theory of Acceptance and Use of Technology model (UTAUT). **Technology in Society**, v. 63, p. 101415, nov. 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0160791X20304942>. Acesso em: 14 jul. 2022.

ROSE, D. C. et al. Agriculture 4.0: Making it work for people, production, and the planet. **Land Use Policy**, v. 100, p. 104933, jan. 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0264837719319489>. Acesso em: 20 jun. 2022.

ROSE, D. C. et al. Decision support tools for agriculture: Towards effective design and delivery. **Agricultural Systems**, v. 149, p. 165-174, nov. 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0308521X16305418>. Acesso em: 5 jan. 2021.

ROSE, D. C. et al. Exploring the spatialities of technological and user re-scripting: The case of decision support tools in UK agriculture. **Geoforum**, v. 89, p. 11-18, fev. 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0016718517303421>. Acesso em: 12 jun. 2022.

ROSE, D. C.; CHILVERS, J. Agriculture 4.0: Broadening Responsible Innovation in an Era of Smart Farming. **Frontiers in Sustainable Food Systems**, v. 2, p. 87, dez. 2018. Disponível em: <https://www.frontiersin.org/articles/10.3389/fsufs.2018.00087/full>. Acesso em: 25 abr. 2021.

ROSSKOPF, K.; WAGNER, P. Requirements for agricultural software and reasons for adoption constraints—results of empirical studies. In: **EFITA Conference**. 2003. Disponível em: https://www.informatique-agricole.org/download/efita-conference/Congres_EFITA_2003/1202.pdf. Acesso em: 11 jun. 2022.

ROTZ, S. et al. Automated pastures and the digital divide: How agricultural technologies are shaping labour and rural communities. **Journal of Rural Studies**, v. 68, p. 112-122, mai. 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0743016718307769>. Acesso em: 18 jan. 2022.

ROWLEY, J.; SLACK, F. Conducting a literature review. **Management research news**, v. 27, n. 6, p. 31-39, jun. 2004. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/01409170410784185/full/html>. Acesso em: 7 dez. 2021.

ROZMI, A. N. A. et al. Investigating the Intentions to Adopt ICT in Malaysian SMEs Using the UTAUT Model. In: **Advances in Visual Informatics**. Springer International Publishing, 2019. p. 477-487. Disponível em: https://link.springer.com/chapter/10.1007/978-3-030-34032-2_42. Acesso em: 5 set. 2021.

RÜBCKE VON VELTHEIM, F.; THEUVSEN, L.; HEISE, H. German farmers' intention to use autonomous field robots: a PLS-analysis. **Precision Agriculture**, v. 23, n. 2, p. 670-697, set. 2021. Disponível em: <https://link.springer.com/article/10.1007/s11119-021-09854-3>. Acesso em: 14 jul. 2022.

RUSERE, F. et al. Enabling acceptance and use of ecological intensification options through engaging smallholder farmers in semi-arid rural Limpopo and Eastern Cape, South Africa. **Agroecology and sustainable food systems**, v. 44, n. 6, p. 696-725, 2020. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/21683565.2019.1638336>. Acesso em: 13 ago. 2022.

RYAN, B.; GROSS, N. C. The diffusion of hybrid seed corn in two Iowa communities. **Rural sociology**, v. 8, n. 1, p. 15, 1943. Disponível em: <https://www.proquest.com/openview/7de2b2276a089fe888071663de12b6a0/1?pq-origsite=gscholar&cbl=1817355>. Acesso em: 10 jan. 2020.

SAAKSJARVI, M. Consumer adoption of technological innovations. **European Journal of Innovation Management**, v. 6, n. 2, p. 90-100, jun. 2003. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/14601060310475246/full/html>. Acesso em: 14 jan. 2022.

SAIZ-RUBIO, V.; ROVIRA-MÁS, F. From smart farming towards agriculture 5.0: a review on crop data management. **Agronomy**, v. 10, n. 2, p. 207, fev. 2020. Disponível em: <https://www.mdpi.com/2073-4395/10/2/207>. Acesso em: 21 mar. 2022.

SALIMI, M.; POURDARBANI, R.; NOURI, B. A. Factors affecting the adoption of agricultural automation using Davis's acceptance model (case study: Ardabil). **Acta Technologica Agriculturae**, v. 23, n. 1, p. 30-39, mar. 2020. Disponível em: <https://sciendo.com/article/10.2478/ata-2020-0006>. Acesso em: 10 dez. 2022.

SAMBASIVAN, M.; WEMYSS, G.P; ROSE, R.C. User acceptance of a G2B system: a case of electronic procurement system in Malaysia. **Internet Research**, v. 20, n. 2, p. 169-187, abr. 2010. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/10662241011032236/full/html>. Acesso em: 14 nov. 2022.

SALLOUM, S. A.; SHAALAN, K. Factors affecting students' acceptance of e-learning system in higher education using UTAUT and structural equation modeling approaches. **Advances in Intelligent Systems and Computing**, p. 469-480, ago. 2018. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-99010-1_43. Acesso em: 19 abr. 2021.

SAN MARTÍN, H.; HERRERO, Á. Influence of the user's psychological factors on the online purchase intention in rural tourism: Integrating innovativeness to the UTAUT framework. **Tourism Management**, v. 33, n. 2, p. 341-350, abr. 2012. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0261517711000975>. Acesso em: 15 fev. 2021.

SAUNDERS, M.; LEWIS, P.; THORNHILL, A. **Research methods for business students**. Nova Iorque: Pearson education, 2009.

SCUDERI, A. et al. Current and Future Opportunities of Digital Transformation in the Agrifood Sector. In: **HAICTA**, 2020. p. 317-326. Disponível em: <https://www.semanticscholar.org/paper/Current-and-Future-Opportunities-of-Digital-in-the-Scuderi-Via/8b1aed1cee59b66bf4ef374ab7700dd05ef2ddc6>. Acesso em: 10 mai. 2022.

SINGH, N.; KOHLI, D. S. The green revolution in Punjab, India: The economics of technological change. **J Punjab Stud**, v. 12, n. 2, p. 285-306, 1997. Disponível em:

https://punjab.global.ucsb.edu/sites/secure.lsit.ucsb.edu.gisp.d7_sp/files/sitefiles/journals/volume12/no2/12.2_Table_of_Contents.pdf#page=95. Acesso em: 3 mai. 2020.

SCHWERING, D. S.; BERGMANN, L.; SONNTAG, W. I. How to encourage farmers to digitize? A study on user typologies and motivations of farm management information systems. **Computers and Electronics in Agriculture**, v. 199, p. 107133, ago. 2022. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169922004501>. Acesso em: 10 dez. 2022.

SHANG, L. et al. Adoption and diffusion of digital farming technologies - integrating farm-level evidence and system interaction. **Agricultural Systems**, v. 190, p. 103074, mai. 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0308521X21000275>. Acesso em: 18 nov. 2022.

SHARMA, A. et al. Blockchain adoption in agri-food supply chain management: an empirical study of the main drivers using extended UTAUT. **Business Process Management Journal**, 2023. Disponível em: <https://doi.org/10.1108/BPMJ-10-2022-0543>. Acesso em: 18 mar. 2023.

SHI, Y. et al. The antecedents of willingness to adopt and pay for the IoT in the agricultural industry: An application of the UTAUT 2 theory. **Sustainability**, v. 14, n. 11, p. 6640, mai. 2022. Disponível em: <https://www.mdpi.com/2071-1050/14/11/6640>. Acesso em: 10 out. 2022.

SILVEIRA, F.; LERMEN, F. H.; AMARAL, F. G. An overview of agriculture 4.0 development: Systematic review of descriptions, technologies, barriers, advantages, and disadvantages. **Computers and electronics in agriculture**, v. 189, p. 106405, out. 2021. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169921004221>. Acesso em: 12 nov. 2022.

SLADE, E. L. et al. Modeling consumers' adoption intentions of remote mobile payments in the United Kingdom: extending UTAUT with innovativeness, risk, and trust. **Psychology & Marketing**, v. 32, n. 8, p. 860-873, jul. 2015. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/mar.20823>. Acesso em: 8 jun. 2021.

SOUZA FILHO, H. M. et al. Condicionantes da adoção de inovações tecnológicas na agricultura. **Cadernos de Ciência & Tecnologia**, v. 28, n. 1, p. 223-255, abr. 2011. Disponível em <https://seer.sct.embrapa.br/index.php/cct/article/view/12041>. Acesso em: 12 dez. 2022.

SØRENSEN, C. G. et al. Conceptual model of a future farm management information system. **Computers and Electronics in Agriculture**, v. 72, n. 1, p. 37-47, jun. 2010. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169910000396>. Acesso em: 23 ago. 2022.

SOUSA, R. et al. Modelo conceitual para sistema de coleta e comunicação automática de dados para máquina e implemento automatizado e para robô agrícola móvel. In: BERNARDI, A. C. de C. et al. **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. p. 165-172. Disponível em: <https://www.alice.cnptia.embrapa.br/bitstream/doc/1003504/1/cap11.pdf>. Acesso em: 29 nov. 2021.

SOUZA FILHO, H. M. et al. Condicionantes da adoção de inovações tecnológicas na agricultura. **Cadernos de Ciência & Tecnologia**, v. 28, n. 1, p. 223-255, 2011. Disponível em: <https://seer.sct.embrapa.br/index.php/cct/article/view/12041>. Acesso em: 21 dez. 2020.

SPAULDING, A. D.; TUDOR, K. W.; MAHATANANKOON, P. The effects of outcome expectations on individual's anxiety and continued usage of mobile devices: a post-adoption study. **International Food and Agribusiness Management Review**, v. 18, n. 4, p. 173-188, nov. 2015. Disponível em: <https://ageconsearch.umn.edu/record/211659/>. Acesso em: 10 mai. 2020.

SPONCHIONI, G. et al. The 4.0 revolution in agriculture: a multi-perspective definition. **Polimi.it**, p. 143-149, nov. 2019. Disponível em: <https://re.public.polimi.it/handle/11311/1123114>. Acesso em: 17 dez. 2021.

SRIPALAWAT, J.; THONGMAK, M.; NGRAMYARN, A. M-banking in metropolitan Bangkok and a comparison with other countries. **Journal of computer information systems**, v. 51, n. 3, p. 67-76, 2011. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/08874417.2011.11645487>. Acesso em: 12 abr. 2020.

STEENEVELD, W.; HOGEVEEN, H.; LANSINK, A. G. J. M. O. Economic consequences of investing in sensor systems on dairy farms. **Computers and Electronics in Agriculture**, v. 119, p. 33-39, nov. 2015. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S016816991500318X>. Acesso em: 15 set. 2022.

SUIFAN, T. S.; ALHYARI, S.; SWEIS, R. J. A moderated mediation model of intragroup conflict. **International Journal of Conflict Management**, v. 31, n. 1, p. 91-114, jan. 2020. Disponível em <https://www.emerald.com/insight/content/doi/10.1108/IJCMA-05-2019-0084/full/html>. Acesso em: 12 nov. 2022.

TAECHATANASAT, P.; ARMSTRONG, L. Decision Support System Data for Farmer Decision Making. In: TAECHATANASAT, P.; ARMSTRONG, L. **Proceedings of Asian Federation for Information Technology in Agriculture**. Perth, W.A. Australian Society of Information and Communication Technologies in Agriculture, 2014. p. 472-486. Disponível em: <https://ro.ecu.edu.au/ecuworkspost2013/855/>. Acesso em: 15 out. 2022.

TAN, L.; WU, L. An empirical study on factors affecting customer intention in mobile commerce contexts. **2nd International Conference on Multi Media and Information Technology**, pp. 310-313, abr. 2010. Disponível em: <https://ieeexplore.ieee.org/document/5474284> . Acesso em: 18 out. 2022.

TARHINI, A. et al. Factors influencing students' adoption of e-learning: a structural equation modeling approach. **Journal of International Education in Business**, v. 10, n. 2, p. 164-182, nov. 2017. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/JIEB-09-2016-0032/full/html>. Acesso em: 17 out. 2020.

TAYLOR, S.; TODD, P. Decomposition and crossover effects in the theory of planned behavior: A study of consumer adoption intentions. **International Journal of Research in Marketing**, v. 12, n. 2, p. 137-155, jul. 1995. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/016781169400019>. Acesso em: 24 abr. 2021.

TERENCE, S.; PURUSHOTHAMAN, G. Systematic review of Internet of Things in smart farming. **Transactions on Emerging Telecommunications Technologies**, v. 31, n. 6, p. e3958, abr. 2020. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/ett.3958>. Acesso em: 9 ago. 2022.

TEY, Y. S.; BRINDAL, M. Factors influencing the adoption of precision agricultural technologies: a review for policy implications. **Precision Agriculture**, v. 13, n. 6, p. 713-730, jul. 2012. Disponível em: <https://link.springer.com/article/10.1007/s11119-012-9273-6>. Acesso em: 17 dez. 2021.

THOMAS, T. et al. Measurement invariance of the UTAUT constructs in the Caribbean. **International Journal of Education and Development using ICT**, v. 10, n. 4, dez. 2014. Disponível em: <https://www.learntechlib.org/p/150707/>. Acesso em: 21 dez. 2020.

THOMPSON, R. L.; HIGGINS, C. A.; HOWELL, J. M. Personal computing: toward a conceptual model of utilization. **MIS quarterly**, v. 15, n. 1, p. 125-143, mar. 1991. Disponível em: <https://www.jstor.org/stable/249443>. Acesso em: 8 set. 2021.

THORSTENSEN, V.; THOMAZELLA, F. **Os indicadores da OCDE para a análise do setor agrícola brasileiro**. São Paulo: Escola de Economia de São Paulo da Fundação Getúlio Vargas, 2020. Disponível em: https://bibliotecadigital.fgv.br/dspace/themes/Mirage2/pages/pdfjs/web/viewer.html?file=https://bibliotecadigital.fgv.br/dspace/bitstream/handle/10438/29300/TD%20530%20-%20CCGI_25.pdf?sequence=1&isAllowed=y. Acesso em: 9 set. 2022.

TIBENDERANA, P. et al. Measuring Levels of End-Users' Acceptance and Use of Hybrid Library Services. **International Journal of Education and Development using Information and Communication Technology**, v. 6, n. 2, p. 33-54, 2010. Disponível em: <https://eric.ed.gov/?id=EJ1084985>. Acesso em: 28 dez. 2022.

TRIANDIS, H. C. **Interpersonal behavior**. Brooks/Cole Pub. Co., 1977. Disponível em: <https://scirp.org/reference/referencespapers.aspx?referenceid=136721>. Acesso em: 7 mar. 2022.

TRIVELLI, L. et al. From precision agriculture to Industry 4.0. **British Food Journal**, v. 121, n. 8, p. 1730-1743, jun. 2019. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/BFJ-11-2018-0747/full/html>. Acesso em: 10 nov. 2021.

TU, M. An exploratory study of Internet of Things (IoT) adoption intention in logistics and supply chain management: **The International Journal of Logistics Management**, v. 29, n. 1, p. 131-151, fev. 2018. Disponível em:

<https://www.emerald.com/insight/content/doi/10.1108/IJLM-11-2016-0274/full/html>. Acesso em: 24 ago. 2022.

TUMMERS, J.; KASSAHUN, A.; TEKINERDOGAN, B. Obstacles and features of Farm Management Information Systems: A systematic literature review. *Computers and Electronics in Agriculture*, v. 157, p. 189-204, fev. 2019. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0168169918307944>. Acesso em: 11 dez. 2022.

UAIENE, R. N.; ARNDT, C.; MASTERS, W. A. Determinants of agricultural technology adoption in Mozambique. In: UAIENE, R. N.; ARNDT, C.; MASTERS, W. A. **10th African Crop Science Conference Proceedings**, Maputo, Mozambique, African Crop Science Society, 2011. p 375. Disponível em: <https://www.cabdirect.org/cabdirect/abstract/20133200277>. Acesso em: 16 dez. 2021.

UGOCHUKWU, A. I.; PHILLIPS, P. W. B. Technology adoption by agricultural producers: A review of the literature. **From agriscience to agribusiness**, p. 361-377, nov. 2017. Disponível em: https://link.springer.com/chapter/10.1007/978-3-319-67958-7_17. Acesso em: 8 dez. 2020.

UNAY-GAILHARD, Í.; BOJNEC, Š. Sustainable participation behaviour in agri-environmental measures. **Journal of Cleaner Production**, v. 138, p. 47-58, dez. 2016. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S095965261501224X>. Acesso em: 11 jan. 2022.

USB - The Western Cape Department of Agriculture and University of Stellenbosch Business School (WCDoA and USB). (2018). **The future of the Western Cape agricultural sector in the context of the Fourth Industrial Revolution** (Synthesis report). Disponível em: <https://www.usb.ac.za/wp-content/uploads/2018/07/THE-FUTURE-OF-THE-WC-AGRICULTURAL-SECTOR-IN-THE-CONTEXT-OF-4IR-FINAL-REP.pdf>. Acesso em: 10 dez. 2022.

VAN BILJON, J; KOTZE, P. Cultural factors in a mobile phone adoption and usage model. **Journal of Universal Computer Science**, v. 14, n. 16, p. 2650-2679, 2008. Disponível em: <http://researchspace.csir.co.za/dspace/handle/10204/2984>. Acesso em: 28 nov. 2022.

VENKATESH, V. et al. User acceptance of information technology: Toward a unified view. **MIS quarterly**, v. 27, n. 3, p. 425-478, set. 2003. Disponível em: <https://www.jstor.org/stable/30036540>. Acesso em: 6 dez. 2021.

VENKATESH, V.; DAVIS, F. D. A theoretical extension of the technology acceptance model: Four longitudinal field studies. **Management science**, v. 46, n. 2, p. 186-204, fev. 2000. Disponível em: <https://pubsonline.informs.org/doi/abs/10.1287/mnsc.46.2.186.11926>. Acesso em: 11 fev. 2022.

VENKATESH, V.; DAVIS, F.; MORRIS, M. G. Dead or alive? The development, trajectory and future of technology adoption research. **Journal of the association for information systems**, v. 8, n. 4, p. 1, 2007. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3681776. Acesso em: 26 out. 2022.

VENKATESH, V.; THONG, J. Y.; XU, X. Consumer acceptance and use of information technology: extending the unified theory of acceptance and use of technology. **MIS quarterly**, p. 157-178, mar. 2012. Disponível em: <https://www.jstor.org/stable/41410412>. Acesso em: 29 set. 2022.

VERDOUW, C. N.; ROBBEMOND, R. M.; WOLFERT, J. ERP in agriculture: Lessons learned from the Dutch horticulture. **Computers and Electronics in Agriculture**, v. 114, p. 125–133, jun. 2015. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016816991500109X>. Acesso em: 30 jan. 2022.

VICENTE, J. R. Determinantes da adoção de tecnologia na agricultura paulista. **Estudos Econômicos (São Paulo)**, v. 28, n. 3, p. 421-451, 1998. Disponível em: <https://www.revistas.usp.br/ee/article/view/117070>. Acesso em: 16 dez. 2020.

VON VELTHEIM, F. R.; HEISE, H. The AgTech Startup Perspective to Farmers Ex Ante Acceptance Process of Autonomous Field Robots. **Sustainability**, v. 12, n. 24, p. 10570, 17 dez. 2020. Disponível em: <https://www.mdpi.com/2071-1050/12/24/10570> Acesso em: 28 nov. 2023.

WALTER, A. et al. Smart farming is key to developing sustainable agriculture. **Proceedings of the National Academy of Sciences**, v. 114, n. 24, p. 6148-6150, jun. 2017. Disponível em: <https://www.pnas.org/doi/abs/10.1073/pnas.1707462114>. Acesso em: 21 ago. 2021.

WALTON, J. C. et al. Grid soil sampling adoption and abandonment in cotton production. **Precision Agriculture**, v. 11, n. 2, p. 135-147, dez. 2010. Disponível em: <https://link.springer.com/article/10.1007/s11119-009-9144-y>. Acesso em: 30 out. 2022.

WHEELER, S. A. The barriers to further adoption of organic farming and genetic engineering in Australia: Views of agricultural professionals and their information sources. **Renewable Agriculture and Food Systems**, v. 23, n. 2, p. 161-170, jun. 2008. Disponível em: <https://www.jstor.org/stable/44491519>. Acesso em: 6 dez. 2022.

WHITFIELD, S.; CHALLINOR, A. J.; REES, R. M. Frontiers in climate smart food systems: outlining the research space. **Frontiers in sustainable food systems**, v. 2, p. 2, jan 2018. Disponível em: <https://www.frontiersin.org/articles/10.3389/fsufs.2018.00002/full>. Acesso em: 15 nov. 2022.

WILLIAMS, M. D.; RANA, N. P.; DWIVEDI, Y. The unified theory of acceptance and use of technology (UTAUT): a literature review. **Journal of enterprise information management**, v. 28 n. 3, p. 443-488, abr. 2015. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/JEIM-09-2014-0088/full/html>. Acesso em: 11 fev. 2022.

WILSON, E. J. Research design effects on the reliability of rating scales in marketing: An update on Churchill and Peter. In: KARDES, F. R.; SUJAN, M. NA - **Advances in Consumer Research**. Louisiana State University, 1995. p. 360-365. Disponível em: <https://www.acrwebsite.org/volumes/9876>. Acesso em: 24 set. 2022.

WISEMAN, L. et al. Farmers and their data: An examination of farmers' reluctance to share their data through the lens of the laws impacting smart farming. **NJAS: Wageningen Journal of Life Sciences**, v. 90-91, n. 1, p. 100301, dez. 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1573521418302616>. Acesso em: 12 dez. 2022.

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

<https://www.sciencedirect.com/science/article/pii/S0308521X16303754>. Acesso em: 23 jun. 2022.

WOLFERT, S.; GOENSE, D.; SØRENSEN, C. A future internet collaboration platform for safe and healthy food from farm to fork. *In: 2014 annual SRII global conference*. San Jose: IEEE, 2014. p. 266-273. Disponível em: <https://ieeexplore.ieee.org/document/6879694>. Acesso em: 5 set. 2022.

WOODSIDE, A. G.; BIEMANS, W. G. Modeling innovation, manufacturing, diffusion and adoption/rejection processes. **Journal of Business & Industrial Marketing**, vol. 20, n. 7, p. 380-393, dez. 2005. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/08858620510628614/full/html>. Acesso em: 29 nov. 2022.

WU, J.; BABCOCK, B. A. The choice of tillage, rotation, and soil testing practices: economic and environmental implications. **American Journal of Agricultural Economics**, v. 80, n. 3, p. 494-511, ago. 1998. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.2307/1244552>. Acesso em: 13 fev. 2021.

WU, L. An empirical research on poor rural agricultural information technology services to adopt. **Procedia Engineering**, v. 29, p. 1578-1583, 2012. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1877705812001865>. Acesso em: 28 out. 2022.

YOON, C.; LIM, D.; PARK, C. Factors affecting adoption of smart farms: The case of Korea. **Computers in Human Behavior**, v. 108, p. 106309, jul. 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0747563220300637>. Acesso em: 15 jan. 2022.

YU, C. Factors affecting individuals to adopt mobile banking: Empirical evidence from the UTAUT model. **Journal of electronic commerce research**, v. 13, n. 2, 2012. Disponível em: <https://www.scinapse.io/papers/133541039>. Acesso em: 28 jun. 2022.

ZAMBON, I. et al. Revolution 4.0: Industry vs. agriculture in a future development for SMEs. **Processes**, v. 7, n. 1, p. 36, jan. 2019. Disponível em: <https://www.mdpi.com/2227-9717/7/1/36>. Acesso em: 12 ago. 2022.

ZHAI, Z. et al. Decision support systems for agriculture 4.0: Survey and challenges. **Computers and Electronics in Agriculture**, v. 170, p. 105256, mar. 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169919316497>. Acesso em: 28 jun. 2022.

ZHENG, L. et al. Development of a smart mobile farming service system. **Mathematical and Computer Modelling**, v. 54, n. 3-4, p. 1194-1203, ago. 2011. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0895717710005443>. Acesso em: 16 dez. 2021.