



**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
CENTRO DE ESTUDOS E PESQUISAS EM AGRONEGÓCIOS
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRONEGÓCIOS**

MARCELO DA COSTA BORBA

**PREDIÇÃO PARA O USO DA INTELIGÊNCIA ARTIFICIAL NO
AGRONEGÓCIO NA CAATINGA**

TESE DE DOUTORADO

**PORTO ALEGRE/RS
2022**

MARCELO DA COSTA BORBA

**PREDIÇÃO PARA O USO DA INTELIGÊNCIA ARTIFICIAL NO
AGRONEGÓCIO NA CAATINGA**

Tese de Doutorado apresentado ao Programa de Pós-Graduação em Agronegócios do Centro de Estudos e Pesquisas em Agronegócios da Universidade Federal do Rio Grande do Sul, como requisito para a obtenção do título de Doutor em Agronegócios.

Orientador: Prof. Dr. João Armando Dessimon Machado

**PORTO ALEGRE/RS
2022**

CIP - Catalogação na Publicação

Borba, Marcelo da Costa
Predição para o uso da inteligência artificial no
agronegócio na Caatinga / Marcelo da Costa Borba. --
2022.
141 f.
Orientador: João Armando Dessimon Machado.

Tese (Doutorado) -- Universidade Federal do Rio
Grande do Sul, Centro de Estudos e Pesquisas em
Agronegócios, Programa de Pós-Graduação em
Agronegócios, Porto Alegre, BR-RS, 2022.

1. Inteligência Artificial. 2. Caatinga. 3.
Agricultura 5.0. 4. Semiárido Brasileiro. 5.
Agricultura de sequeiro . I. Machado, João Armando
Dessimon, orient. II. Título.

MARCELO DA COSTA BORBA

**PREDIÇÃO PARA O USO DA INTELIGÊNCIA ARTIFICIAL NO
AGRONEGÓCIO NA CAATINGA**

Tese de Doutorado apresentado ao Programa de Pós-Graduação em Agronegócios do Centro de Estudos e Pesquisas em Agronegócios da Universidade Federal do Rio Grande do Sul, como requisito para a obtenção do título de Doutor em Agronegócios.

Aprovada em 01 de abril de 2022.

BANCA EXAMINADORA

Prof. Dr. João Armando Dessimon Machado
Universidade Federal do Rio Grande do Sul – UFRGS
Orientador

Prof.^a Dr.^a Alessandra Carla Ceolin
Universidade Federal Rural de Pernambuco - UFRPE
Examinadora Externa

Prof. Dr. José Mancinelli Lêdo do Nascimento
Universidade Federal da Paraíba - UFPB
Examinador Externo

Prof. Dr. Homero Dewes
Universidade Federal do Rio Grande do Sul – UFRGS
Examinador Interno

**PORTO ALEGRE/RS
2022**

*Dedico esta tese:
A minha Amada Mãe, Rosinete da Costa Borba (Dona Rosa) e
ao meu Saudoso Pai, Severino Trajano Borba (Seu Birico).
Amo vocês.*

Agradecimentos

A minha mãe, dona Rosa, por todo o apoio incondicional e amor fraterno o qual durante todo o doutorado se fez presente e se tornou minha fonte de incentivo. A meus irmãos Marcos, Selma, Marcones, Sandra, Célia e Silvana pelo carinho e ajuda nessa caminhada. E aos demais familiares que sempre me fortaleceram e fortalecem a cada dia. Guardo com bastante ternura toda a generosidade de vocês.

A Administradora Edileide Ramos, minha companheira e amiga, a qual me acompanhou durante toda esta trajetória, e suportou todo o estresse, aborrecimento, chateação. Sempre disposta a me compreender e ajudar durante todo o período do doutorado. Aos amigos de longa data, os agradeço pelas alegrias e apoio. Em especial a Ana Paula, Anderson Dutra, Andrea Rego, Bibiana Ramborger, Cleidelene Vieira, Daiane Faoro, Daniel Mendes, Eduardo Melo, Elen Presotto, Elenice Moraes, Eluardo Marques, Ernane Souza, Fábio dos Anjos, Franciene Santos, Fúlvia Lima, Íris Pontes, Joândson da Costa, João Rafael, Luciana Silva, Luiz Gustavo, Marcos Araújo, Maria do Carmo, Paulo Eduardo, Paulo Vinícius, Robison dos Anjos, Tibério Dantas.

Ao meu orientador, Prof. João Armando Dessimon Machado, pela parceria e contribuição na construção da tese: orientação, experiência, ensino, paciência, conhecimento e dedicação. Sei que a realização desse trabalho foi concretizada através da parceria orientador/orientando durante todo esse tempo de pesquisa. Ao Prof. Dr. Homero Dewes pelo incentivo, disponibilidade e iniciativa de contribuir sempre que possível com minha pesquisa. A professora Alessandra Ceolin, figura indispensável nesta pesquisa, ajudando para a formalização das minhas ideias em proposta/projeto/tese. Ao professor Mancinelli, pela disponibilidade e carinho em participar desta fase de minha pesquisa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa integral em parte do Doutorado. A Universidade Federal do Rio Grande do Sul/Centro de Estudos e Pesquisas em Agronegócio por ter proporcionado uma das maiores experiências de minha vida. A Universidade Federal Rural de Pernambuco e a Universidade Federal da Paraíba, as quais sempre levarei comigo e que as guardo com bastante carinho pela formação do conhecimento em minha caminhada acadêmica.

A todos, meu muito obrigado!!!

“[...]Por ser de lá, do sertão,
Lá do interior do mato,
Da Caatinga, do roçado[...]
[...]Para mim é uma beleza
Vim falar do meu lugar,
Lá tenho
Dois palminhos de terra,
De onde tiro o sustento.
Pra tirar raça um bode
Um galo e um jumento
Não tem curral nem boiada
Pois muita gente ignora
Se eu botar mais um bicho
O rabo fica de fora [...]”.

**José Domingos de Moraes (Dominguinhos),
Gilberto Passos Gil Moreira (Gilberto Gil) e
Francisco Ferreira Lima (Pinto do Acordeom).**

RESUMO

A ciência e a tecnologia, em diferentes formas, sempre exerceram um papel expressivo na solução de problemas, sendo usadas para o desenvolvimento de estratégias, produtos, métodos e ferramentas. Os avanços em ciência e tecnologia têm se mostrado promissores no intuito de aprimorar setores como o agronegócio. E essa visão tem sido justificada pelo constante avanço de dispositivos tecnológicos projetados para apresentar soluções aos problemas agrícolas. Sendo assim, este estudo tem por objetivo analisar o processo de inovação no contexto da Inteligência Artificial (IA), desde a produção do conhecimento científico até a fase de predição dessa tecnologia no agronegócio na Caatinga. Do ponto de vista dos aspectos metodológicos a pesquisa é classificada como exploratória, uma vez que essa investigação leva em consideração uma área na qual há pouco conhecimento acumulado e sistematizado. Em relação à técnica de pesquisa, é caracterizada como estudo de caso. Os resultados da aplicação dos métodos da IA no agronegócio no contexto geral apresentam diferentes abordagens como o uso de Visão de Máquina por meio de Sistema Agrícola Virtual, SVM e ELM na detecção precoce do patógeno de pragas e doenças; FIS e MLP para a exploração de culturas; propagação reversa para monitoramento dos limites da fazenda; ANN e MFNN para análise de estruturas de irrigação; e Árvore da Decisão e TDNN para a vigilância do rebanho. Com os dispositivos integrados no sistema de produção agrícola, os sistemas das fazendas passam a oferecer recomendações e insights mais ricos para a tomada de decisão e melhoria da cadeia de suprimentos agrícola. Em relação ao levantamento das tecnologias atuais no agronegócio na Caatinga, o contexto local apresenta abordagens bem distintas, desde a utilização de técnicas de convivência com o semiárido como os métodos de manejo do solo, aproveitamento da água da chuva e preparo de ração animal. Já a análise do uso das tecnologias, o foco está na viabilidade da produção, diversificação e manejo da colheita em polos integrados de grande desenvolvimento tecnológico em polos de cultivo e manejo de culturas irrigadas. A perspectiva da adoção e o desenvolvimento de IA no agronegócio na Caatinga ainda se encontram em fase inicial, com os agentes buscando nas pesquisas, conhecer as oportunidades dessa tecnologia frente aos negócios no setor agrícola. Na Caatinga, os estudos ainda são reduzidos, mas já há exemplos como rastreabilidade de carne, predição da produtividade da palma forrageira, delineamento de zonas de manejo ou mesmo na estimativa da evapotranspiração de referência. Contudo, há etapas que devem ser superadas até a integração da IA como a habilidade de entender e manusear as ferramentas com IA e a integração dos sistemas dentro da cadeia de suprimentos. Já os resultados do levantamento sistemático apresentam ações como modelagem e previsão do fluxo de água; evapotranspiração; variabilidade, avaliação de terra; previsão de época ótima de semeadura e seleção de cultivares. De modo que, os achados apresentam os diferentes usos da IA, com iniciativas de sustentabilidade habilitadas por mudanças no sistema agrícola atual.

Palavras-chave: Agricultura 5.0. Agricultura de sequeiro. Semiárido Brasileiro. Tomada de decisão. Empreendedorismo.

ABSTRACT

Science and technology, in different forms, have always played an expressive role in problem solving, being used for the development of strategies, products, methods and tools. Advances in science and technology have shown promise in order to improve sectors such as agribusiness. And this vision has been justified by the constant advancement of technological devices designed to present solutions to agricultural problems. Therefore, this study aims to analyze the innovation process in the context of artificial intelligence, from the production of scientific knowledge to the prediction phase of this technology in agribusiness in the Caatinga. From the point of view of methodological aspects, the research is classified as exploratory, since this investigation takes into account an area in which there is little accumulated and systematized knowledge. Regarding the research technique, it is characterized as a case study. The results of the application of AI methods in agribusiness in the general context present different approaches such as the use of Machine Vision through Virtual Agricultural System, SVM and ELM in the early detection of the pathogen of pests and diseases; FIS and MLP for the exploitation of cultures; reverse propagation for monitoring farm boundaries; ANN and MFNN for analysis of irrigation structures; and Decision Tree and TDNN for herd surveillance. With the devices integrated into the agricultural production system, farm systems now offer richer recommendations and insights for decision making and agricultural supply chain improvement. Regarding the survey of current technologies in agribusiness in the Caatinga, the local context presents very different approaches, from the use of technologies of coexistence with the semi-arid region or social techniques such as methods of soil management, use of rainwater and preparation of feed. animal. Even the use of technologies themselves aimed at the viability of production, diversification and management of the harvest in integrated poles of great technological development in poles of cultivation and management of irrigated cultures. The perspective of the adoption and development of AI in agribusiness in the Caatinga is still at an early stage, with agents seeking, in research, to know the opportunities of this technology in relation to business in the agricultural sector. In the Caatinga, studies are still very limited, but there are already examples such as meat traceability, prediction of forage cactus productivity, delineation of management zones or even in the estimation of reference evapotranspiration. However, there are steps that must be overcome until the integration of AI such as the ability to understand and handle the tools with AI and the integration of systems within the supply chain. On the other hand, the results of the systematic survey present actions such as modeling and forecasting the water flow; evapotranspiration; variability, land assessment; prediction of optimal sowing time and selection of cultivars. So, the findings present the different uses of AI, with sustainability initiatives enabled by changes in the current agricultural system.

Keywords: Agriculture 5.0. Rainfed agriculture. Brazilian semiarid. Decision making. Entrepreneurship.

LISTA DE ILUSTRAÇÕES

Figura 1.1 – Síntese estrutural desenvolvida na tese.....	22
Figura 2.1 – Etapas da pesquisa e revisão.....	28
Figura 2.2 – Interface de gestão e tomada de decisão com IA na Atividade Agrícola.....	29
Figura 2.3 – Principais campos de Inteligência Artificial.....	31
Figura 2.4 – Propostas de aplicação de Redes Neurais Artificiais.....	34
Figura 2.5 – Propostas de aplicação da aprendizagem supervisionada.....	36
Figura 2.6 – Propostas de aplicação de sistemas variados de IA.....	39
Figura 2.7 – Métodos de Aprendizado de Máquina da extração de literatura.....	41
Figura 3.1 – Processos da Revisão Sistemática.....	53
Figura 3.2 – Dados anuais, localização, culturas estudadas e atividades predominantes. ..	54
Figura 3.3 – Mapa do Bioma Caatinga e da Região do Semiárido Brasileiro.....	56
Figura 3.4 – Cores das fibras de cultivares brasileiras de algodão naturalmente colorido.	66
Figura 3.5 – Tecnologias utilizadas no agronegócio na Caatinga.....	70
Figura 4.1 – Perfis dos especialistas entrevistados.....	84
Figura 4.2 – Processos da Revisão Sistemática.....	86
Figura 4.3 – Sequenciamento para uso de modelos híbridos de IA.....	96
Figura 4.4 – Aplicações de IA em sistemas agrícolas.....	100

LISTA DE SIGLAS

ABC	Colônia Artificial de Abelha
AL	Alagoas
ANN	Redes Neurais Artificias
APAC	Agência Pernambucana de Águas e Clima
API	Interfaces do Programa de Aplicativo
ASA	Articulação Semiárido Brasileiro
ATER	Assistência Técnica e de Extensão Rural
BA	Bahia
CART	Árvore de Classificação e Regressão
CE	Ceará
CNN	Rede Neural de Convolução
CPAs	Centros de Pesquisa Aplicada
ELM	Aprendizado de Máquina Extremo
ELM	Aprendizado de Máquina Extremo
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ES	Sistemas Especialistas
FIS	Sistema de Inferência Fuzzy
GA	Algoritmo Genético
GPU	Unidades de Processamento Gráfico
IA	Inteligência Artificial
ICA	Algoritmo Competitivo Imperialista
IFBA	Instituto Federal de Educação, Ciência e Tecnologia da Bahia
IFRN	Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte
IFSPE	Instituto Federal Sertão Pernambucano
INSA	Instituto Nacional do Semiárido
IoT	Internet das Coisas
IPA	Instituto Agrônômico de Pernambuco
MA	Maranhão
MATOPIBA	Maranhão, Tocantins, Piauí e Bahia
METRIC	Mapeamento da Evapotranspiração em Alta Resolução e Calibração Internalizada
MFNN	Rede Neural com Alimentação Multicamada
MG	Minas Gerais
MLP	<i>Perceptron</i> Neural em Multicamadas
NLP	Processamento de Linguagem Natural
PB	Paraíba
PE	Pernambuco
PI	Piauí
PIB	Produto Interno Bruto
PRISMA	Principais Itens para Relatar Revisões Sistemáticas e Meta-análises
RIDE	Região Integrada de Desenvolvimento Econômico do Polo Petrolina e Juazeiro
RN	Rio Grande do Norte
SAB	Semiárido Brasileiro
SAFER	Algoritmo Simples para Recuperação de Evapotranspiração
SDTF	Floresta Tropical Sazonalmente Seca

SE	Sergipe
SUDENE	Superintendência de Desenvolvimento do Nordeste
SVM	Máquina de Vetores de Suporte
SVR	Regressão do Vetor de Suporte
TDNN	Rede Neural com Retardo de Tempo
TICs	Tecnologias de Informação e Comunicação
UFC	Universidade Federal do Ceará
UFCG	Universidade Federal de Campina Grande
UFPB	Universidade Federal da Paraíba
UFPE	Universidade Federal de Pernambuco
UFPI	Universidade Federal do Piauí
UFRB	Universidade Federal do Recôncavo da Bahia
UFRN	Universidade Federal do Rio Grande do Norte
UFRPE	Universidade Federal Rural de Pernambuco
UFRSA	Universidade Federal Rural do Semi-Árido
UNIMONTES	Universidade Estadual de Montes Claros
UNIVASF	Universidade Federal do Vale do São Francisco
UVA	Universidade Estadual Vale do Acaraú
WNN	Rede Neural Wavelet
WSN	Rede de Sensores Sem Fio

SUMÁRIO

1	INTRODUÇÃO	14
1.1	ASPECTOS INICIAIS	14
1.2	PROBLEMA DE PESQUISA	17
1.2.1	Questões Iniciais: Produção Científica	17
1.2.2	Questões Intermediárias: o Mercado e a Difusão das Tecnologias	17
1.2.3	Questão Final: Prospecção de Serviços	18
1.3	OBJETIVOS	19
1.3.1	Objetivo Geral	19
1.3.2	Objetivos Específicos	19
1.4	JUSTIFICATIVA	19
1.5	ESTRUTURA DA TESE	21
2	CAPÍTULO I - GESTÃO NO MEIO AGRÍCOLA COM O APOIO DA INTELIGÊNCIA ARTIFICIAL: UMA ANÁLISE DA DIGITALIZAÇÃO NO AGRONEGÓCIO	24
2.1	INTRODUÇÃO	24
2.2	MATERIAL E MÉTODOS	26
2.3	RESULTADOS E DISCUSSÕES	28
2.3.1	Campos da Inteligência Artificial	30
2.3.2	Redes Neurais Artificiais	33
2.3.3	Aprendizagem Supervisionada	35
2.3.4	Métodos Dinâmicos	38
2.4	CONCLUSÕES	42
	REFERÊNCIAS	43
3	CAPÍTULO II - DIFUSÃO DE TECNOLOGIAS NO MEIO AGRÍCOLA NA CAATINGA - REGIÃO DE CLIMA SEMIÁRIDO BRASILEIRA	49
3.1	INTRODUÇÃO	50
3.2	ASPECTOS METODOLÓGICOS	52
3.3	RESULTADOS	57
3.3.1	Técnicas sociais	57
3.3.2	Tecnologias	61
3.3.3	Discussões	68
3.4	CONCLUSÕES	72
	REFERÊNCIAS	74

4	CAPÍTULO III - ANÁLISE DINÂMICA PARA O USO DA INTELIGÊNCIA ARTIFICIAL NO AGRONEGÓCIO NA CAATINGA - MAIOR REGIÃO SEMIÁRIDA DA AMÉRICA DO SUL	80
4.1	INTRODUÇÃO	81
4.2	ASPECTOS METODOLÓGICOS	83
4.3	RESULTADOS	86
4.3.1	Perspectiva da IA na Caatinga na concepção dos especialistas.....	86
4.3.2	Explorando a literatura científica acerca do uso de IA em zonas semiáridas.....	92
4.3.3	Discussões.....	101
4.4	CONCLUSÕES	103
	REFERÊNCIAS	104
5	CONSIDERAÇÕES FINAIS	112
	REFERÊNCIAS	117

1 INTRODUÇÃO

1.1 ASPECTOS INICIAIS

A abordagem de agricultura digital combina as novas tecnologias e os dados para otimizar a qualidade da gestão e monitoramento das atividades agrícolas (AHMAD *et al.*, 2022), de modo que a adoção das tecnologias aumentou a conectividade, a eficiência e a produtividade em vários setores (ATWELL; WUDDIVIRA, 2022). A fusão bem-sucedida de tecnologia e dados é dependente da coleta de parâmetros, da adoção de modelagem e da integração de tecnologia que está sendo implementada com precisão de acordo com as necessidades especificadas da fazenda (TIEN, 2017; VROCHIDOU *et al.*, 2022). No agronegócio, o uso de tecnologias disruptivas tem fortalecido a conectividade da cadeia de suprimentos de ponta a ponta, proporcionado o monitoramento e o controle de forma remota e em tempo real (ALZU'BI *et al.*, 2019; BHAGAT; BARUAH; MUKHERJEE, 2022; CAMARÉNA, 2020; SRINIVASAN, 2018).

No Brasil, o setor corresponde a um dos pilares econômicos do Produto Interno Bruto (PIB) nacional, e assim como em outros setores, o agronegócio vem passando por inúmeras mudanças, principalmente na chamada Era da Informação (ALWIS *et al.*, 2022; DUTRA; SILVA, 2016; GARCIA *et al.*, 2019). Se anteriormente o setor era visto como detentor de três fatores clássicos de produção: terra, trabalho e capital, viu surgir a "informação e conhecimento" como um quarto fator (ALTHOFF, 2013; MOLOTKOVA *et al.*, 2020). Essa comprovação ganha pertinência ao se abordar o desafio de dobrar o rendimento das colheitas até o ano de 2050 para possibilitar a alimentação de mais de nove bilhões de pessoas em todo o mundo (WOLFERT *et al.*, 2017). Em contrapartida a essa necessidade, a quantidade de terra arável nos países vem diminuindo, havendo necessidade de concentrar os esforços no melhor emprego do conhecimento e da tecnologia visando o aumento da produtividade (ALZOUBI; ALMALIKI; MIRZAEI, 2019).

Neste contexto, a Inteligência Artificial (IA) torna-se relevante, ao revelar uma variedade de tecnologias de potencial a serem aplicadas, fornecendo um cenário de domínio agrícola e ambiental por um conjunto cada vez maior de conhecimento publicamente acessível (TIEN, 2017; WOLFERT *et al.*, 2017). A IA se origina da capacidade de simular o comportamento do cérebro humano para resolver problemas complexos e poder apresentar uma estratégia eficiente de simulação e otimização de processos na atividade agrícola

(CHEN; JAKEMAN; NORTON, 2008; ILIADIS; MARIS, 2007; MAY; SIVAKUMAR, 2009; RAJANAYAKA; SAMARASINGHE; KULASIRI, 2001).

A IA é caracterizada pela capacidade do sistema de interpretar corretamente dados externos, aprender a partir desses dados e utilizar essa aprendizagem para atingir objetivos e tarefas específicos por meio de adaptação flexível (KAPLAN; HAENLEIN, 2019). Assim, as técnicas de IA como redes neurais artificiais e *clustering* são utilizadas para analisar os dados agrícolas em prol da tomada de decisão inteligente, esses bancos de dados (*Big Data*) podem ser coletados e transferidos por tecnologias como Internet das Coisas (IoT - *Internet of Things*) (BU; WANG, 2019; CHEN; JAKEMAN; NORTON, 2008). Tecnologias como a IoT e a Computação em Nuvem (*Cloud Computing*), tende a alavancar o desenvolvimento e a disseminação da IA no agronegócio (BAYATVARKESHI *et al.*, 2020). A combinação dessas tecnologias pode ser compreendido como um facilitador de informação para as empresas agrícolas, tornando-as mais eficientes e produtivas de modo a possibilitar que a tomada de decisão seja economicamente viável e ambientalmente amigável (JARRAHI, 2018; SUNDMAEKER *et al.*, 2016).

No campo agrícola, tecnologias disruptivas como a IA podem contribuir significativamente para organizar, conectar e desenvolver ainda mais o conhecimento, a fim de suprir melhor a demanda coletiva por alimentos (BU; WANG, 2019; SIMÕES, 2018; WOLFERT *et al.*, 2017). Os sistemas alimentares e agrícolas devem conciliar a necessidade de produzir alimentos em quantidade e qualidade sem a degradação dos ecossistemas ambientais, numa perspectiva de transição da revolução da agricultura inteligente para a agricultura 5.0 (FRASER; CAMPBELL, 2019; MASSRUHÁ *et al.*, 2020; SILVEIRA; LERMEN; AMARAL, 2021). Um exemplo desse tipo de contribuição é o emprego de ferramentas de modelagem no uso dos recursos hídricos, na racionalização de custos e diminuição de esforços, sempre influenciando as variáveis complexas e inter-relacionadas dos processos produtivos (ALAGHA *et al.*, 2017; BUGHIN *et al.*, 2018; CHUI *et al.*, 2018; ROOPAEI; RAD; CHOO, 2017).

Outro exemplo, é o uso da IA para a realização do zoneamento climático, com isso, determinar o potencial agrícola de uma região. Algo que tende proporcionar ao agricultor não só a escolha da melhor cultura para aquele local, mas também a aplicação de técnicas de manejo, como o uso de sistemas de irrigação artificial e de mitigação dos efeitos de eventos atmosféricos adversos: chuvas, ventos, temperaturas dentre outros (OLIVEIRA; MOREIRA; FERREIRA, 2018; WALDHEIM *et al.*, 2006). Na região Nordeste do Brasil,

particularmente na zona semiárida, onde a agricultura é a principal atividade econômica e a pecuária ainda é realizada com um baixo nível tecnológico (BARBOSA *et al.*, 2015), conhecer melhor os paradigmas pode ser determinante para a realização de um melhor planejamento e gestão dos recursos naturais. A zona semiárida nordestina corresponde a toda a área do bioma Caatinga, a maior e mais populosa região semiárida da América Latina, sendo extremamente vulnerável à degradação do solo em decorrência de fatores climatológicos e antrópicos adversos (SANTOS *et al.*, 2020a). Dentre esses fatores, a seca – período longo de deficiência hídrica, é o que mais afeta a sociedade por atuar em grandes extensões territoriais e por longos períodos impactando significativamente nos aspectos edáfico, meteorológicos e hídricos (ROCHA JÚNIOR *et al.*, 2020; SANTOS *et al.*, 2020b).

Ao realizar um levantamento das condições do agronegócio na Caatinga é possível observar duas perspectivas distintas: a primeira corresponde à atividade agrícola tradicional com os estabelecimentos da agricultura familiar que produzem de forma convencional, pouco produtiva, sendo tipicamente praticada com baixo uso de insumos e composta por mais de uma atividade produtiva na mesma área, como a agricultura de subsistência e a pecuária extensiva na maior parte do bioma (VILELA; CALLEGARO; FERNANDES, 2019); e a segunda representada pela agricultura irrigada na Caatinga a qual tem contribuído para o fortalecimento socioeconômico por meio de práticas agrícolas diversificadas, impulso à agroindústria e exportação de produtos em larga escala (LACERDA *et al.*, 2021).

Essa divisão tornou-se possível a partir da implementação de modernos sistemas de transporte de águas do rio São Francisco ou de reservatórios até as propriedades rurais em polos de desenvolvimento agrícola integrado (PEREIRA; CARMO, 2014), bem como pelo uso de alta tecnologia paralelamente associada à entrada de empresas agrícolas, agroquímicas, agroindustriais, atacadistas e varejistas (OLIVEIRA; RODRIGUES, 2020). Fato este que transformou áreas ‘marginais’ em ‘vales’ ou regiões integradas de desenvolvimento agrícola, as principais responsáveis por produzir e exportar frutas no Brasil (CARNEIRO *et al.*, 2019; SILVA *et al.*, 2020b).

Portanto, o potencial da utilização da IA pode permitir o desenvolvimento econômico e, ao mesmo tempo, melhorar os indicadores de sustentabilidade (PALMER, 2017; PYKA, 2017). E entender os princípios dos processos de um sistema tão amplo é passo importante na direção a um melhor aspecto que permita encontrar soluções sólidas e sustentáveis para o agronegócio na Caatinga com o apoio da IA. Ao mesmo tempo, que o desenvolvimento da IA na Caatinga passa por variáveis ajustadas ao ambiente, visando a melhora na

autocorrelação dos indicadores. Neste sentido, prever o uso dessa tecnologia no agronegócio no bioma vislumbra o desenvolvimento de sistemas agrícolas que visam conciliar a necessidade de produzir alimentos com o imperativo igualmente importante de garantir a não degradação dos ecossistemas locais.

1.2 PROBLEMA DE PESQUISA

1.2.1 Questões Iniciais: Produção Científica

A IA deve impactar positivamente no agronegócio, pois, como setor altamente competitivo e globalizado, os produtores e outros atores devem considerar aspectos ambientais e geográficos locais. Ao mesmo tempo tem de levar em consideração os fatores ecológicos e políticos globais, a fim de garantir a sobrevivência econômica e a produção sustentável (DENGEL, 2013). Mesmo assim, a atividade agrícola ainda é um dos últimos setores a passar pelo processo de digitalização e uso das Tecnologias de Informação e Comunicação (TIC), quando comparado a outros setores econômicos (PIVOTO *et al.*, 2018; WOLFERT *et al.*, 2017).

Ao analisar o contexto econômico, a dinâmica das inovações, as mudanças estruturais na economia e na sociedade mostram que as revoluções tecnológicas se originam do desenvolvimento científico anterior em outras áreas do conhecimento (DOSI, 1984; FREEMAN, 1989). Posteriormente, esse conhecimento científico passa por desenvolvimento tecnológico e comercial nas organizações. Assim, para entender o processo de desenvolvimento tecnológico e inovação com IA, é importante compreender o cenário atual da ciência e o estado da arte da produção científica sobre a temática. Nisso, surgem as primeiras questões a serem respondidas: Como o conceito de Inteligência Artificial no agronegócio é definido na literatura científica? Como a ciência aborda essa questão? Quais os métodos e funcionalidades dessa tecnologia no campo?

1.2.2 Questões Intermediárias: o Mercado e a Difusão das Tecnologias

A atividade agrícola requer uma melhor compreensão para lidar com a complexidade, incertezas e imprecisões inerentes a alimentar a população mundial em crescimento, com necessidade de aumento contínuo na produção de alimentos, só que com o limitador de terra

arável (LIU, 2017). Novas soluções nos aspectos da produção agrícola tendem a ser a solução viável - desde um planejamento melhor e previsível da safra até a agricultura de precisão, aplicação otimizada de recursos e apoio a projetos eficientes e colaborativos (ALZOUBI; ALMALIKI; MIRZAEI, 2019; SHAKIBAI; KOOCHEKZADEH, 2009). Isso implica também no desenvolvimento de processos que utilizem tecnologias poupadoras de recursos e que sejam capazes de alcançar soluções autônomas, de forma parcial ou total até o desenvolvimento sustentável no longo prazo.

Na Caatinga, o manejo adequado das culturas agrícolas implica em conhecer os padrões de crescimento de cada variedade, fazendo com que as fases de máximo desenvolvimento coincidam com os períodos de maior disponibilidade hídrica e radiação solar, permitindo que a cultura expresse todo seu potencial produtivo (KEATING *et al.*, 1999; STONE; SORENSEN; JAMIESON, 1999). No entanto, a má distribuição e a redução dos volumes de chuvas têm sido uma constante na região nos últimos anos (2015-2018), trazendo prejuízos a inúmeras culturas, com a mortalidade e renovação precoce das plantações (XIMENES, 2018). Nesse contexto, surge mais uma questão: como os produtores poderão utilizar a IA para melhorar a gestão da informação visando a tomada de decisão?

1.2.3 Questão Final: Prospecção de Serviços

O paradigma de integrar as várias informações da agricultura abre novas possibilidades para os produtores, mas pode trazer mudanças para os gestores (ATWELL; WUDDIVIRA, 2022; YASEEN *et al.*, 2015). Um primeiro aspecto a ser destacado é a possibilidade de um novo relacionamento consultivo com profissionais técnicos da área, a exemplo de administradores, agrônomos e zootecnistas (AHMAD *et al.*, 2022; TABARI; TALAEI; WILLEMS, 2015). Com maior volume de dados remotamente transmitidos e informações automáticas, os consultores profissionais podem enviar relatórios e informações diárias aos agricultores, buscando uma melhor assistência administrativa (VROCHIDOU *et al.*, 2022; ZARE; KOCH, 2021). Além disso, as novas tecnologias tendem a contribuir na identificação de soluções potenciais para a sociedade local visando conciliar a conservação ambiental, a prosperidade socioeconômica, o desenvolvimento rural e as mudanças climáticas (BILALI; TALEB, 2020; TABARI; TALAEI; WILLEMS, 2015; UNTARU; ROTARESCU; DORNEANU, 2012). Sendo assim, como a Inteligência Artificial pode

contribuir para o desenvolvimento do agronegócio na Caatinga? Quais os desafios encontrados na predição para o uso da IA no agronegócio na Caatinga?

1.3 OBJETIVOS

1.3.1 Objetivo Geral

Analisar o processo de inovação no contexto da Inteligência Artificial, desde a produção do conhecimento científico até a fase de predição dessa tecnologia no agronegócio na Caatinga.

1.3.2 Objetivos Específicos

- (i) Caracterizar o conhecimento científico sobre IA na atividade agrícola;
- (ii) Identificar as tecnologias utilizadas na atividade agrícola na Caatinga;
- (iii) Descrever as perspectivas atuais da IA na Caatinga sob a ótica de especialistas da área;
- (iv) Apresentar as principais aplicações da IA no agronegócio em ambientes semiáridos.

1.4 JUSTIFICATIVA

O aumento progressivo da população mundial exige continuamente aumento na produção agrícola. A adoção de tecnologias como IA pode ser uma forma de atender às demandas da sociedade, como segurança alimentar, sustentabilidade e preservação ambiental (SILVA *et al.*, 2020c). A partir de uma abordagem microeconômica dos sistemas de produção agrícola é possível observar que a manutenção das culturas requer ganhos de produtividade ou redução de custos; para isso, precisa-se avançar na adoção de tecnologias (COELHO JUNIOR *et al.*, 2020).

O agronegócio é uma atividade antrópica que consome bastante água. As atividades agrícolas são altamente influenciadas pelas condições climáticas, principalmente por abrangerem o manejo do solo, a semeadura, a colheita, o transporte e o armazenamento dos produtos (SILVA *et al.*, 2013; WALDHEIM *et al.*, 2006). Os frequentes eventos de seca que

afetam as vastas áreas do globo impõem uma gestão cada vez mais cuidadosa dos recursos hídricos, tanto em escala global quanto na escala das bacias hidrográficas individuais (DIXON, 2005; GRANATA, 2019; PELESARAEI *et al.*, 2016). Nas regiões áridas e semiáridas, o problema é ainda mais grave, os períodos de alta demanda de água coincidem com os baixos períodos de chuvas (NARAYAN; SCHLEEBERGER; BRISTOW, 2007; SEYAM; OTHMAN; EL-SHAFIE, 2017). A produção agrícola (especialmente das culturas de sequeiro), flutua frequentemente nos ecossistemas limitados pela água, secas periódicas e chuvas irregulares (SALEHNIA *et al.*, 2019). No Brasil, a região semiárida (Caatinga) representa aproximadamente cinquenta e sete por cento do território nordestino e sua principal atividade econômica é a agricultura, em sua maioria de subsistência (BARBOSA *et al.*, 2015).

A tendência em longo prazo da precipitação e temperatura mostra que pode haver o agravamento nas mudanças e ainda mais oscilações de produtividade (TABARI; TALAEE, 2011). Nesse sentido, o planejamento e monitoramento das práticas agrícolas tornam-se indispensáveis para aliviar os prováveis efeitos adversos. Faz-se mister avaliar as reais condições que satisfazem as necessidades das culturas, bem como as tecnologias disponíveis que auxiliem na viabilidade agrícola sustentável (XIMENES, 2018). Para que isso ocorra, há a necessidade da intensificação do conhecimento em novas formas de gestão no agronegócio, algo que requer a adoção de tecnologias inteligentes, como IA. O uso dessa tecnologia tem sido para muitas agências governamentais seu principal foco, dadas as preocupações sobre a significativa quantidade de dados que pode ajudar os produtores a melhorarem a produtividade e a sustentabilidade (GRIEVE *et al.*, 2019; PURDY; DAUGHERTY, 2017).

Estima-se que as ferramentas de IA têm o potencial de crescimento agrícola até 2035, de 1,3% a 3,4%, um dos maiores aumentos percentuais de indústrias agrícolas estudadas (ONU, 2019-). A maioria dos relatórios afere que o valor para o setor de tecnologia de IA e Tecnologias Inteligentes na agricultura, tende a causar impacto complexo e multifacetado, com grandes variações no potencial entre fazendas, empresas e países (GRIEVE *et al.*, 2019). Mesmo com essa perspectiva, no continente americano a atividade agrícola ainda está atrasada na adoção de tecnologias com IA (DEFRA, 2018). Neste continente, a aplicação da IA sofre resistência pelo uso de práticas tradicionais e o rompimento das barreiras econômicas e tecnológicas passa pelas influências sociológicas (GOLDSMITH; BURTON, 2017; ÖHMAN; FLORIDI, 2018). Essa influência se baseia em modelos lineares de

transferência de tecnologia para os agricultores e nas quais, as inovações derivam da capacidade de ganhos de produtividade e modelagem das práticas atuais de manejo dos recursos naturais (BUGHIN *et al.*, 2018; CHUI *et al.*, 2018). Considerando as atuais restrições financeiras e tecnológicas, essas tendências, isoladas ou coletivas, provavelmente representam uma pressão adicional sobre os recursos já escassos no bioma. Assim, é cada vez mais reconhecida a inevitabilidade de assegurar que as motivações, sensibilidades, prioridades e conhecimento dos agricultores sejam adequadamente integradas com as tecnologias. Com isso, o uso da IA tende a somar potencialmente no apoio à eficiência operacional e à tomada de decisão estratégica.

1.5 ESTRUTURA DA TESE

Este manuscrito é composto por cinco seções: introdução, capítulo I, capítulo II, capítulo III, considerações finais. Sendo a pesquisa propriamente dita subdividida nos três capítulos: o primeiro aborda os estudos acerca da IA no agronegócio de forma geral; o segundo se volta para estudos específicos com o levantamento das tecnologias atuais na Caatinga; e o terceiro traz uma análise por especialistas em torno das perspectivas atuais para a adoção da IA no agronegócio na Caatinga e os respectivos estudos complementares de utilização dessa tecnologia em ambientes semiáridos. Cada capítulo apresenta estudos individuais com metodologias, resultados e conclusões específicas, mesmo sendo complementares entre si e em consonância com os objetivos específicos para o alcance do objetivo geral da pesquisa (ver Figura 1.1).

Assim, a seção 1 traz a introdução da temática da IA no agronegócio, bem como apresenta a problematização e a justificativa para esta pesquisa. Contempla os fatores iniciais acerca do uso de diversas tecnologias que têm fortalecido a conectividade da cadeia de suprimentos de ponta a ponta, proporcionado o monitoramento e o controle de forma remota e em tempo real.

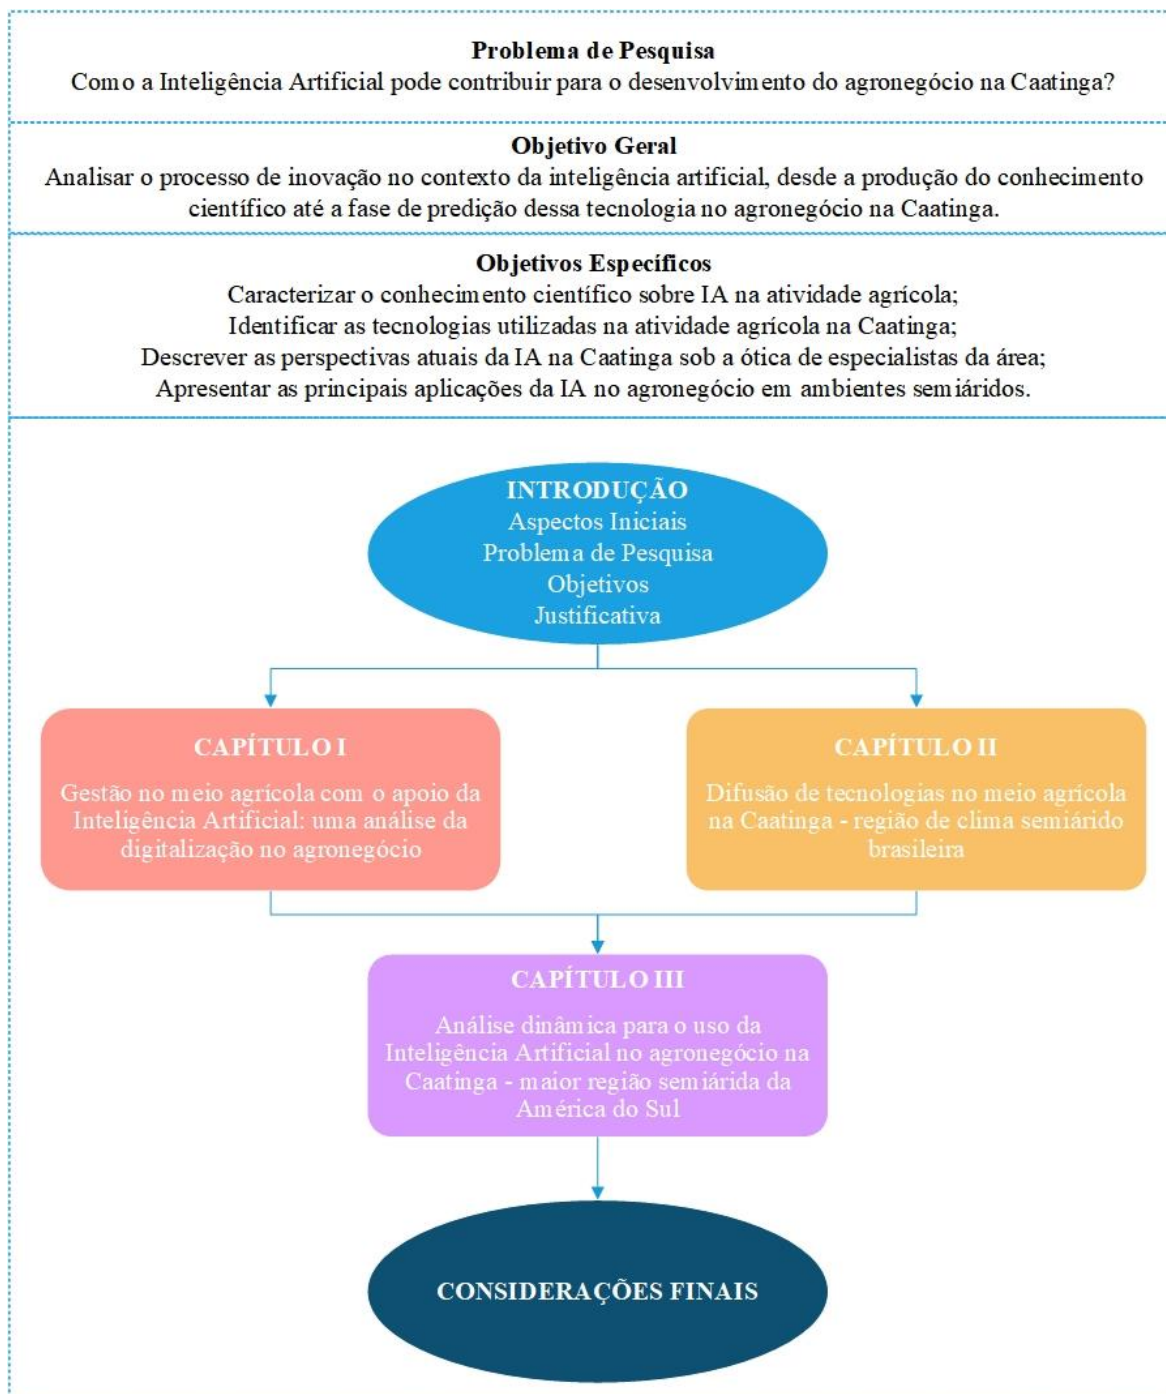
A seção 2 discute o estado da arte da IA no agronegócio a partir de um protocolo de revisão sistemática. Realizou-se a revisão de documentos da literatura científica mundial, publicados em periódicos, que possuíam como objetivo apresentar os mais variados métodos de IA aplicados à atividade agrícola. Os documentos que cumpriam com este requisito foram minuciosamente avaliados e representam as diferentes estruturadas e abordagens das ramificações da IA.

Já a seção 3 faz o levantamento sistemático das tecnologias utilizadas na Caatinga, apresentando inicialmente as tecnologias de convivência com o semiárido ou técnicas sociais, como os métodos de manejo do solo, aproveitamento da água da chuva e preparo de ração animal. E depois, as tecnologias propriamente ditas, com as evidências que convergem para a utilização tecnológica direcionada à viabilidade da produção, diversificação e tempo de colheita principalmente de culturas irrigadas.

A seção 4 aborda as perspectivas do uso da IA na Caatinga por especialistas de organizações de fomento à pesquisa. Assim como, faz o levantamento dessa tecnologia disruptiva em ambientes semiáridos. Essa seção busca compreender a fase atual de adoção e do desenvolvimento de IA na Caatinga, buscando conhecer as oportunidades dessa tecnologia para os negócios no setor agrícola no bioma.

A seção 5 apresenta as considerações finais da tese, expressando as conclusões obtidas por meio das leituras, análises dos dados e escritas desenvolvidas e discutidas ao longo dos textos apresentados. Aborda-se uma recapitulação de cada capítulo desenvolvido, com considerações pertinentes aos capítulos e à tese.

Figura 1.1 – Síntese estrutural desenvolvida na tese.



Fonte: Dados da Pesquisa (2022).

Cabe destacar que esta pesquisa emprega uma abordagem multidisciplinar contemporânea que endossa um estudo construído em torno dos objetivos pré-definidos, sendo construída sob a ótica da formação e gestão do conhecimento, ao abordar sua importância em prol da difusão de pesquisas no bioma Caatinga.

2 CAPÍTULO I - GESTÃO NO MEIO AGRÍCOLA COM O APOIO DA INTELIGÊNCIA ARTIFICIAL: UMA ANÁLISE DA DIGITALIZAÇÃO NO AGRONEGÓCIO¹

Resumo

A aplicação da Inteligência Artificial aos dados dos sensores e nos sistemas de gerenciamento de fazendas está evoluindo para programas de acompanhamento em tempo real, que fornecem recomendações e *insights* valiosos em ação e apoio à decisão dos agricultores. Neste artigo, apresenta-se uma revisão dedicada a aplicações da Inteligência Artificial na produção agrícola. Os trabalhos analisados foram categorizados em (a) redes neurais; (b) aprendizagem supervisionada e (c) métodos dinâmicos. A categorização dos artigos demonstrou como a agricultura pode se beneficiar das tecnologias com o apoio da Inteligência Artificial, por meio do gerenciamento e tomada de decisão mais precisos, assim como otimizando a lucratividade, a produtividade e a sustentabilidade. Assim, resultando em métodos que podem ser eficazes se integrados a um sistema de informação robusto e construído em funções que podem ser cobertas por seus usuários.

Palavras-chave: *E-agriculture*. Aprendizado de Máquina. Sistemas especializados. Árvore de Decisão.

Abstract

The application of artificial intelligence to sensor data and farm management systems is evolving into real-time monitoring programs, which provide valuable recommendations and ideas in action and support farmers' decisions. In this article, a review dedicated to applications of artificial intelligence in agricultural production is presented. The works were categorized into (a) neural networks; (b) supervised learning and (c) dynamic methods. The categorization of articles, how agriculture can benefit from technologies supported by artificial intelligence, through more accurate management and decision-making, as well as optimizing profitability, productivity and sustainability. Resulting in methods that can be effective if integrated with a robust information system and built-in functions that can be covered by its users.

Keywords: E-agriculture. Machine Learning. Specialized systems. Decision tree.

2.1 INTRODUÇÃO

As constantes mudanças no ambiente agrícola têm exigido cada vez mais soluções equilibradas e contínuas, face a diminuição da disponibilidade de mão-de-obra, da baixa nos recursos naturais, da escassez média de recursos agrícolas, da alta idade média dos agricultores e da baixa renovação da população agrícola (FENG, 2019; LI; YANG, 2018).

¹ Manuscrito submetido e aprovado para publicação no periódico Revista em Agronegócio e Meio Ambiente – RAMA, com previsão de publicação em julho no v. 15, n. 3 de 2022.

Uma alternativa a esses desafios é a adoção da Inteligência Artificial (IA), visando a modernização da atividade agrícola. A IA é a capacidade do sistema para interpretar corretamente dados externos, aprender a partir desses dados e utilizar dessa aprendizagem para atingir objetivos e tarefas específicas por meio de adaptação flexível (KAPLAN; HAENLEIN, 2019). Na perspectiva agrícola, a IA visa identificar e fazer uso do potencial da produtividade resultante de equipamentos inteligentes: dados, informações, transmissões e processamento.

No setor agrícola, o desenvolvimento de tecnologias inteligentes como a Internet das Coisas - IoT (LI; YANG, 2018; PIVOTO *et al.*, 2018), Computação na Nuvem (ROOPAIEI; RAD; CHOO, 2017), *Big Data* (BRONSON; KNEZEVIC, 2016; WOLFERT *et al.*, 2017), Blockchain (ALMEIDA *et al.*, 2018; SEEBACHER; SCHÜRITZ, 2017), Inteligência Artificial (EVANS; TERHORST; KANG, 2017; UNTARU; ROTARESCU; DORNEANU, 2012), têm impulsionado o fenômeno chamado de Agricultura Inteligente (*Smart Farm*) ou *Agriculture 4.0* (ANDRITOIU *et al.*, 2018; BENTHAM, 1998; LEZOUCHE *et al.*, 2020).

A promoção da IA no campo, tende a contribuir para a redução de custos e o desenvolvimento sustentável do setor, auxiliando os sistemas de gerenciamento da cadeia produtiva e objetivando fornecer apoio as operações (PERINI; SUSI, 2004). No entanto, considerando a ampla variedade de métodos dentro da IA, torna-se fundamental conhecer as características individuais de métodos e o cenário para o uso (LI; YANG, 2018; PATRÍCIO; RIEDER, 2018).

Devido à relevância do assunto, algumas revisões foram produzidas nos últimos anos objetivando analisar a influência da Inteligência Artificial no meio agrícola. Alguns desses estudos, como o de Rooh, Li e Ali (2015), apresenta uma revisão sobre a integração da IA com técnicas de abordagem clássica e sugestões para exploração de variáveis de pesquisa para profissionais do meio agrícola. Dongre e Gandhi (2016), fazem uma análise das informações aprendidas por meio de experiências repetidas, semelhantes à aprendizagem humana, para fornecer classificação, reconhecimento de padrões, otimização e realização de previsões futuras no setor pecuário. Evans, Terhorst e Kang (2017) trazem implicações do estilo do agricultor para a condução situacional da decisão frente à incorporação da IA, assim como trata do gerenciamento de culturas por meio de plataformas tecnológicas. Patrício e Rieder (2018) analisam a aplicabilidade da IA na produção de grãos para a detecção de doenças, qualidade de grãos e fenotipagem. Chukwu (2019) faz uma revisão das aplicações da IA para aumentar a produtividade, por meio do manejo do solo, de culturas, de plantas

daninhas e de doenças. E Chia *et al.* (2020) apresentam um mapeamento das relações entre parâmetros climáticos e evapotranspiração para fornecer dados em tempo real do gerenciamento de recursos hídricos e manejo de irrigação.

A partir da análise das diferentes revisões, esta pesquisa, foi esquematizada em uma revisão que integre os conceitos e aplicabilidade dos campos da IA, baseados na atividade agrícola. Apresentando também os métodos e ramificações da Inteligência Artificial como aporte para o seu desenvolvimento em auxílio à tomada de decisão. O estudo tem a seguinte estrutura: os aspectos metodológicos - em que se apresenta a metodologia implementada para a coleta e categorização dos trabalhos citados; resultados da pesquisa - traz o aporte e discussão da implantação dos campos e métodos da IA no meio agrícola; e considerações finais – apresentam as conclusões do estudo e as expectativas futuras.

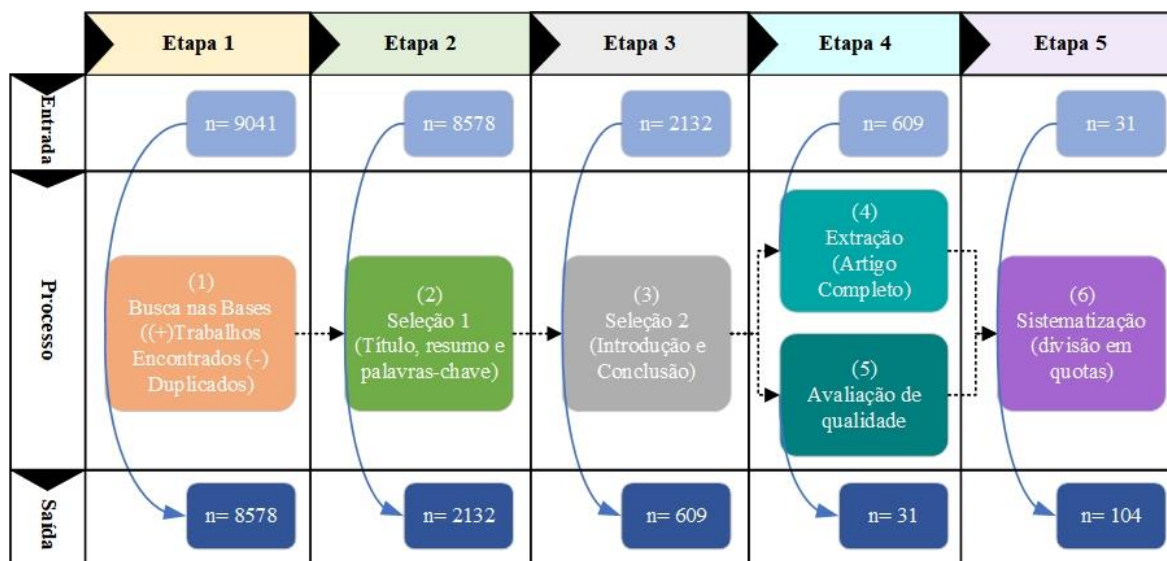
2.2 MATERIAL E MÉTODOS

Este artigo seguiu a abordagem sistemática, sendo feita a partir da busca de dados em quatro das principais bases de dados bibliográficos: *Science Direct*, *Scopus*, *Springer Link* e *Web of Science*, usando a combinação das palavras em inglês ("*artificial intelligence*" AND *Agric** OR *Agribusiness* OR *Farm** OR *e-agriculture*). As bases de dados foram escolhidas em decorrência de sua ampla cobertura de literatura relevante ao tema proposto, e ainda por recursos bibliométricos avançados, como sugerir literatura relacionada ou citações, sendo o inglês o idioma escolhido, por representar a língua com a maior quantidade de publicações nessas bases. Teve o período de 2000 a 2019 como tempo de análise, por corresponder ao período com maior número de publicações de artigos de acesso livre. A questão norteadora dessa revisão sistemática é: como a Inteligência Artificial está sendo utilizada no meio agrícola: campos, métodos e aplicações?

Com a pergunta definida, iniciou-se de fato a revisão sistemática da literatura, sendo feita em quatro etapas: (i) leitura do título, resumo e palavras-chaves - sendo necessário que esses elementos apresentassem alguma ligação à pergunta de pesquisa; (ii) leitura da introdução e conclusão - foi considerado o fato de haver na introdução ou na conclusão indícios que respondessem à questão da revisão; (iii) leitura do artigo completo, extração das cotas e avaliação da qualidade - foram extraídas cotas considerando que durante todo o artigo a temática tinha sido tratada com clareza e estavam adequadamente referenciados; e (iv)

análise e síntese das evidências – localização e separação das cotas que efetivamente respondiam à questão proposta pela revisão. Ver Figura 2.1 das etapas da revisão.

Figura 2.1 – Etapas da pesquisa e revisão.



Fonte: Dados da Pesquisa (2020).

A revisão sistemática seguiu o protocolo de Principais Itens para Relatar Revisões Sistemáticas e Meta-análises - PRISMA (2009), por ser uma estrutura metodológica bastante utilizada nesse tipo de pesquisa e que permite o desenvolvimento das etapas de forma clara e que possibilita replicações. A pesquisa foi desenvolvida no período de janeiro a junho de 2020, sendo apoiadas pelos softwares: StArt (3.3 Beta 03) para a organização dos dados e seleção dos artigos; e Mendeley (1.19.4) para a gestão bibliográfica.

2.3 RESULTADOS E DISCUSSÕES

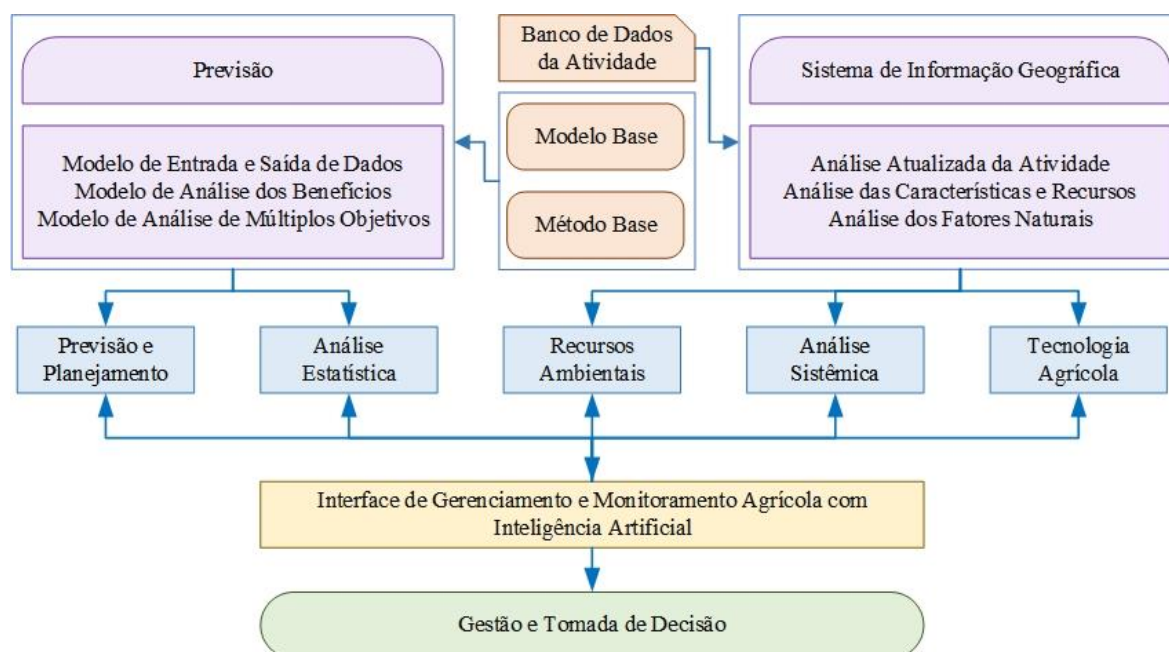
A atividade agrícola na maioria dos países desempenha papel crítico, tanto em fatores econômicos quanto ocupacional (LIAKOS *et al.*, 2018), de modo que a utilização de tecnologias no campo tende a impulsionar o setor para modernização, ao mesmo tempo em que busca soluções visando o uso efetivo de recursos escassos, frente ao crescente consumo global de alimentos (ALZOUBI; ALMALIKI; MIRZAEI, 2019; UNTARU; ROTARESCU; DORNEANU, 2012). Assim, há a inevitabilidade de que o setor torne-se mais eficiente e “inteligente” (NAVULUR; SASTRY; PRASAD, 2017).

Atualmente (2020), algumas atividades agrícolas já convivem com o poder computacional oferecido por sistemas eletrônicos incorporados paralelamente aos microprocessadores e às Unidades de Processamento Gráfico (GPU - *Graphics Processing Unit*). Essas tecnologias incluem: sensores ativos e sistemas robóticos autônomos singulares ou em rede, capazes de manipular e sentir os efeitos subsequentes em seu ambiente

(BAYINDIR, 2016; TAN; ZHENG, 2013); dispositivos de Internet das Coisas (IoT – *Internet of Things*) em rede sem fio para monitorar remotamente a umidade do solo, o crescimento das culturas e tomar medidas preventivas para detectar danos e ameaças (GUBBI *et al.*, 2013; KAMBLE; GUNASEKARAN; GAWANKAR, 2020; NAVULUR; SASTRY; PRASAD, 2017); ou mesmo, fornecimento de transparência, segurança, neutralidade e confiabilidade das operações na cadeia de suprimentos com o uso do Blockchain (ALMEIDA *et al.*, 2018; SEEBACHER; SCHÜRITZ, 2017).

Por sua vez a utilização da IA no campo agrícola, contribui para a monitoramento em tempo real das atividades de forma autônoma, visando analisar dados operacionais, combinados com informações de terceiros: serviços meteorológicos, conselhos de especialistas, etc., para fornecer ideias e melhorar a tomada de decisão (HUTSON, 2017; KARGAR; SHIRZADIFAR, 2013), ver Figura 2.2. Dada sua importância na simulação dos dados para gerar conhecimento exponencial e alternativas aos produtores (HASHIMOTO *et al.*, 2001), a IA exige que uma máquina (computador) perceba elementos em seu ambiente (recursos ambientais, tecnologias existentes) e retorne ao usuário - um ser humano ou outra máquina - algumas instruções ou informações (análises estatísticas, sistêmicas) que auxiliem o receptor a alcançar algum objetivo – planejamento, previsão e tomada de decisão (KUMAR; BHRAMARAMBA, 2017), ver Figura 2.2.

Figura 2.2 – Interface de gestão e tomada de decisão com IA na Atividade Agrícola.



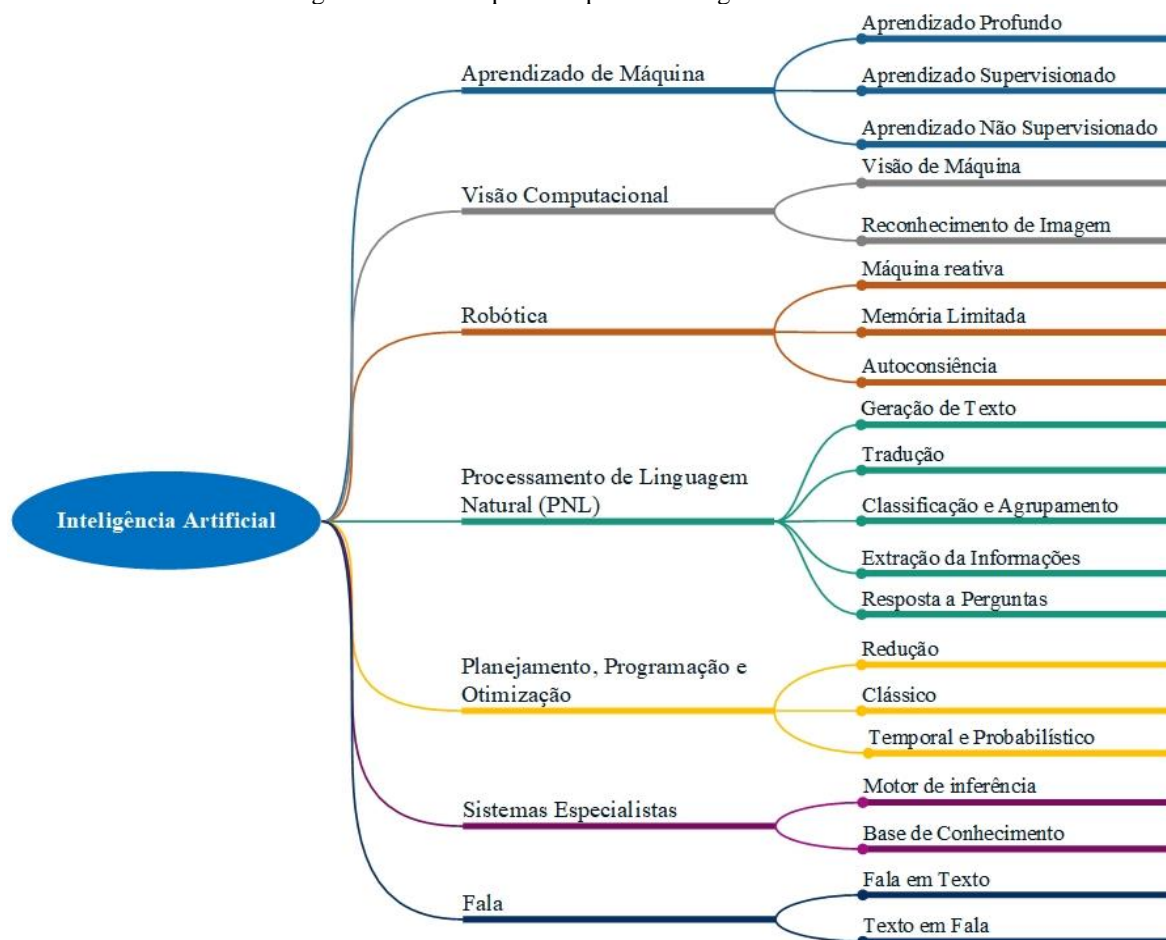
Fonte: Adaptado de Xue-Lei e Gong-Hu (2000).

A gestão e tomada de decisão com o apoio da IA passa pela integração de fatores como planejamento, análise estatística e sistêmica, recursos ambientais e tecnologias agrícolas (KOUADIO *et al.*, 2018; VENKATESH; THANGARAJ, 2008). Essa integração representa o acúmulo de fatores orientados para o desenvolvimento de sistemas baseados no conhecimento (KUMAR; BHRAMARAMBA, 2017). Isso contribui para diminuir o tempo em que as decisões são tomadas, bem como ampliar a consistência e a qualidade delas, expressa em características e recursos (MAHMOUD; M RAFEA; A RAFEA, 2008). A tomada de decisão apoiada pela IA pode, por exemplo, fazer previsão e simulação da produtividade de grãos de aveia com menor erro médio (DORNELLES *et al.*, 2018).

2.3.1 Campos da Inteligência Artificial

A previsão da produção agrícola exige ao menos dois campos da IA, o aprendizado de máquina e a visão computacional. Os algoritmos de visão computacional têm como funções, extraírem vetores de recursos de imagens e utilizarem para classifica-las (SABRI *et al.*, 2012). Já os algoritmos de aprendizagem de máquina realizam a classificação, agrupamento e identificação do que deve aprender quando a imagem é apresentada (KOUADIO *et al.*, 2018). Com isso, há um trabalho conjunto de dois campos para criar uma máquina mais inteligente, em que o aprendizado de máquina é o foco, ver Figura 2.3.

Figura 2.3 – Principais campos de Inteligência Artificial.



Fonte: Adaptado de Villaneuva e Salenga (2018).

A IA possui sete campos principais, o aprendizado de máquina talvez seja o mais conhecido e difundido, e que responde pela construção de algoritmos complexos a partir de conjuntos de dados que se prestam à previsão e revelação de insights ocultos por meio do aprendizado de relacionamentos históricos e tendências nos dados (CORTÉS *et al.*, 2000; KUMAR; BHRAMARAMBA, 2017). O Aprendizado Profundo é um subcampo da IA/aprendizado de máquina que faz uso de Redes Neurais Artificiais (ANN - *Artificial Neural Networks*), com algoritmos inspirados na estrutura e função do cérebro (DORNELLES *et al.*, 2018). As ANNs são processadoras de informação massivamente distribuídas em paralelo que têm características de desempenho semelhantes às redes neurais biológicas (VENKATESH; THANGARAJ, 2008). Elas foram desenvolvidas como uma generalização de modelos matemáticos do sistema neural humano (ALZOUBI; ALMALIKI; MIRZAEI, 2019).

A robótica e visão computacional representam outros dois campos da IA, esses campos são responsáveis por avanços tecnológicos em sistemas de posicionamento global,

tecnologias a laser, atuadores e mecatrônica (AMPATZIDIS; BELLIS; LUVISI, 2017). A Visão Computacional é um campo que visa dar a um computador a capacidade semelhante ou superior a de seres humanos, ao usar os sensores como olhos para identificar anomalias ao seu redor (VILLANUEVA; SALENGA, 2018). Já, a Robótica se utiliza de ferramentas como os drones e os biossensores para o diagnóstico em tempo real e na observação georreferenciada. Outras funções desses dispositivos correspondem à detecção precoce do patógeno de pragas e doenças, exploração de culturas, monitoramento dos limites da fazenda, estruturas de irrigação e a vigilância do gado com os dispositivos integrados (BALAN, 2016; ROSE; CHILVERS, 2018).

O campo do Processamento de Linguagem Natural (NLP – *Natural Language Processing*) visa interpretar a entrada da linguagem natural humana. Isso permite que o sistema compreenda a entrada de fala do usuário, mesmo que as frases não sejam gramaticalmente corretas ou incompletas. Algo que permite, por exemplo, que o produtor se comunique por meio de um assistente virtual de conversação, possibilitando a comunicação contínua de usuário e máquina, como uma conversa entre humanos (VIJAYALAKSHMI; PANDIMEENA, 2019).

O campo do Planejamento e Programação refere-se à análise dos processos de erros e incertezas nos experimentos e podem surgir da seleção, condição e calibração do instrumento, ambiente, observação, leitura e idealização de testes para a gestão e previsão dos recursos (GÖTZ *et al.*, 2015; TOPUZ, 2010). Já, a otimização trata da precisão na previsão, nas variáveis de entrada em topologia da rede, no método de aprendizado, na função de não linearidade estabelecida, no número de camadas ocultas, no número de neurônios de cada camada e no número de épocas de treinamento (UNTARU; ROTARESCU; DORNEANU, 2012).

Os Sistemas Especialistas (ES - *Expert System*) é o campo da integração do conhecimento a relatórios e projetos de extensão tradicionais, objetivando fornecer conselhos gerais que auxiliem a gestão (MAHMOUD; M RAFEA; A RAFEA, 2008; VIJAYALAKSHMI; PANDIMEENA, 2019). O ES na forma prática proporciona aos produtores o acesso a um sistema de ensino sobre as informações agrícolas usando a técnica de consulta interativa. Também ajuda os agricultores a planejarem suas atividades futuras, prevendo o custo futuro dos produtos agrícolas por meio de dados históricos (MEHDIZADEH, 2018).

O campo da Fala ajuda os usuários com dificuldades de aprendizagem, a usar o sistema com eficiência. Os robôs de bate-papo normalmente fornecem uma interface ao usuário baseada em texto, permitindo que ao digitar comandos de texto, receba a resposta em formato texto ou fala (VIJAYALAKSHMI; PANDIMEENA, 2019). A saída textual gerada é passada pela Interfaces do Programa de Aplicativo (API - *Application Program Interfaces*) de síntese de fala. A API obtém entrada de texto e a converte em fala para fornecer som de saída a ser ouvida pelo interessado (EVANS; TERHORST; KANG, 2017). Esse sistema ajuda os agricultores a consultarem sobre a agricultura, obtêm a resposta em texto e fala de modo que o aprimoramento futuro pode ser feito e a saída é constituída na linguagem local (VIJAYALAKSHMI; PANDIMEENA, 2019).

Como visto na Figura 2.3, todos os campos explicados anteriormente se enquadram na classificação do eixo principal da IA, no entanto, para se desenvolver um modelo aplicável o subcampo principal deve ser identificado (VILLANUEVA; SALENGA, 2018). Assim, a aplicação da IA não se desenvolve diretamente pelos sete campos citados, mas por meio do uso de subgrupos, os métodos. A seguir, eles serão apresentados por meio da organização em três tópicos: redes neurais artificiais, aprendizagem supervisionada e métodos dinâmicos.

2.3.2 Redes Neurais Artificiais

Nas revisões, a ANN foi o método mais citado, muito em decorrência de sua facilidade de programação, assim como uma ferramenta eficaz para lidar com a complexidade dos dados agrícolas e dos dados qualitativos de alta variância afetados por ruído (UNTARU; ROTARESCU; DORNEANU, 2012). O uso de ANN no agronegócio tornou-se frequente desde meados da década de 1990 (HASHIMOTO *et al.*, 2001), abordando principalmente a previsão de produtividade, modelagem espacial (manejo de irrigação e índices de vegetação espectral) e previsão espaço-temporal (séries temporais do rendimento em um tempo específico), ver Figura 2.4.

Figura 2.4 – Propostas de aplicação de Redes Neurais Artificiais.

Autor	País do Estudo	Proposta de Aplicação	Modelo Aplicado	Resultados
Venkatesh e Thangaraj (2008)	Índia	Determinar os tipos de culturas adequadas para uma região, através do estudo das características do solo. Visando aumentar o rendimento e minimiza os gastos em irrigação e aplicação de fertilizantes.	Rede Neural com Alimentação Multicamada (MFNN)	A utilização de MFNN ajudou na obtenção de estimativas quase precisas das características do solo e a escolha de culturas planejadas para o cultivo com base nas necessidades de nutrientes do solo. Resultados experimentais mostraram que a aplicação superou o desempenho esperado.
Topuz <i>et al.</i> (2010)	Turquia	Prever as características de secagem de produtos agrícolas como avelã, feijão e grão de bico. Através da predição para a secagem em leito fluidizado de produtos agrícolas granulares.	ANN	As redes neurais artificiais conseguiram produzir previsões e resultados úteis para previsão das características de secagem. De modo que o modelo de ANN pode ser efetivamente utilizado como uma ferramenta de previsão.
Stastny <i>et al.</i> (2011)	República Tcheca	Analisar os níveis de produtividade das culturas, com ênfase no julgamento de precisão dos métodos individuais de implementação.	Perceptron Neural em Multicamadas (MLP)	Houve o uso de redes neurais multicamadas e os modelos de regressão de dados empíricos para a predição de produtividades e rendimento de culturas. A MLP provou ser preciso no caso de uma tarefa específica do que o modelo regressivo.
Sabri <i>et al.</i> (2012)	Taiwan	Utilizar a IA como sistema de controle autônomo de temperatura e a umidade em estufas durante o dia e noite. Assim como, contribuir para reduzir o consumo de energia.	Sistema de Inferência Fuzzy (FIS)	A utilização do sistema foi capaz de fornecer monitoramento em tempo real com dados autônomo de baixo custo, fácil de instalação e manutenção em tamanho reduzido e com pouca interferência dos funcionários.
Untaru <i>et al.</i> (2012)	Romênia	Contribuir com soluções práticas para otimizar um uso equilibrado de custo-benefício dos recursos naturais no agronegócio.	ANN	As experiências de redes neurais otimizadas para prever com precisão dos resultados financeiros de várias culturas. Há também resultados visando o melhoramento dos processos de tomada de decisão.
Boniecki <i>et al.</i> (2014)	Polônia	Definir as características representativas visuais encontradas em imagens de raios-X, digitais de grãos de trigo que apresentam traços de danos no núcleo interno causados pelo gorgulho do celeiro.	ANN	Uma análise da sensibilidade da rede neural (para inserir variáveis) ajudou a identificar características representativas para a identificação de núcleos danificados. Sendo uma tecnologia útil para a identificação dos efeitos adversos em sementes.
Bittar <i>et al.</i> (2018)	Brasil	Estimar os atributos físicos e químicos do solo. Com à análise descritiva, geostatística, treinamento e análise das ANN. Considerando a assertividade no mapeamento dos padrões.	ANN	O uso de ANN apresentou-se promissora para obter estimativas de atributos de solos. Uma vez treinadas, as ANNs adquiriram o conhecimento para estimar resultados das propriedades do solo, independentemente de sua vinculação espacial.
Mehdizadeh (2018)	Irã	Estimar a evapotranspiração de referência, objetivando a precisão dos modelos para prever a capacidade diária dos recursos hídricos e outras aplicações.	FIS	A estimação de dados meteorológicos e de evapotranspiração pode ser útil na previsão de dados e informações de locais de mesmo clima. Assim como, ser capaz de desenvolver cenários.
Rathod <i>et al.</i> (2018)	Índia	Analisar o comportamento passado e atual para prever a produção futura de oleaginosas, auxiliando na tomada de decisão e planejamento futuro de maneira eficaz e eficiente.	Rede Neural com Retardo de Tempo (TDNN)	A aplicação da TDNN tende a aumentar a precisão da previsão da produção de oleaginosas. Essa abordagem pode ser estendida usando técnicas de aprendizado de máquina em outras culturas.
Simone, Rivera e Guida (2018)	Itália	Usar sensores ultrassônicos de baixo custo junto com algoritmos de redes neurais para reconhecimento de objetos em veículos não tripulados durante a navegação autônoma.	ANN	Com o uso de redes neurais e sensores ultrassônicos foi possível a identificação de objetos ao longo do percurso. Através da técnica de adaptação em pequenas máquinas agrícolas autônomas.
Villanueva <i>et al.</i> (2018)	China	Determinar a capacidade de produção de melão amargo, através de imagens de folhas. Sendo classificadas como boas e ruins. A pesquisa utilizou como apoio o algoritmo de Aprendizado de Máquina.	ANN	O aumento do número de imagens pode permitir que uma máquina aprenda a diferença entre uma boa e uma má planta quando apresentada uma imagem para previsão. De modo que, ao aumentar o número de imagens, melhorou-se os resultados.
Deepa e Ganesan (2019)	Índia	Integrar as abordagens para desenvolver um modelo de classificação de várias classes que ajude os agricultores a tomar uma decisão sobre o cultivo de uma determinada terra agrícola.	FIS	A abordagem é usada para gerar regras de classificação para cinco culturas: arroz, amendoim, cana-de-açúcar, cumbu e ragi. O modelo desenvolvido foi testado com um conjunto de dados agrícolas que se mostrou confiável e robusto para o desenvolvimento da agricultura.
Vincent <i>et al.</i> (2019)	Índia	Propor um sistema multicamadas, integrando redes de sensores com sistemas de Inteligência Artificial para a avaliação da adequação das terras agrícolas.	MLP	Os resultados obtidos usando o sistema com quatro camadas ocultas são eficazes no sistema de classificação em classes de decisão, ou seja, mais adequadas, adequadas, moderadamente adequadas e inadequadas.

Fonte: Dados da Pesquisa (2020).

A ANN é derivada do caráter de modelo de rede, ou seja, sua capacidade de aproximação geral a um método com simplicidade em sua teoria, facilidade de programação e bons resultados (BITTAR; ALVES; MELO, 2018; BONIECKI *et al.*, 2014). Um passo importante para a construção do modelo de ANN é a seleção do tipo de rede (sua topologia), juntamente com a escolha de uma função de ativação ao algoritmo de aprendizado de máquina (SIMONE; RIVERA; GUIDA, 2018; TOPUZ, 2010). A seleção de rede adequada a ser desenvolvida passa pela necessidade do estudo, por exemplo, o fenômeno das séries temporais pode ser modelado matematicamente usando uma representação funcional implícita do tempo, as conhecidas como Rede Neural com Retardo de Tempo (TDNN - *Time Delay Neural Network*) (RATHOD *et al.*, 2018). Ou mesmo por meio da aplicação abrangente de neurônios da primeira camada que direcionam sua saída para os neurônios da segunda camada, de maneira unidirecional como as Redes Neurais com Alimentação Multicamada (MFNN - *Multilayer Feed-forward Neural Network*) (VENKATESH; THANGARAJ, 2008). Resultados do uso desses métodos podem ser observados por Vicente *et al.* (2019), ao afirmar que o método ajuda agricultores a avaliarem as terras agrícolas adequadas e inadequadas para cultivo de determinado produto.

No modelo *Perceptron* Neural de Múltiplas Camadas (MLP - *Multi-Layer Neural Perceptron*) é utilizada a configuração que segue um neurônio na entrada, dois na camada oculta e um na saída (1-2-1), junto com os não-função de ativação linear (STASTNY; KONECNY; TRENZ, 2011; VINCENT *et al.*, 2019). Esse sistema faz avaliação das terras agrícolas em termos de diferentes classes de decisão para o cultivo e também em futuras classificações pós-cultivo (VINCENT *et al.*, 2019). Já o Sistema de Inferência *Fuzzy* (FIS - *Fuzzy Inference System*) trata do comportamento dinâmico do sistema, sendo caracterizado por um conjunto de regras linguísticas difusas (MEHDIZADEH, 2018; SABRI *et al.*, 2012). Essas regras são elaboradas por um especialista humano com experiência na área do domínio por meio do agrupamento multiclases: cálculo de peso de variáveis, conversão de dados contínuos em valores difusos e geração de regras de classificação (DEEPA; GANESAN, 2019). O FIS permite, por exemplo, por meio do sensor de temperatura e umidade, o controle de alta precisão e baixo consumo de energia baseada no método de suspensão/ativação em um período de tempo predefinido.

2.3.3 Aprendizagem Supervisionada

Os algoritmos de aprendizagem supervisionada são uma combinação de técnicas de conjuntos de dados trabalhados e não trabalhados com monitoramento de resultados pressupostos (KUMAR; BHRAMARAMBA, 2017). Na Figura 2.5, são apresentados alguns desses algoritmos predominantemente encontrados ao longo dos trabalhos analisados. As ANNs também se enquadram nessa classificação, assim foram colocadas na tabela anterior pela relevância e quantidade de citações.

Figura 2.5 – Propostas de aplicação da aprendizagem supervisionada.

Autor	País do Estudo	Proposta de Aplicação	Modelo Aplicado	Resultados
Hashimoto <i>et al.</i> (2001)	Japão	Estimar a aplicação de abordagens inteligentes para problemas de otimização na agricultura. Com a discussão dos algoritmos derivados do bio-sistema, sistema de decisão e agricultura inteligente.	Algoritmo Genético (GA)	Há uma avaliação da pesquisa agrícola desenvolvida em três áreas: a) aplicações de Inteligência Artificial na agricultura; b) controle de ambiente inteligente para sistemas de produção de plantas; e c) robôs inteligentes na agricultura.
Perini e Susi (2004)	Itália	Desenvolver um sistema de apoio a decisão a ser usado por técnicos do serviço de consultoria que executam o gerenciamento de pragas de acordo com uma abordagem de produção integrada.	Aprendizado da Árvore de Decisão	A análise permitiu derivar os requisitos funcionais e não funcionais do sistema a partir dos objetivos do domínio de stakeholders e de suas dependências da dimensão organizacional/técnica.
Latorre-Biel <i>et al.</i> (2013)	Espanha	Propor uma metodologia para tomada de decisão, apoiada pela IA aplicada no campo agrícola, com análises de vantagens e desvantagens.	GA	Houve a otimização dos processos para decisões estruturais, definindo um bom design ou redesenho de vinícola, fornecendo estratégias de gerenciamento do negócio.
Götz <i>et al.</i> (2015)	Alemanha	Desenvolver uma ferramenta de planejamento para os agricultores avaliarem os componentes logísticos: motorista, carga, tipo de estrada, enrolamento, situação do tráfego, diurno etc.	Algoritmo de Vizinhos Mais Próximos	O algoritmo permite estimar os parâmetros-chave de energia e tempo para as tarefas de logística na agricultura. Os chamados fatores leves, têm uma enorme influência sobre os parâmetros-chave: energia e tempo.
Ogunde e Olanbo (2017)	Nigéria	Apresentar um sistema de apoio à decisão para analisar e extrair conhecimento de dados do solo com relação a sua adequação ao cultivo de mandioca.	Aprendizado da Árvore de Decisão	O sistema desenvolvido auxilia à tomada de decisão pelos agricultores pela determinação do rendimento potencial no uso da terra agrícola e na previsão da adequação do solo ao cultivo de mandioca.
Dornelles <i>et al.</i> (2018)	Brasil	Propor o uso de IA na simulação da produtividade de grãos de aveia (<i>Avena sativa</i>) e na otimização da densidade de semeadura nos principais sistemas de sucessão.	GA	O uso de GA permitiu simular com eficiência a produtividade de grãos de aveia e otimizar a densidade de semeadura em comparação com regressão polinomial.
Alzoubi <i>et al.</i> (2019)	Irã	Determinar um modelo linear na prevenção dos indicadores ambientais para o nivelamento da terra e estimação do grau de dependência de parâmetros: densidade, fator de compressibilidade do solo e índice de volume do aterro	Algoritmo Competitivo Imperialista (ICA)	Há uma superioridade do modelo em relação a outros métodos de prever problemas, como estimativa de energia no nível da terra. Tendo efeito no consumo de combustível e melhor desempenho na previsão de parâmetros de saída.
Feng (2019)	China	Construir um modelo de distribuição de terceiros através do cálculo logístico, custos e eficiência sob diferentes variáveis de produtos agrícolas de frutas e vegetais.	Algoritmo de Colônia de Formigas	Esse modelo reduziu os custos operacionais gerais e aumentaram a receita de logística. A entrada de ativos fixos, a ocupação de pessoal e o risco de gestão em áreas rurais foram reduzidos.
Xin <i>et al.</i> (2019)	China	Melhorar o nível intensivo do cultivo de hortaliças com a redução de desperdício de recursos de produção, semeadura de precisão, dosagem quantitativa de líquidos, reconhecimento de materiais e plantas daninhas com controle por aplicativo móvel.	Algoritmo de Propagação Reversa	O dispositivo foi utilizado como atuador inteligente da plantação, da unidade de aquisição de imagem, da unidade de controle elétrico e do terminal de controle de software. Através do acoplamento magnético dos atuadores conectados ao dispositivo.

Fonte: Dados da Pesquisa (2020).

O aprendizado supervisionado pode ser aplicado para configurar um procedimento de execução de previsões, a exemplo, classificação, regressão, regressão linear, regressão logística (RATHOD *et al.*, 2018). Essa modalidade representa a entrada da informação já preparada e sujeita ao algoritmo (VENKATESH; THANGARAJ, 2008). O algoritmo de propagação reversa trabalha com reconhecimento de padrões em uma rede avançada de alimentação em várias camadas, treinada de acordo com o algoritmo de propagação de erro de retorno (XIN *et al.*, 2019). O método apresentou desempenho efetivo na identificação e segmentação de plantas daninhas de modo preciso, apresentando também a capacidade de reduzir a taxa de falso reconhecimento. Os Algoritmos Genéticos (GA - *Genetic Algorithm*) têm sido utilizados no campo de controles, otimização e simulação como referência para comparação de resultados que possam ajudar no controle por aplicativos, ao mesmo tempo em que fornecem opções adicionais de técnicas de pesquisa por meio da linguagem de programação Java (HASHIMOTO *et al.*, 2001; LATORRE-BIEL *et al.*, 2013). Em um estudo desenvolvido por Dornelles *et al.* (2018) houve o uso dos GAs para a simulação com eficiência do rendimento de grãos de aveia e otimização da densidade de semeadura, nos sistemas de sucessão de milho/aveia e soja/aveia no sul do Brasil.

O Algoritmo Competitivo Imperialista (ICA - *Imperialist Competitive Algorithm*) é um método evolutivo utilizado na solução de problemas como agrupamento de dados, obtenção de ponto de equilíbrio de Nash, construções compostas, complicações na administração da produção e complicações de otimização (ALZOUBI; ALMALIKI; MIRZAEI, 2019). O ICA divide os dados iniciais em subgrupos de dados e, em seguida, procura o melhor ponto no espaço da solução, usando operadores principais: competição e assimilação. No campo agrícola, sua implementação pode ser feita em operações pesadas, como nivelamento da terra pela densidade, fator de compressibilidade do solo e índice de volume do aterro, algo que tende a ajudar na proteção do meio ambiente (ALZOUBI; ALMALIKI; MIRZAEI, 2019).

Outro método é o algoritmo de Vizinhos Mais Próximos (*Nearest Neighbors*), ele permite estimar uma variável dependente desconhecida com a ajuda de uma variável descritiva em um conjunto de dados de referência (GÖTZ *et al.*, 2015). Na prática, o algoritmo auxilia no cálculo de estimação de tempo e melhor percurso perante problemas logísticos complexos como o tipo de veículo, tipo de estrada, curvas, inclinação e desvios diários no fluxo do tráfico (FENG, 2019; GÖTZ *et al.*, 2015). Função também desenvolvida pelo Algoritmo de Colônia de Formigas, um método para calcular o caminho de distribuição

usando por base o modelo de colônia de formigas, visando alta pontualidade e robustez para fornecer transporte urgente (FENG, 2019). O algoritmo de colônia de formigas utiliza a combinação da teoria de rede dinâmica e a teoria de otimização discreta em um modelo de redes robustas, começando pela análise global e ajustando as regras para atualização local, aumentando a quantidade de informações de cada caminho (VILLANUEVA; SALENGA, 2018). Assim, tanto o Algoritmo de Vizinhos Mais Próximos como o Algoritmo Colônia de Formigas tendem a ser boas alternativas no processo de transação de comércio eletrônico rural. A otimização da rota pode melhorar a eficiência, reduzir os custos e diminuir o tempo de transporte.

O algoritmo de Aprendizagem da Árvore de Decisão funciona dividindo seus dados de treinamento em partes menores de forma contínua para que os padrões possam ser identificados na classificação dos dados (OGUNDE; OLANBO, 2017). Sendo o método mais adequado para casos de distinções categóricas hierárquicas (PERINI; SUSI, 2004), como a previsão da adequação do solo para o cultivo de determinada plantação. Ou mesmo, para estimar a evolução sazonal de doenças em plantas. Esses métodos normalmente resultam de experiências anteriores destinadas a aplicar as técnicas de IA à solução de problemas ambientais.

2.3.4 Métodos Dinâmicos

Os métodos dinâmicos são classificados por reunir métodos com características próximas em relação a sua capacidade. Por exemplo, estratégias baseadas em sistemas agrícolas virtuais e técnicas inspiradas em aprendizado de máquina extremo. Esses métodos fazem parte de uma família mais ampla de métodos de aprendizado de máquina baseados em representações de dados, em oposição a algoritmos específicos de tarefas – algoritmos supervisionados (GENG; DONG, 2017). Existem ainda, métodos que simplesmente se encaixam em várias categorias, como a máquina de vetores de suporte, que é uma estratégia impulsionada pelo sistema neural e uma técnica baseada em ocasiões (MORALES *et al.*, 2016), ver Figura 2.6.

Figura 2.6 – Propostas de aplicação de sistemas variados de IA.

Autor	País do Estudo	Proposta de Aplicação	Método Aplicado	Resultados
Xue-Lei e Gong-Hu (2000)	China	Estabelecer o sistema de planejamento e apoio à tomada decisões, exploração sustentável dos recursos, aumento do nível de gestão da modernização agrícola e manutenção do desenvolvimento regional sustentável	Sistema Dinâmico	Sistema pode ser usado para fazer monitoramento dinâmico, análise, avaliação e previsão de recursos e ambiente. Este sistema fornecerá um sistema viável de gerenciamento agrícola.
Mahmoud, M Rafea e A Rafea (2008)	Egito	Usar a tecnologia de sistemas especialistas para avaliar os impactos econômicos (o custo, o lucro e o rendimento) e ambientais (conservação da água e do solo e também na diminuição da quantidade de pesticidas utilizados nos campos).	Sistemas Especialistas (ES)	Os campos gerenciados pelo sistema usaram menos recursos em termos de fertilizantes e pesticidas. Assim como, uma menor quantidade média de água de irrigação foi necessária para produzir uma unidade da produção.
Morales et al. (2016)	Suécia	Analisar o treinamento e o teste de máquinas de vetores de suporte para uma detecção e alerta precoce de problemas relacionados a curva de produção de ovos comerciais visando evitar perdas econômicas.	Máquina de Vetores de Suporte (SVM)	Verificou-se que o modelo foi capaz de detectar como falsos positivos, alguns dias antes da ocorrência de um evento. Sendo útil para que se decida executar um diagnóstico preventivo ao identificar sintomas clínicos.
Ampatzidis, Bellis e Luvisi (2017)	Estados Unidos	Fornecer detalhes da nova geração de robôs que pode apoiar patologistas de plantas. E suas aplicações para o reconhecimento de plantas, localização, identificação e gerenciamento de doenças.	Tecnologias de Visão de Máquina	A especificidade do diagnóstico pode corresponder às ferramentas de diagnóstico convencionais para algumas doenças, mas não para todos os estágios do desenvolvimento da doença.
Geng e Dong (2017)	China	Investigar os fatores da agricultura automática moderna: (a) alocação de roteamento e o modo de transmissão de consumo de energia; (b) aplicação da Rede de Sensores Sem Fio no monitoramento contínuo da temperatura e umidade do solo.	Aprendizado Profundo	O experimento simulou as condições áridas, úmidas e outras condições do solo. Conseguindo identificar rapidamente o teor de umidade quando o solo estava seco e instruiu o sistema de irrigação a suplementar a água.
Kang e Wang (2017)	China	Apresentar as três etapas do manejo paralelo das plantas: descrição do crescimento, previsão e prescrição. Adicionando a capacidade de aprendizado e adaptação do banco de dados de conhecimento de acordo com o modelo descritivo e preditivo.	Sistema Agrícola Virtual	O sistema “humano em loop” adiciona a dimensão e o comportamento humano para influenciar o comportamento final do sistema. De modo que um usuário experiente, possa tomar uma decisão inteligente.
Kumar e Bhramaramba (2017)	Índia	Discutir as técnicas de aprendizado de máquina aplicadas a dados agrícolas, no intuito de realizar previsões para apoiar o processo de tomada de decisão e visualização de resultados mais precisos.	Estilo de Aprendizagem	A utilização do modelo demonstrou benefício para agricultores em termos de custo efetivo. Assim como, em sistemas baseados em sensores aplicados na agricultura de precisão.
Kouadio <i>et al.</i> (2018)	Vietnã	Utilizar o ELM para a previsão do rendimento do café em pequenas propriedades, particularmente com relação à seleção apropriada de propriedades do solo que podem ser usadas na previsão do rendimento de lavoura de café.	Aprendizado de Máquina Extremo (ELM)	O potencial do acoplamento de algoritmos de IA com modelos de culturas biofísicas em sistemas de apoio à decisão pode melhorar o rendimento em pequenas propriedades, sendo capaz de elucidar as incertezas e levar a previsões confiantes.
Vijayalakshmi e Pandimeena (2019)	Índia	Desenvolvimento de um <i>bot</i> de bate-papo com reconhecimento de voz inteligente, capaz de reconhecer frases não tão gramaticalmente definidas, ajudando a agricultores na obtenção as informações e adaptação às tecnologias.	Processamento de Linguagem Natural (NLP)	Esse sistema ajuda os agricultores a questionar sobre a agricultura, obter a resposta em texto e fala e também ajuda a prever os dados futuros do preço, para que eles possam planejar suas atividades.

Fonte: Dados da Pesquisa (2020).

As tecnologias de visão de máquina são aplicadas na agricultura para identificar e localizar plantas individuais, com uso prospectivo em contextos automatizados, como estufas inteligentes (AMPATZIDIS; BELLIS; LUVISI, 2017). Mas esse reconhecimento é considerado um dos problemas mais difíceis da robótica e da ciência da computação (GENG; DONG, 2017). Pois, em um ambiente como um jardim ou campo aberto, não há garantias de que um objeto tenha tamanho ou forma exatamente iguais, devido às condições de crescimento e fatores de interação entre plantas, organismos e ambiente (BONIECKI *et al.*, 2014). Mesmo assim, os sistemas de navegação por visão de máquina foram desenvolvidos

para orientar veículos autônomos em campos agrícolas, em que o "olho" de um robô é melhor que o humano e pode com isso, coletar uma grande quantidade de dados (AMPATZIDIS; BELLIS; LUVISI, 2017). Tecnologias de visão de máquina detêm funções similares a uma Rede de Sensores Sem Fio (WSN - *Wireless Sensor Network*), que realiza o monitoramento distribuído por meio de um grande número de nós de microssensores de baixo custo implantados em um determinado ambiente (GENG; DONG, 2017). Com a ajuda da comunicação sem fio, esses nós se coordenam para perceber o ambiente, adquirir informações, processar dados (aprendizado profundo) e enviam feedback ao controlador.

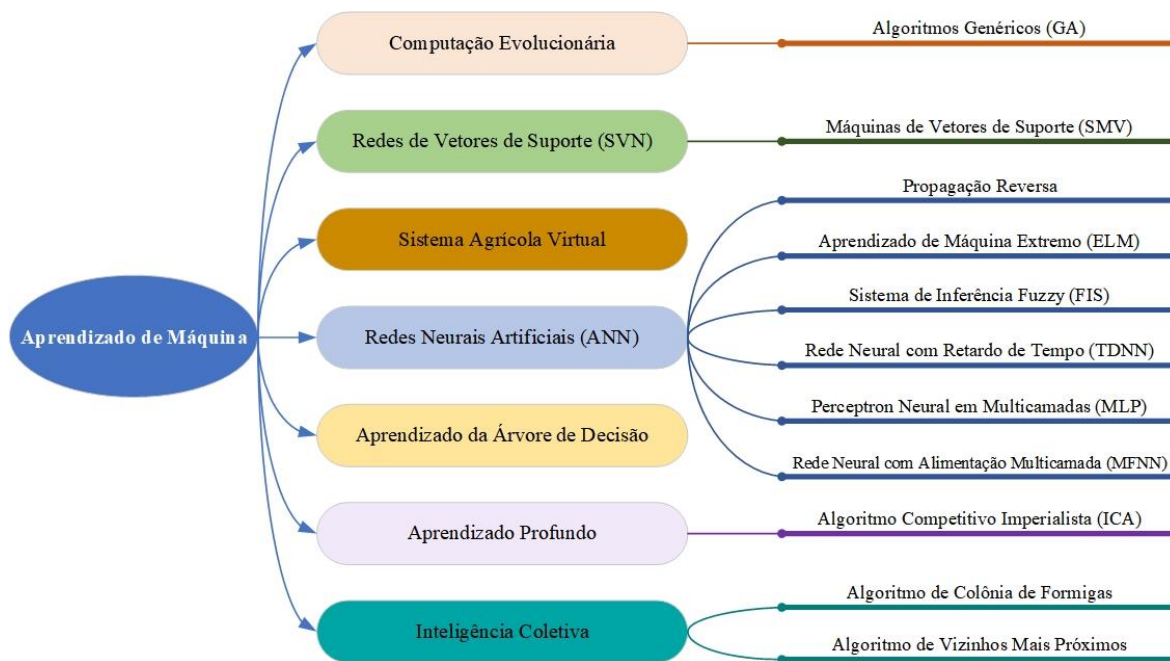
O Aprendizado Profundo (*Deep Learning*) é um dos novos direcionamentos para o aprendizado de máquina, com o objetivo de estabelecer uma rede neural que imita o mecanismo analítico do cérebro humano para figuras, imagens, áudios e textos (KUMAR; BHRAMARAMBA, 2017). Por outro lado, o aprendizado profundo não pode ser confundido com o Aprendizado de Máquina Extremo (ELM - *Extreme Learning Machine*), pois o aprendizado profundo é algo não controlado e o ELM emprega uma abordagem de estimativa de mínimos quadrados de solução fechada. Isso permite que o ELM resolva problemas de regressão em um tempo de execução relativamente curto e com maior precisão do que outros métodos de aprendizado, por exemplo, a ANN (KOUADIO *et al.*, 2018). No estudo de Kouadio *et al.* (2018) o ELM teve a função de analisar as propriedades de fertilidade do solo e gerar uma estimativa precisa da produção, buscando melhor rendimento de solo em pequenas propriedades.

Em se tratando de mineração de dados, as Máquinas de Vetores de Suporte (SVM - *Support Vector Machines*) são os métodos mais usados, pois possuem características próprias de classificação de conjuntos de dados em duas classes diferentes, separadas por um hiperplano apropriado (MORALES *et al.*, 2016; RATHOD *et al.*, 2018). As SVM são rotuladas e treinadas para construir um modelo que prediz a classe de uma nova amostra, diferente da original (DEEPA; GANESAN, 2019). Esse método pode ser aplicado, por exemplo, para uma detecção precoce de problemas na curva de produção de ovos comerciais, usando dados de produção de ovos das fazendas de galinhas poedeiras (MORALES *et al.*, 2016). As SVMs podem ainda ser usadas com apoio de outros métodos, por exemplo, os Estilos de Aprendizagem, ao trabalhar dados já disponíveis, com o intuito de fornecer escopo e flexibilidade aos resultados (KUMAR; BHRAMARAMBA, 2017).

Por sua vez, o Processamento de Linguagem Natural (NLP - *Natural Language Processing*), tem por objetivo facilitar a comunicação entre humano e máquina ao interpretar

a entrada da linguagem natural humana (VIJAYALAKSHMI; PANDIMEENA, 2019). Esse processo envolve a tokenização, remoção de ruído, normalização do léxico e modelo de caixa de palavras ou vetor de espaço (LATORRE-BIEL *et al.*, 2013). O NPL poderá responder às perguntas dos usuários sem qualquer assistência humana, mesmo que o interlocutor se expresse de forma gramaticalmente errada ou com uso de dialeto local. Portanto, cada método possui determinada função a depender da necessidade do usuário, sua aplicabilidade tende a auxiliar na construção de um sistema agrícola inteligente, capaz de acompanhar atividades como o processo de crescimento das plantas, incluindo fotossíntese, respiração, produção de biomassa, alocação, remobilização e condicionamento de frutos (KANG; WANG, 2017). A informatização do meio rural é uma evolução inevitável e a manipulação de grande quantidade de dados só será possível utilizando métodos e recursos computacionais (DORNELLES *et al.*, 2018; GÖTZ *et al.*, 2015). E a solução de problemas por meio da IA no uso de métodos torna-se mais atraente, criando a possibilidade de desempenho superior em comparação aos modelos convencionais validados. A Figura 2.7 apresenta as abordagens concentradas em torno dos métodos de aprendizado de máquinas encontrados na extração dos dados e seus métodos e suas ramificações.

Figura 2.7 – Métodos de Aprendizado de Máquina da extração de literatura.



Fonte: Dados da Pesquisa (2020).

A aplicação de métodos de IA passa pela captação de diferentes atores como Sistema Agrícola Virtual, SVM e ELM na detecção precoce do patógeno de pragas e doenças (Visão de Máquina), exploração de culturas (FIS e MLP), monitoramento dos limites da fazenda

(propagação reversa), estruturas de irrigação (ANN e MFNN) e a vigilância do rebanho com os dispositivos integrados no sistema de produção agrícola (árvore da decisão e TDNN). Os métodos podem ser bastante eficazes se integrados a um sistema de informação geral, constituído por funções que podem ser geridas pelo proprietário agrícola.

2.4 CONCLUSÕES

Ao aplicar os métodos da IA no meio agrícola, os sistemas das fazendas passam a oferecer recomendações e insights mais ricos para a tomada de decisão e melhoria das etapas da cadeia de suprimentos agrícola. Essa relação forma um registro automatizado de dados, análise, implementação e gestão agrícola baseada no conhecimento. Para esse escopo, espera-se que o uso dos métodos de IA seja ainda mais difundido, permitindo a integração dos métodos.

Avanços no aprendizado de máquina; robótica; visão computacional; processamento de linguagem natural; planejamento, programação e otimização; sistemas especialistas; e fala, permitem o desenvolvimento e a implementação de sistemas tecnológicos inteligentes no meio rural. Sendo capazes de fornecer rendimentos efetivos e eficientes da atividade, para atender à crescente demanda por alimentos - fator vital para a prosperidade econômica do setor agrícola e segurança alimentar geral.

Em se tratando do uso de tecnologias, as possibilidades são múltiplas. Por exemplo, ao simular a transferência de calor e umidade dentro de um sistema de secagem solar de arroz, fornece também, modelos integrados para produzir previsões bem-sucedidas de curvas de sobrevivência para microrganismos em alimentos (LATORRE-BIEL *et al.*, 2013). Ou até mesmo, monitorar o desenvolvimento animal como cria, recria, engorda, abate, comercialização, ao representar um sistema dinâmico com gerenciamento paralelo, obtido por experimento computacional e atividade em tempo real (MAHMOUD; M RAFEA; A RAFEA, 2008; XUE-LEI; GONG-HU, 2000).

Assim, o gerenciamento e tomada de decisão tornam-se mais precisos, otimizando a lucratividade, a produtividade e a sustentabilidade, por meio da compreensão do conjunto de dados. Para estudos posteriores, recomenda-se que a revisão possa ser desenvolvida para cada campo ou mesmo método em específico de IA. Isso pode gerar estudos sobre o uso da visão computacional ou Algoritmo Genético no meio agrícola, estudos esses, focados na terminologia.

Agradecimento

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

ALMEIDA, O. B. *et al.* Blockchain in Agriculture: A Systematic Literature Review. *In:* 2018, Cham. **Conferência Internacional sobre Tecnologias e Inovação**. Cham: CITI 2018, 2018. p. 44–56. Disponível em: <https://doi.org/10.1007/978-3-319-67283-0>

ALZOUBI, I.; ALMALIKI, S.; MIRZAEI, F. Prediction of environmental indicators in land leveling using artificial intelligence techniques. **Chemical and Biological Technologies in Agriculture**, Cham, v. 6, n. 1, p. 4, 2019. Disponível em: <https://doi.org/10.1186/s40538-019-0142-7>

AMPATZIDIS, Y.; BELLIS, L.; LUVISI, A. iPathology: Robotic applications and management of plants and plant diseases. **Sustainability (Switzerland)**, v. 9, n. 6, p. 1–14, 2017. Disponível em: <https://doi.org/10.3390/su9061010>

ANDRITOIU, D. *et al.* Agriculture autonomous monitoring and decisional mechatronic system. **Proceedings of the 2018 19th International Carpathian Control Conference, ICC 2018**, Szilvásvárad, p. 241–246, 2018. Disponível em: <https://doi.org/10.1109/CarpathianCC.2018.8399635>

ARISTODEMOU, L.; TIETZE, F. The state-of-the-art on Intellectual Property Analytics (IPA): A literature review on artificial intelligence, machine learning and deep learning methods for analysing intellectual property (IP) data. **World Patent Information**, v. 55, n. 2, p. 37–51, 2018. Disponível em: <https://doi.org/10.1016/j.wpi.2018.07.002>

BALAN, K. C. S. Robotic-Based Agriculture for Rural Renaissance: Drones and Biosensors. **Comprehensive Analytical Chemistry**, v. 74, p. 363–375, 2016. Disponível em: <https://doi.org/10.1016/bs.coac.2016.04.017>

BAYINDIR, L. A review of swarm robotics tasks. **Neurocomputing**, Oxford, v. 172, p. 292–321, 2016. Disponível em: <https://doi.org/10.1016/j.neucom.2015.05.116>

BENTHAM, M. J. Farm Smart 2000: A multi-agent decision support system for crop production. *In:* 1998, Hong Kong. **7th International Conference on Computers in Agriculture**. Hong Kong: 7, 1998. p. 469–479.

BITTAR, R. D.; ALVES, S. M. F.; MELO, F. R. Estimation of physical and chemical soil properties by artificial neural networks. **Revista Caatinga**, Mossoró, v. 31, n. 3, p. 704–712, 2018.

BONIECKI, P. *et al.* Detection of the granary weevil based on X-ray images of damaged wheat kernels. **Journal of Stored Products Research**, v. 56, p. 38–42, 2014. Disponível em: <https://doi.org/https://doi.org/10.1016/j.jspr.2013.11.001>

BRONSON, K.; KNEZEVIC, I. Big Data in food and agriculture. **Big Data & Society**, v.

3, n. 1, p. 2053951716648174, 2016.

CHIA, M. Y. *et al.* Recent Advances in Evapotranspiration Estimation Using Artificial Intelligence Approaches with a Focus on Hybridization Techniques—A Review.

Agronomy, New York, v. 10, n. 1, p. 101, 2020. Disponível em:

<https://doi.org/10.3390/agronomy10010101>

CHUKWU, N. C. E. Applications of artificial intelligence in agriculture: A review.

Engineering, Technology & Applied Science Research, v. 9, n. 4, p. 4377–4383, 2019.

CORTÉS, U. *et al.* Artificial intelligence and Environmental Decision Support Systems.

Applied Intelligence, Amsterdam, v. 13, n. 1, p. 77–91, 2000. Disponível em:

<https://doi.org/10.1023/A:1008331413864>

DEEPA, N.; GANESAN, K. Hybrid rough fuzzy soft classifier based multi-class

classification model for agriculture crop selection. **Soft Computing**, v. 23, n. 21, p.

10793–10809, 2019. Disponível em: <https://doi.org/10.1007/s00500-018-3633-8>

DONGRE, V. B.; GANDHI, R. S. Applications of artificial neural networks for enhanced livestock productivity: A review. **Indian Journal of Animal Sciences**, v. 86, n. 11, p.

1232–1237, 2016. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84998865619&partnerID=40&md5=363aef2063a6ea7d2f06f968acc40367>

DORNELLES, E. F. *et al.* Artificial intelligence in seeding density optimization and yield simulation for oat. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campo

Grande, v. 22, n. 3, p. 183–188, 2018. Disponível em: [https://doi.org/10.1590/1807-](https://doi.org/10.1590/1807-1929/agriambi.v22n3p183-188)

[1929/agriambi.v22n3p183-188](https://doi.org/10.1590/1807-1929/agriambi.v22n3p183-188)

EVANS, K. J.; TERHORST, A.; KANG, B. H. From Data to Decisions: Helping Crop Producers Build Their Actionable Knowledge. **Critical Reviews in Plant Sciences**,

London, v. 36, n. 2, p. 71–88, 2017. Disponível em:

<https://doi.org/10.1080/07352689.2017.1336047>

FENG, Z. Constructing rural e-commerce logistics model based on ant colony algorithm and artificial intelligence method. **Soft Computing**, v. 8, 2019. Disponível em:

<https://doi.org/10.1007/s00500-019-04046-8>

GENG, L.; DONG, T. An agricultural monitoring system based on wireless sensor and

depth learning algorithm. **International Journal of Online Engineering**, v. 13, n. 12, p.

127–137, 2017. Disponível em: <https://doi.org/10.3991/ijoe.v13i12.7885>

GÖTZ, S. *et al.* Simulation of agricultural logistic processes with k-nearest neighbors

algorithm. **Agricultural Engineering International: CIGR Journal**, v. 2015, p. 241–245, 2015.

GUBBI, J. *et al.* Internet of Things (IoT): A vision, architectural elements, and future

directions. **Future Generation Computer Systems**, Amsterdam, v. 29, n. 7, p. 1645–

1660, 2013. Disponível em: <https://doi.org/10.1016/j.future.2013.01.010>

HASHIMOTO, Y. *et al.* Intelligent systems for agriculture in Japan. **IEEE Control**

Systems Magazine, Washington DC, v. 21, n. 5, p. 71–85, 2001. Disponible em: <https://doi.org/10.1109/37.954520>

HUTSON, M. AI Glossary: Artificial intelligence, in so many words. **Science**, New York, v. 357, n. 6346, p. 19–19, 2017. Disponible em: <https://doi.org/10.1126/science.357.6346.19>

KAMBLE, S. S.; GUNASEKARAN, A.; GAWANKAR, S. A. Achieving sustainable performance in a data-driven agriculture supply chain: A review for research and applications. **International Journal of Production Economics**, Amsterdam, v. 219, p. 179–194, 2020. Disponible em: <https://doi.org/10.1016/j.ijpe.2019.05.022>

KANG, M.; WANG, F. Y. From parallel plants to smart plants: Intelligent control and management for plant growth. **IEEE/CAA Journal of Automatica Sinica**, v. 4, n. 2, p. 161–166, 2017. Disponible em: <https://doi.org/10.1109/JAS.2017.7510487>

KAPLAN, A.; HAENLEIN, M. Siri, Siri, in my hand: Who’s the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. **Business Horizons**, Amsterdam, v. 62, n. 1, p. 15–25, 2019. Disponible em: <https://doi.org/10.1016/j.bushor.2018.08.004>

KARGAR, A. H. B.; SHIRZADIFAR, A. M. Automatic weed detection system and smart herbicide sprayer robot for corn fields. *In*: 2013, Tehran. **2013 First RSI/ISM International Conference on Robotics and Mechatronics (ICRoM)**. Tehran: IEEE, 2013. p. 468–473. Disponible em: <https://doi.org/10.1109/ICRoM.2013.6510152>

KOUADIO, L. *et al.* Artificial intelligence approach for the prediction of Robusta coffee yield using soil fertility properties. **Computers and Electronics in Agriculture**, Amsterdam, v. 155, n. April, p. 324–338, 2018. Disponible em: <https://doi.org/10.1016/j.compag.2018.10.014>

KUMAR, A. V. S. P.; BHRAMARAMBA, R. Adapting mining into agriculture sector with machine learning techniques. **International Journal of Control and Automation**, Seoul, v. 10, n. 7, p. 13–22, 2017. Disponible em: <https://doi.org/10.14257/ijca.2017.10.7.02>

LATORRE-BIEL, J. I. *et al.* Decision support in the rioja wine production sector. **International Journal of Food Engineering**, Berlin, v. 9, n. 3, p. 267–278, 2013. Disponible em: <https://doi.org/10.1515/ijfe-2013-0032>

LEZOCHE, M. *et al.* Agri-food 4.0: A survey of the supply chains and technologies for the future agriculture. **COMPUTERS IN INDUSTRY**, RADARWEG 29, 1043 NX AMSTERDAM, NETHERLANDS, v. 117, 2020. Disponible em: <https://doi.org/10.1016/j.compind.2020.103187>

LI, D.; YANG, H. State-of-the-art Review for Internet of Things in Agriculture. **Nongye Jixie Xuebao/Transactions of the Chinese Society of Agricultural Machinery**, Pequim, v. 49, n. 1, p. 1–20, 2018. Disponible em: <https://doi.org/10.6041/j.issn.1000-1298.2018.01.001>

LIAKOS, K. G. *et al.* Machine Learning in Agriculture: A Review. **Sensors**, v. 18, n. M1, p. 1–29, 2018. Disponível em: <https://doi.org/10.3390/s18082674>

LIBERATI, A. *et al.* The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: explanation and elaboration. **PLoS medicine**, New York, v. 6, n. 7, 2009.

MAHMOUD, M.; M RAFEA, M.; A RAFEA, A. Using expert systems technology to increase agriculture production and water conservation. **3rd International Conference on Digital Information Management, ICDIM 2008**, p. 1–7, 2008. Disponível em: <https://doi.org/10.1109/ICDIM.2008.4746802>

MEHDIZADEH, S. Estimation of daily reference evapotranspiration (ET_o) using artificial intelligence methods: Offering a new approach for lagged ET_o data-based modeling. **Journal of Hydrology**, Amsterdam, v. 559, p. 794–812, 2018. Disponível em: <https://doi.org/10.1016/j.jhydrol.2018.02.060>

MORALES, I. R. *et al.* Early warning in egg production curves from commercial hens: A SVM approach. **Computers and Electronics in Agriculture**, v. 121, p. 169–179, 2016. Disponível em: <https://doi.org/10.1016/j.compag.2015.12.009>

NAVULUR, S.; SASTRY, A. S. C. S.; PRASAD, M. N. G. Agricultural management through wireless sensors and internet of things. **International Journal of Electrical and Computer Engineering**, Jacarta, v. 7, n. 6, p. 3492–3499, 2017. Disponível em: <https://doi.org/10.11591/ijece.v7i6.pp3492-3499>

OGUNDE, A. O.; OLANBO, A. R. A web-based decision support system for evaluating soil suitability for cassava cultivation. **Advances in Science, Technology and Engineering Systems**, v. 2, n. 1, p. 42–50, 2017. Disponível em: <https://doi.org/10.25046/aj020105>

PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. **Computers and Electronics in Agriculture**, Amsterdam, v. 153, n. April, p. 69–81, 2018. Disponível em: <https://doi.org/10.1016/j.compag.2018.08.001>

PERINI, A.; SUSI, A. Developing a decision support system for integrated production in agriculture. **Environmental Modelling and Software**, v. 19, n. 9, p. 821–829, 2004. Disponível em: <https://doi.org/10.1016/j.envsoft.2003.03.001>

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, 2018. Disponível em: <https://doi.org/https://doi.org/10.1016/j.inpa.2017.12.002>

RATHOD, S. *et al.* Modeling and forecasting of oilseed production of India through artificial intelligence techniques. **The Indian Journal of Agricultural Sciences**, Nova Delhi, v. 88, n. 1, p. 22–27, 2018.

ROOH, U. A.; LI, A.; ALI, M. M. Fuzzy, neural network and expert systems

methodologies and applications - A review. **Journal of Mobile Multimedia**, v. 11, n. 1-2, p. 157–176, 2015. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84926505137&partnerID=40&md5=aa4383f83e91ffdc18ae2b3e5ac4e79>

ROOPAELI, M.; RAD, P.; CHOO, K.-K. R. Cloud of Things in Smart Agriculture: Intelligent Irrigation Monitoring by Thermal Imaging. **IEEE Cloud Computing**, New York, v. 4, n. 1, p. 10–15, 2017. Disponível em: <https://doi.org/10.1109/mcc.2017.5>

ROSE, D. C.; CHILVERS, J. Agriculture 4.0: Broadening Responsible Innovation in an Era of Smart Farming. **Frontiers in Sustainable Food Systems**, v. 2, n. December, p. 1–7, 2018. Disponível em: <https://doi.org/10.3389/fsufs.2018.00087>

SABRI, N. *et al.* Smart prolong fuzzy wireless sensor-actor network for agricultural application. **Journal of Information Science and Engineering**, Taipé, v. 28, n. 2, p. 295–316, 2012.

SEEBACHER, S.; SCHÜRITZ, R. Blockchain Technology as an Enabler of Service Systems: A Structured Literature Review. *In*: 2017, Geneva. **International Conference on Exploring Services Science**. Geneva: 2017. p. 12–23. Disponível em: https://doi.org/10.1007/978-3-319-56925-3_2

SIMONE, M. C.; RIVERA, Z. B.; GUIDA, D. Obstacle avoidance system for unmanned ground vehicles by using ultrasonic sensors. **Machines**, v. 6, n. 2, 2018. Disponível em: <https://doi.org/10.3390/machines6020018>

STASTNY, J.; KONECNY, V.; TRENZ, O. Agricultural data prediction by means of neural network. **Agricultural Economics (Zemědělská ekonomika)**, Wiley, v. 57, n. No. 7, p. 356–361, 2011. Disponível em: <https://doi.org/10.17221/108/2011-AGRICECON>

TAN, Y.; ZHENG, Z. Research Advance in Swarm Robotics. **Defence Technology**, Pequim, v. 9, n. 1, p. 18–39, 2013. Disponível em: <https://doi.org/10.1016/j.dt.2013.03.001>

TOPUZ, A. Predicting moisture content of agricultural products using artificial neural networks. **Advances in Engineering Software**, London, v. 41, n. 3, p. 464–470, 2010. Disponível em: <https://doi.org/10.1016/j.advengsoft.2009.10.003>

UNTARU, M.; ROTARESCU, V.; DORNEANU, L. Artificial neural networks for sustainable agribusiness: A case study of five energetic crops. **Agrociencia**, Cidade do México, v. 46, n. 5, p. 507–518, 2012. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84869426625&partnerID=40&md5=af10af49e1e3bec1b9356a2f8e717543>

VENKATESH, E. T.; THANGARAJ, P. Self-organizing map and multi-layer perceptron neural network based data mining to envisage agriculture cultivation. **Journal of Computer Science**, Washington DC, v. 4, n. 6, p. 494–502, 2008. Disponível em: <https://doi.org/10.3844/jcssp.2008.494.502>

VIJAYALAKSHMI, J.; PANDIMEENA, K. Agriculture talkbot using AI. **International Journal of Recent Technology and Engineering**, v. 8, n. 2 Special Issue 5, p. 186–190,

2019. Disponível em: <https://doi.org/10.35940/ijrte.B1037.0782S519>

VILLANUEVA, M. B.; SALENGA, M. L. M. Bitter melon crop yield prediction using Machine Learning Algorithm. **International Journal of Advanced Computer Science and Applications**, Saga, v. 9, n. 3, p. 1–6, 2018. Disponível em: <https://doi.org/10.14569/IJACSA.2018.090301>

VINCENT, D. R. *et al.* Sensors driven ai-based agriculture recommendation model for assessing land suitability. **Sensors (Switzerland)**, v. 19, n. 17, 2019. Disponível em: <https://doi.org/10.3390/s19173667>

WOLFERT, S. *et al.* Big Data in Smart Farming – A review. **Agricultural Systems**, London, v. 153, p. 69–80, 2017. Disponível em: <https://doi.org/https://doi.org/10.1016/j.agsy.2017.01.023>

XIN, J. *et al.* Development of vegetable intelligent farming device based on mobile APP. **Cluster Computing**, v. 22, p. 8847–8857, 2019. Disponível em: <https://doi.org/10.1007/s10586-018-1979-4>

XUE-LEI, W.; GONG-HU, L. Study on decision support system of agricultural sustainable Development of Jianli county in Jiangnan plain. **Wuhan University Journal of Natural Sciences**, Pelotas, v. 5, n. 3, p. 334–338, 2000. Disponível em: <https://doi.org/10.1007/bf02830149>

3 CAPÍTULO II - DIFUSÃO DE TECNOLOGIAS NO MEIO AGRÍCOLA NA CAATINGA - REGIÃO DE CLIMA SEMIÁRIDO BRASILEIRA

Resumo

O uso de tecnologias influencia diretamente a produtividade no agronegócio, sendo determinante para uma produção economicamente viável em ambientes com condições climáticas adversas, como o semiárido brasileiro. Assim, este artigo faz a análise, por meio de uma revisão sistemática, das tecnologias usadas no meio agrícola na região de clima semiárido brasileira, o bioma Caatinga. Os resultados apresentam inicialmente as tecnologias de convivência com o semiárido ou técnicas sociais, com destaque para os métodos de manejo do solo, aproveitamento da água da chuva e preparo de ração animal. Já em relação às tecnologias propriamente ditas, as evidências convergem para a utilização tecnológica direcionada à viabilidade da produção, diversificação e tempo de colheita principalmente de culturas irrigadas. Outrossim, o melhoramento genético também contribuiu para a propagação de culturas resistentes e para o aumento da população de animais. Ao mesmo tempo que foi possível identificar o nível tecnológico da atividade agrícola na Caatinga, a qual, na maior parte do bioma, apresenta baixo uso de tecnologias caracterizado por atividades de subsistência, mão de obra familiar e monocultura, por outro lado, em polos locais agrícolas ocorre a utilização de sistemas integrados e agropecuária de base biológica.

Palavras-chave: Colheita perene. Agricultura de sequeiro. Fronteira de produção. Gestão do Conhecimento. Inteligência estratégica.

Abstract

The use of technologies directly influences productivity in agribusiness, being crucial for an economically viable production in environments with adverse climate conditions, such as the Brazilian semiarid region. Thus, this article analyzes, through a systematic review, the technologies used in the agricultural environment in the Brazilian semiarid climate region, the Caatinga biome. The results initially present technologies for coexistence with the semiarid region or social techniques, with emphasis on methods of soil management, use of rainwater and preparation of animal feed. In relation to the technologies themselves, the evidence converges to the technological use directed to the viability of production, diversification and harvest time, mainly for irrigated crops. Furthermore, genetic improvement also contributed to the propagation of resistant crops and to the increase in the population of animals. At the same time, it was possible to identify the technological level of agricultural activity in the Caatinga, which, in most of the biome, has low use of technologies characterized by subsistence activities, family labor and monoculture, on the other hand, in local centers agricultural systems use integrated and biologically-based agricultural systems.

Keywords: Perennial harvest. Rainfed agriculture. Production frontier. Knowledge management. Strategic intelligence.

3.1 INTRODUÇÃO

A agricultura irrigada na Caatinga tem contribuído para o fortalecimento socioeconômico por meio de práticas agrícolas diversificadas, impulso à agroindústria e exportação de produtos em larga escala (LACERDA *et al.*, 2021). Isso tornou-se possível a partir da implementação de modernos sistemas de transporte de águas do rio São Francisco ou de reservatórios até as propriedades rurais (PEREIRA; CARMO, 2014), bem como pelo uso de alta tecnologia paralelamente associada à entrada de empresas agrícolas, agroquímicas, agroindustriais, atacadistas e varejistas (OLIVEIRA; RODRIGUES, 2020). Fato este que transformou áreas ‘marginais’ em ‘vales’ ou regiões integradas de desenvolvimento agrícola, as principais responsáveis por produzir e exportar frutas no Brasil (CARNEIRO *et al.*, 2019; SILVA *et al.*, 2020b). Todavia, o setor agrícola mesmo na Caatinga não se comporta de forma homogênea, pois esse exemplo de maior nível tecnológico se aplica a áreas restritas, em que na maior parte do bioma os produtores têm que conviver com condições geográficas, institucionais e estruturais distintas (SILVA *et al.*, 2019).

No país, cerca de 50% dos estabelecimentos da agricultura familiar concentram-se no Nordeste, com ampla maioria situada na região de clima semiárido; o restante percentual corresponde a 19% no Sul, 16% no Sudeste, 10% no Norte e 5% no Centro-Oeste (MASSRUHÁ *et al.*, 2020). Os estabelecimentos da agricultura familiar no bioma produzem de forma convencional, pouco produtiva, sendo tipicamente praticada com baixo uso de insumos e composta por mais de uma atividade produtiva na mesma área, como a agricultura de subsistência e a pecuária extensiva (VILELA; CALLEGARO; FERNANDES, 2019). A agricultura tradicional adota o modelo migratório ou itinerante: desmatamento total, queimada da madeira, cultivo em períodos - em média, dois anos e repouso para a fertilidade do solo; nessas áreas também há o desenvolvimento de sistemas perenes - atividade sequeira através da plantação de fruteiras como umbuzeiro, cajueiro e outras (ARAÚJO FILHO, 2013). Em alguns locais férteis como vazantes, os plantios são feitos em barramentos com o aproveitamento de água por meio de barragens subterrâneas ou mesmo o uso de irrigação por pequenos ‘açudes’ e ‘barreiros’.

Na região Nordeste a pecuária concentra-se nos rebanhos de bovino, caprino e ovino os quais equivalem a aproximadamente 12%, 92% e 65% dos respectivos plantéis nacionais - a maior parte criada na região da Caatinga (IBGE, 2017), indicando a importância da

pecuária para os residentes rurais no bioma (ARAÚJO FILHO, 2013). A criação de animais se destina à produção de carne e leite contribuindo como fonte de renda para as famílias (SANTOS *et al.*, 2012). Na Caatinga, o rebanho médio é inferior à capacidade de carga da terra, onde cerca de 66% das propriedades possuem menos de 10 hectares e 30% estão abaixo de 100 hectares (HOFFMANN; NEY, 2010; MUIR *et al.*, 2019). Já na silvicultura, destaca-se a extração de madeira para produção de lenha - segunda fonte de energia mais utilizada da matriz energética, depois da energia elétrica, gerando dependência dos recursos florestais (ANDRADE *et al.*, 2019b; ARAÚJO FILHO, 2013; COELHO JUNIOR; MARTINS; CARVALHO, 2019); além da lenha e carvão, a vegetação lenhosa da Caatinga fornece também estacas para a confecção de cercas e varas para suporte às plantações (ARAÚJO FILHO, 2013; COELHO JUNIOR *et al.*, 2020). A vegetação nativa é resiliente frente às condições climáticas de semiaridez, fazendo parte da vida do homem do campo por meio das seguintes finalidades: frutíferas, medicinais, melíferas e para construção civil (BARACUHY; FURTADO; FRANCISCO, 2017).

O bioma Caatinga, é a região de sequeiro mais populosa do planeta, sendo extremamente vulnerável à degradação do solo em decorrência de fatores climatológicos e antrópicos adversos (SANTOS *et al.*, 2020a). Dentre esses fatores, a seca – período longo de deficiência hídrica - é o que mais afeta a sociedade por atuar em grandes extensões territoriais e por longos períodos impactando significativamente nos aspectos edáfico, meteorológicos e hídricos (ROCHA JÚNIOR *et al.*, 2020; SANTOS *et al.*, 2020b). Com a maior frequência e duração de eventos de seca na região, associados às mudanças climáticas e aumento de temperaturas, a tendência é limitar atividades como a própria agricultura de subsistência; comprometendo ainda mais as condições socioeconômicas, além de intensificar a degradação ambiental (SILVA *et al.*, 2020a; SILVA *et al.*, 2020e). Neste sentido, a caracterização de tecnologias no meio agrícola no bioma pode ajudar na busca por ferramentas de melhoramento e elaboração de projetos em vista ao maior desenvolvimento agrícola.

Diante do que foi exposto, o objetivo desta pesquisa é descrever as tecnologias atualmente utilizadas na atividade agrícola no bioma Caatinga. Com isso, analisar os sistemas de produção e as estratégias de manejo das culturas e dos rebanhos. Sendo este trabalho estruturado em três partes, além da introdução. Na primeira, são abordados os aspectos metodológicos da pesquisa com a descrição das etapas da revisão sistemática da literatura. Nela também será caracterizado o bioma Caatinga, lócus de investigação desta

pesquisa. Os desfechos da revisão com a descrição das técnicas sociais, tecnologias e discussões será destaque na segunda parte. Por último, na conclusão, são apresentadas as considerações finais e as perspectivas futuras para a atividade agrícola na Caatinga.

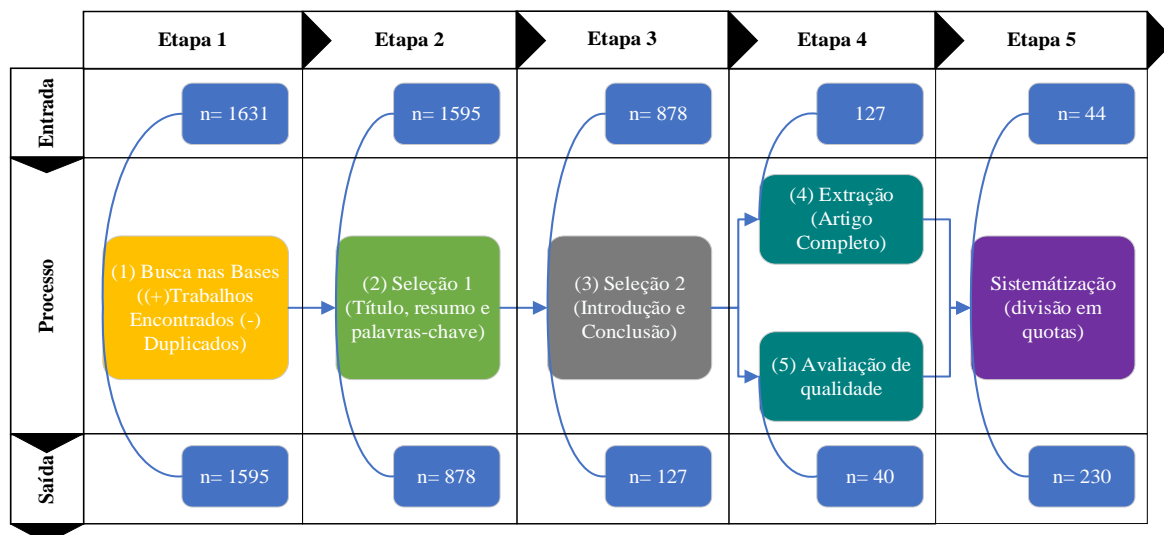
3.2 ASPECTOS METODOLÓGICOS

Este artigo corresponde a uma revisão sistemática da literatura feita a partir da busca de dados nas principais bases de dados bibliográficos: *Science Direct*, *Scopus*, *Springer Link* e *Web of Science*; sendo complementada com pesquisas nas bases direcionadas a tecnologias e pesquisa em geral: *ACM Explore*, *Google Scholar*, *IEEE Xplore* e *Scielo.org*. As bases de dados foram escolhidas em decorrência de sua ampla cobertura de literatura relevante ao tema proposto, e ainda por recursos bibliométricos avançados, como sugerir literatura relacionada ou citações. A busca foi realizada usando a combinação de caracteres em inglês: [(techn*) AND (agric*) AND ("semiarid northeastern Brazil" OR "semiarid north-eastern Brazil" OR "brazil semiarid" OR "brazil semi-arid" OR caatinga)]. A pesquisa correspondeu a todo o período de publicação encontrado até o ano de 2020 (1985-2020). Com critério de inclusão de ser artigo completo e de acesso livre em inglês e português, uma vez que inglês representa a língua com maior número de publicações nas bases, já o português por representar a língua local da temática. A questão norteadora dessa revisão sistemática foi: quais são as tecnologias utilizadas na atividade agrícola na região de clima semiárido brasileira, Caatinga: definições, caracterização e aplicação?

A partir da pergunta definida, a revisão sistemática foi desenvolvida em cinco etapas: (i) busca nas bases bibliográficas com a combinação dos caracteres, seleção total dos artigos em cada base e geração do arquivo *bibtex*, conseqüentemente importado para o software Start 3.3 para organização dos dados e identificação dos artigos duplicados; (ii) leitura do título e resumo com o intuito de selecionar os artigos que tinham alguma ligação à pergunta de pesquisa; (iii) leitura da introdução e conclusão - sendo selecionados os artigos que possuíam na introdução ou na conclusão indícios que respondessem à questão da revisão; (iv) leitura dos artigos completos para contemplar a seleção e extração dos artigos finais, logo após, foi realizada uma nova releitura dos artigos selecionados para contemplar a avaliação da qualidade dos artigos finais por meio da escala de Likert ((1) discordo totalmente, (2) discordo, (3) indiferente (ou neutro), (4) concordo e (5) concordo totalmente), com a escolha dos artigos agrupados na escalas (4) e (5); e (v) sistematização com a escolha

das quotas – frases ou parágrafos destaques dentro dos artigos ligadas à pergunta pesquisa. Ver Figura 3.1, acerca das etapas de sistematização da revisão.

Figura 3.1 – Processos da Revisão Sistemática.



Fonte: Dados da Pesquisa (2021).

Esta revisão seguiu o protocolo de Principais Itens para Relatar Revisões Sistemáticas e Meta-análises - PRISMA (2009), por ser uma estrutura metodológica bastante utilizada nesse tipo de pesquisa e que permite o desenvolvimento das etapas de forma clara e que possibilita replicações. O desenvolvimento da pesquisa ocorreu no período de janeiro a maio de 2021, sendo apoiadas pelos softwares: StArt (3.3 Beta 03) para a organização dos dados e seleção dos artigos; e Mendeley (1.19.4) para a gestão bibliográfica.

A seguir é apresentado a Figura 3.2, sobre dados gerais da revisão sistemática. Nela é possível visualizar o gráfico sobre das publicações de forma anual, com destaque para o crescente aumento dos estudos a partir do ano de 2010. Em relação aos locais dos estudos o estado da Bahia possui a maior quantidade de trabalho selecionados, cabendo destacar que alguns estudos tinham como foco toda a região semiárida. Já nas atividades desenvolvidas e as culturas analisadas, os resultados direcionam para a predominância da agricultura em relação a pecuária.

Figura 3.2 – Dados anuais, localização, culturas estudadas e atividades predominantes.



Continua

(FOLHES; RENNÓ; SOARES, 2009)	(SANTOS <i>et al.</i> , 2017)	
(FREITAS <i>et al.</i> , 2019)	(SANTOS; MOREIRA; RODRIGUES, 2013)	

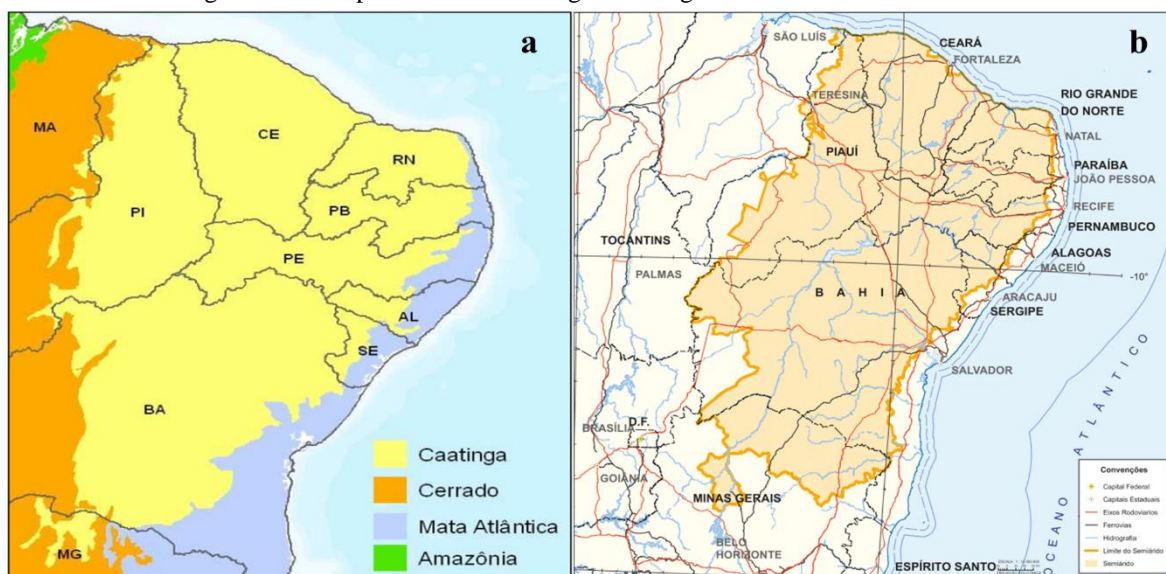
*Alguns estudos não tratam de uma cidade específica, mas das áreas semiáridas de cada estado em particular, da combinação de mais de um estado ou de toda a região da Caatinga.

Fonte: Dados da pesquisa (2021).

O local de estudo corresponde à toda região de clima semiárido brasileira, o bioma Caatinga. Cabe destacar que no Brasil o termo semiárido remete tanto ao clima como à região geográfica, em que o termo ‘Clima Semiárido’ é utilizado para delimitar áreas onde a precipitação pluviométrica é menor que a quantidade de água que evapora – essa área corresponde à região do bioma Caatinga (MOURA *et al.*, 2007); já a região denominada Semiárido Brasileiro (SAB), configura-se como uma delimitação político-geográfica da Superintendência de Desenvolvimento do Nordeste (SUDENE) para o desenvolvimento de políticas públicas específicas, ao limitar uma área com condições climáticas dominantes de semiaridez devido precipitação média inferior a 800 mm por ano, índice de aridez inferior a 0,5 e risco de seca superior a 60% (SUDENE, 2017).

A SAB possui clima semiárido e tropical, com locais pertencentes aos biomas: Caatinga, Cerrado e Mata Atlântica; enquanto que a região de clima semiárido concentra unicamente as áreas do bioma Caatinga (SANTOS *et al.*, 2013), ver Figura 3.3. Assim, este estudo busca discorrer sobre a região de clima semiárido por ser uma classificação que leva em consideração uma delimitação geográfica de clima e fatores mais homogêneos que a SAB. A escolha do local da pesquisa se deu em decorrência do baixo número de estudos sobre a região semiárida mais populosa do mundo, ao passo que também representa a região mais pobre do Brasil no Índice de Desenvolvimento Humano (IDH) (FERREIRA *et al.*, 2020; SILVA *et al.*, 2019). Também, adiciona-se as tendências demográficas de migração de jovens para as cidades e o envelhecimento da população rural (LINDOSO *et al.*, 2018); e as tendências climáticas que afetam o fluxo dos rios, o armazenamento de água e a produção irrigada no bioma (BURNEY *et al.*, 2014).

Figura 3.3 – Mapa do Bioma Caatinga e da Região do Semiárido Brasileiro.



Nota: (a) Mapa do bioma Caatinga e suas delimitações com os demais biomas; (b) Mapa da Região Semiárida Brasileira sobreposto aos dez estados brasileiros. Essa delimitação foi criada em 2007 e atualizada em 2017 para substituir a antiga região do polígono das secas.

Fonte: IBGE (2004; 2017).

A Caatinga é uma região ecológica que se encontra no interior do SAB com área total de 844.453 km² (MMA, 2019). O termo 'Caatinga' significa 'Floresta Branca', fenômeno este caracterizado por árvores sem folhas durante a maior parte do ano - estação seca (PRADO, 2003). Essa região equivale a aproximadamente 10% do território nacional, com áreas correspondentes a 100% do Ceará (CE); 95% do Rio Grande do Norte (RN); 92% da Paraíba (PB); 83% do Pernambuco (PE); 63% do Piauí (PI); 54% da Bahia (BA); 49% do Sergipe (SE); 48% de Alagoas (AL); 2% de Minas Gerais (MG); e 1% do Maranhão (MA) (IBGE, 2004).

Cerca de vinte e sete milhões de pessoas residem na área da Caatinga (MMA, 2019). Essa população vive em 1210 municípios, incluindo duas capitais estaduais – Fortaleza (CE) e Natal (RN) (IBGE, 2004). A densidade populacional é pouco homogênea em toda a região, com altas densidades encontradas ao longo das fronteiras orientais e ao longo da costa. Em contraste, os municípios com baixa densidade populacional são encontrados principalmente ao longo das fronteiras ocidentais na transição para o Cerrado. A maior parte dos recursos hídricos provém do rio São Francisco, cujas águas abastecem vários municípios que as utilizam para consumo humano, geração de energia e atividade agrícola (FERREIRA *et al.*, 2020). Fato este que lhe confere um potencial para o desenvolvimento da agricultura irrigada em alguns locais como a Região Integrada de Desenvolvimento Econômico do Polo Petrolina e Juazeiro (RIDE) (SANTOS *et al.*, 2017). Há outros rios na região, alguns perenes, mas com baixa carga hídrica, já outros são temporários e desaparecem no período de

estiagem. Condição essa causada pela variação pluviométrica na região: 68,8% da área recebe entre 600 e 1000 mm/anuais; 22,5% recebe menos de 600 mm/anuais; e apenas 8,7% recebe mais de 1000 mm/anuais concentrados em um período de 90 dias no ano (ANDRADE *et al.*, 2017).

Contrastando com as precipitações baixas e irregulares, a evapotranspiração potencial é alta, entre 1500 e 2000 mm ao ano (VELLOSO; SAMPAIO; PAREYN, 2001). O tipo de vegetação dominante na região é uma Floresta Tropical Sazonalmente Seca (SDTF - *Seasonally Dry Tropical Forest*) (PENNINGTON; LAVIN; OLIVEIRA-FILHO, 2009). Contextualizado o local de estudo, a seção a seguir traz um panorama do uso de técnicas e tecnologias no meio agrícola na Caatinga em vistas de contemplar os resultados desta pesquisa.

3.3 RESULTADOS

O setor agrícola dentro do bioma Caatinga apresenta condições distintas de desenvolvimento; afetadas por fatores geográficos, culturais, históricos, institucionais, estruturais e tecnológicos (SILVA *et al.*, 2019; SILVA *et al.*, 2020b). As técnicas sociais são citadas em grande parte dos artigos como tecnologias adaptativas sendo praticadas em diferentes locais do bioma. A recorrência de tais técnicas suscitou um tópico específico neste estudo e que não podem ser ignoradas em trabalhos que tratam de tecnologia na Caatinga. Assim, a apresentação dos resultados a seguir adotará a divisão entre técnicas sociais e as tecnologias propriamente ditas.

3.3.1 Técnicas sociais

Na maior parte do bioma a atividade agrícola se baseia na agricultura familiar de subsistência; correspondendo a uma atividade de baixa produtividade em que as tecnologias sociais ou de convívio com o semiárido têm sido importantes na produção agropecuária; visando minorar as lacunas na produtividade agrícola – déficit hídrico e manejo da cultura em pequenas e médias propriedades (BURNEY *et al.*, 2014; JESUS *et al.*, 2020; MAIA *et al.*, 2018). Na Caatinga, a água é um recurso estratégico fundamental para o desenvolvimento da atividade agrícola (FOLHES; RENNÓ; SOARES, 2009; SANTOS *et al.*, 2020b) e a produção de subsistência passa pela gestão de reservatórios superficiais

escavados em bacias de pequenos rios e córregos, captando e armazenando o escoamento superficial em barragens abertas como os açudes, as vagens agrícolas e os barreiros; outras estruturas correspondem aos tanques de pedra, barragens de trincheira e barragens de irrigação suplementar (LINDOSO et al., 2018).

O uso de estoques subterrâneos é limitado, sendo tradicionalmente explorados por meio da construção de corpos d'água na forma de poços rasos escavados no leito seco dos rios e riachos, as 'cacimbas' e os 'cacimbões' (LINDOSO *et al.*, 2018). Como a água subterrânea não é um recurso totalmente renovável e a taxa de retirada supera a taxa de recarga em alguns locais no semiárido, a escassez desse recurso tem aumentado ao passo que as áreas adequadas para a irrigação de plantações têm se tornado raras (MAIA et al., 2018; SILVA *et al.*, 2020a).

Em alguns locais, a água obtida nos poços subterrâneos é salobra e geralmente não potável – oitenta por cento do território no semiárido brasileiro corresponde a formações geológicas com xisto, marga, calcário, silvita, gesso e halita com grande quantidade de sais de cálcio e magnésio que deixam a água subterrânea salobra (PESSOA *et al.*, 2016; SILVA; SHARQAWY, 2020). Mesmo assim, é comum o uso de água com teor moderado a alto de sal na irrigação das lavouras e hidratação de animais, uma ação paliativa à escassez de água, mas que afeta a produção, degrada os solos ao longo dos anos de cultivo e influencia negativamente a sustentabilidade agrícola na região (COSTA; MEDEIROS, 2018; DINIZ *et al.*, 2020; PESSOA *et al.*, 2016; SILVA *et al.*, 2020d). Cabe destacar também que a irrigação não é uma prática viável para a maioria dos pequenos agricultores devido aos custos dos sistemas de irrigação (VISSÉS; SENTELHAS; PEREIRA, 2018).

Da mesma forma, a dessalinização da água é uma técnica alternativa com alto potencial para subsidiar cultivos irrigados e promover o uso sustentável da água subterrânea salobra disponível (CAVALCANTE JÚNIOR *et al.*, 2019). No entanto, devido aos altos custos de implantação e gestão dos sistemas de dessalinização, sua implementação depende do poder público, o qual, por meio do Programa Água Doce do Governo Federal instalou cerca de 575 sistemas; a maior parte concentrada nos estados do CE e BA, por possuir uma elevada estrutura de eletrificação rural nesses estados (SILVA; SHARQAWY, 2020). A dessalinização nesses sistemas é feita por osmose reversa, no qual bombas de alta pressão forçam a água através das membranas semipermeáveis seletivas que atuam como barreiras físicas separando os sais dissolvidos e outras impurezas da água (CAVALCANTE JÚNIOR *et al.*, 2019). Essa técnica também demanda um elevado consumo de energia durante a

operação, tornando-se uma prática inviável para a maioria dos pequenos agricultores (SILVA; SHARQAWY, 2020).

A cisterna de produção, tanques de concreto cobertos e abastecidos por água recolhida do pátio de concreto do lado, é uma alternativa utilizada pela agricultura familiar para a irrigação de pequenas hortas ao redor da casa que fornecem alimento para as famílias e geração de renda em caso de excedentes de produção (LINDOSO *et al.*, 2018). Outra técnica que se insere nesse contexto é a barragem subterrânea, uma obra hidro ambiental submersível com objetivo de acumular e armazenar água da chuva em diferentes zonas do solo para o abastecimento humano (familiar e comunitário), animal e produção agrícola - aproveitamento do espelho de água em forma de vazantes para a produção em pequenas quantidades de culturas como macaxeira, batata e feijão (LIMA *et al.*, 2013). Ter um corpo de água na propriedade representa também o incremento na produção agrícola e pecuária em mais de quinze por cento nas pequenas propriedades (MAIA *et al.*, 2018).

O uso de fertilizantes químicos na agricultura familiar do semiárido é ínfimo, devido à variabilidade das chuvas, à disponibilidade de recursos financeiros e à rentabilidade das atividades agrícolas (JESUS *et al.*, 2020). Em locais com problemas físicos do solo são utilizados os fertilizantes orgânicos ou verdes como o esterco bovino, embora paliativo, essa prática propicia a reciclagem de nutrientes e a melhora da estrutura física do solo com o aumento de carbono, nitrogênio e outros nutrientes em plantações de feijão, milho, fava e mandioca (BARRETO *et al.*, 2010; CARNEIRO *et al.*, 2019; JESUS *et al.*, 2020; VISSÉS; SENTELHAS; PEREIRA, 2018). Outra alternativa é a rotação de culturas, a qual utiliza o revezamento de culturas para promover a cobertura do solo e melhorar os atributos físicos, químicos e biológicos, bem como agir na supressão de pragas, doenças e infestação de plantas daninhas (BARRETO *et al.*, 2010; VISSÉS; SENTELHAS; PEREIRA, 2018).

O desenvolvimento de ações adaptadas ao semiárido tem se tornado um aliado importante para o manejo do solo, aproveitamento da água da chuva e cultivo de culturas (MAIA *et al.*, 2018), em que a resiliência das safras à seca depende das práticas de manejo adaptadas, influenciando diretamente na produtividade das culturas e tornando a produção economicamente viável (FREITAS *et al.*, 2019).

O manejo agroecológico é uma dessas práticas que tem incitado adeptos na Caatinga ao valorizar a biodiversidade, diminuir o uso de insumos materiais e elevar a capacidade produtiva da terra (BARRETO *et al.*, 2010). O manejo agroecológico é impulsionado por programas de extensão de instituições de ensino e envolve a formação dos sistemas

agroflorestais: silviagrícola – caracteriza-se pela combinação de árvores ou arbustos com espécies agrícolas; silvipastoril - combina árvores ou arbustos com plantas forrageiras herbáceas e animais; e agrissilvipastoril – combina árvores com pastagem, animais e lavoura agrícola no mesmo ambiente (BARRETO *et al.*, 2010; COSTA; ARRUDA; OLIVEIRA, 2002). O manejo agroecológico tem resultado numa diminuição das queimadas no bioma, consequentemente está havendo uma recuperação da cobertura vegetal e uma diminuição no ritmo de desertificação na Caatinga (SILVA *et al.*, 2020a).

Na pecuária, a atividade predominante é a de corte, com número médio inferior a oito cabeças (cabeças/família), para agricultores familiares e quarenta cabeças para propriedades não familiares, mas também há destaque para os rebanhos caprinos e ovinos, tradicionais no semiárido – média de três cabeças na agricultura familiar e cinco para não familiar (MAIA *et al.*, 2018). Em relação à pecuária leiteira, base econômica dos pequenos e médios produtores no semiárido baiano e mineiro, a produtividade é afetada pela oferta irregular de alimentos ao longo do ano, paralelamente afetada pelo uso de cruzamentos não adaptados ao clima ou com baixo potencial de produção – animais mestiços oriundos por exemplo de raças: holandês x zebu (CARVALHO *et al.*, 2019; VASCONCELOS *et al.*, 2018). Estas características fazem o setor agropecuário no bioma um empreendimento cercado de riscos e com acesso limitado aos mercados (SILVA *et al.*, 2019).

Os índices de produção e qualidade do leite produzido no bioma são bem inferiores aos apresentados em locais referências na produção de leite (SILVA *et al.*, 2020e). Isso, muitas vezes causado pelo precário acesso a tecnologias e assistência técnica (VASCONCELOS *et al.*, 2018). A ordenha mecânica é um equipamento pouco comum, com o predomínio da ordenha manual (MAIA *et al.*, 2018). Assim como o uso de inseminação artificial também é pouco observado nas fazendas, utilizando o serviço natural de vaca/touro para a reprodução animal (VASCONCELOS *et al.*, 2018). Por outro lado, o cooperativismo/associativismo tem tido um substancial papel na pecuária leiteira ao integrarem os produtores entre si e com o mercado consumidor, facilitando a comercialização e ajudando algumas vezes na infraestrutura tecnológica necessária para produção de derivados do leite (MAIA *et al.*, 2018).

Os recorrentes períodos de secas têm resultado na diversificação da base agropecuária com foco em pequenos ruminantes, pois os agricultores tendem a se desfazer dos animais maiores em função da diminuição de ração (MAIA *et al.*, 2018). Algo que tem se revelado uma ação estratégica, pois, em zonas como a da Caatinga o gado é criado por

uma questão de prestígio, sendo as espécies de caprinos e ovinos mais resilientes ao clima (ANDRIEU; NOGUEIRA, 2010; FARIAS *et al.*, 2014; MAIA *et al.*, 2018). A pastagem nativa é o principal alimento dos rebanhos no semiárido com a exploração via sistema extensivo (BARRETO *et al.*, 2010).

A complementação da alimentação dos rebanhos se dá por meio do cultivo de pastagens como palma forrageira, gramíneas e sobras das plantações, os dois últimos quando em excedentes são transformados em forragens e armazenados em silos naturais para serem usados no período seco (FERNANDES *et al.*, 2020). Há por parte de produtores com maior quantidade de animais a compra de rações enriquecidas com proteínas, como farelo de soja e milho, na perspectiva de aumentar a produtividade do leite ou engorda do gado de corte; mas esses produtores acabam por fornecer aos animais quantidades calculadas incorretamente, principalmente por falta de informação/assistência técnica (BURNEY *et al.*, 2014; CARVALHO *et al.*, 2019).

O acesso à assistência técnica se dá, na maioria das vezes, por meio das empresas de Assistência Técnica e de Extensão Rural (ATER) estaduais, pelas universidades, pelos institutos federais, por organizações não-governamentais e pelos bancos públicos (ANDRIEU; NOGUEIRA, 2010; MAIA *et al.*, 2018). Essa assistência tem tido um alcance limitado junto ao baixo nível de capacitação técnica do pequeno produtor, contribuindo para a perpetuação de práticas não sustentáveis na atividade agrícola (ANDRIEU; NOGUEIRA, 2010).

Os pequenos produtores carecem de uma maior intervenção técnica, a fim de melhorar a produtividade da cultura ou mesmo auxílio com a alimentação animal balanceada, sob a ótica da convivência no semiárido (BURNEY *et al.*, 2014; MAIA *et al.*, 2018). Desse modo, o enfoque em tecnologias sociais tem o potencial de fomentar a convivência com o semiárido em uma perspectiva multidimensional, sustentável e tecnológica, ao mesmo tempo que enfrente questões atuais e tendências futuras como a migração de jovens para as cidades e o envelhecimento da população rural (LINDOSO *et al.*, 2018).

3.3.2 Tecnologias

O desenvolvimento do agronegócio brasileiro trouxe significativas transformações e avanços na estrutura produtiva e tecnológica, promovendo um processo de inovação em

parte do país (OLIVEIRA; RODRIGUES, 2020; SANTOS *et al.*, 2017). A exemplo das novas áreas de expansão agrícola que vêm se constituindo nos últimos 15 anos, em partes dos estados do Maranhão, Tocantins, Piauí e Bahia (MATOPIBA), região essa localizada ao longo do cerrado nordestino e em todo o estado tocaninense (SILVA *et al.*, 2019). Essas áreas tornaram-se rentáveis na produção extensiva/mecanizada de grãos - milho, soja, algodão e sorgo, mesmo sob condições naturais adversas (SANTOS *et al.*, 2017). Algo que se correlaciona com a “entrada de empresas agrícolas, agroindustriais, tecnológicas, agroquímicas, atacadistas, varejistas e financeiras em áreas anteriormente desconectadas da dinâmica agrícola nacional” (OLIVEIRA; RODRIGUES, 2020, p. 526).

A Região Integrada de Desenvolvimento (RIDE) do vale do São Francisco é uma representação dessa dinâmica, a qual sedimentou-se numa rede de produção onde as cidades passam a apoiar as atividades do meio agrícola (CARNEIRO *et al.*, 2019; FERREIRA *et al.*, 2020). A RIDE contribuiu para a formação e formulação de estratégias competitivas diferenciadas de inovação na cadeia de produção da fruticultura irrigada nas cidades de Casa Nova (BA), Curaçá (BA), Juazeiro (BA), Lagoa Grande (PE), Orocó (PE), Petrolina (PE), Santa Maria da Boa Vista (PE) e Sobradinho (BA) (SANTOS *et al.*, 2017). Os aglomerados do vale do São Francisco emergiram como o mais importante polo frutícola brasileiro - uva, manga, banana, melão, melancia e goiaba, sendo por exemplo, a maior produtora de manga ao representar mais de oitenta por cento do total da fruta exportado pelo Brasil (CARNEIRO *et al.*, 2019; SILVA *et al.*, 2020b).

Contudo, a viabilização do cultivo em larga escala dessas culturas na RIDE foi fundamentado pela implementação de modernos sistemas de transporte de águas do rio São Francisco até as áreas dos pomares e das lavouras (COTRIM *et al.*, 2011; OLIVEIRA; RODRIGUES, 2020). Já no Vale do Açu, outra importante área fruticultora do nordeste, foi implementada após a construção da barragem no Rio Piranhas-Assu entre os municípios de Assu, Itajá e São Rafael no Rio Grande do Norte (RN), conseqüentemente o transporte de águas aos pomares de frutas tropicais (OLIVEIRA; RODRIGUES, 2020; SILVA *et al.*, 2019). Algo semelhante aconteceu também com a construção do Açude Castanhão na microrregião do Baixo Jaguaribe, referência cearense na produção de frutas (FOLHES; RENNÓ; SOARES, 2009).

Como já foi dito, na Caatinga a água é um recurso estratégico fundamental também para o desenvolvimento da atividade agrícola em larga escala (FOLHES; RENNÓ; SOARES, 2009; SANTOS *et al.*, 2020b). E a gestão eficiente passa pelas perspectivas do

uso racional dos recursos hídricos para garantir o melhor rendimento com o mínimo volume de água (CARNEIRO *et al.*, 2019; SANTOS; MOREIRA; RODRIGUES, 2013), pois, o excesso de bombeamento de água tem reduzido o ganho econômico dos produtores, por exemplo com o aumento dos custos de energia elétrica para bombear água do reservatório (COTRIM *et al.*, 2011; FOLHES; RENNÓ; SOARES, 2009).

No bioma, o desenvolvimento de técnicas eficientes de irrigação é uma realidade presente no plantio de frutas, a exemplo da irrigação por gotejamento nas culturas: uva, mamão, manga, melão, melancia, caju, coco e abacaxi (OLIVEIRA; RODRIGUES, 2020). A irrigação por gotejamento usa sistemas de transporte de água das fontes por tubos, válvulas e pequenos gotejadores; a tecnologia é usada para irrigar as áreas da raiz das plantas de forma direcionada, aplicando-a sob especificação determinada de quantidade (REDDY, 2015; TEIXEIRA; BASTIAANSEN, 2012).

A secagem parcial de zona radicular é outra técnica de irrigação com foco em parte da zona radicular - lado irrigado, ao alterar o lado úmido e seco, isso maximiza a eficiência do uso de água e reduz a pegada hídrica da cultura sem comprometer a fotossíntese, o crescimento e a produção da planta; essa tecnologia é comumente utilizada na produção de frutas precoces como o mamão nos estados da BA, CE e RN (SANTOS *et al.*, 2020b). O mamão apresenta as fases de crescimento, floração e maturação dos frutos em um curto período, a partir do terceiro mês após o plantio (SANTOS *et al.*, 2020b).

Outro exemplo é a irrigação deficitária, que consiste na aplicação de água abaixo das necessidades da evapotranspiração máxima, de modo a influenciar a cultura a extrair água do reservatório do solo para compensar o déficit (COTRIM *et al.*, 2011; FERERES; SORIANO, 2006). Essa prática pode ser utilizada com maior facilidade no período chuvoso, quando a irrigação junto com a precipitação superam a demanda de água da cultura (FOLHES; RENNÓ; SOARES, 2009). Para Santos, Moreira e Rodrigues (2013), é possível reduzir o consumo de água em vinícolas do semiárido brasileiro, sem que afete o metabolismo da uva. Algo que também se aplica à produção de manga, sem que haja perda da qualidade dos frutos e da produtividade do pomar a partir da aplicação controlada da irrigação deficitária (COTRIM *et al.*, 2011). Na cultura do feijão comum, melão e pimentão a irrigação deficitária junto ao plantio direto tem proporcionado um maior rendimento e acúmulo de biomassa do que no plantio convencional (FREITAS *et al.*, 2019).

Por outro lado, a depender da cultura, a redução da aplicação de água pode afetar negativamente a disponibilidade hídrica no solo das plantas (SANTOS *et al.*, 2020b). Como

é o caso da cultura do feijão-caupi [*Vigna unguiculata* (L.) Walp.] produzido no semiárido, nele a irrigação deficitária afeta negativamente o rendimento de grãos e o acúmulo de biomassa (FREITAS *et al.*, 2019). Já na cultura do mamão papaya (*Carica papaya* L.), o uso desse tipo de irrigação afeta o crescimento do fruto e a troca gasosa da folha (SANTOS *et al.*, 2020). Portanto, mesmo que o uso racional do recurso hídrico seja necessário em regiões semiáridas, compreender as técnicas utilizadas para esse fim ainda é um gargalo do conhecimento (SANTOS; MOREIRA; RODRIGUES, 2013).

Efetivamente, o conhecimento da variabilidade espacial das propriedades físicas e hidráulicas do solo tem possibilitado melhoras no manejo da irrigação (OLDONI; BASSOI, 2016). Similarmente ao conhecimento da evapotranspiração da cultura, um componente efetivo no planejamento da irrigação e no equilíbrio hídrico do solo (REIS *et al.*, 2019; VENANCIO *et al.*, 2020). De modo simples, a evapotranspiração representa a água que é vaporizada e que não fica mais disponível para o usuário, sendo parte importante no fluxo total de água próxima à superfície do solo (LAFAYETTE *et al.*, 2019; TEIXEIRA; BASTIAANSSEN; BASSOI, 2007).

A condutividade elétrica aparente do solo também tem sido utilizada como parâmetro de delineamento de zonas de manejo, indicando variações sazonais com base na mudança substancial de água no solo (OLDONI; BASSOI, 2016). Para identificar esses fatores, a tecnologia da Câmara Portátil tem sido usada em alguns experimentos e alguns testes em fazendas modelos com o objetivo de medir diretamente a evaporação/evapotranspiração, sendo a Câmara Portátil responsável por medir em tempo real e em curto intervalo de tempo a perda de água do solo (LAFAYETTE *et al.*, 2019).

Outra ferramenta é o Mapeamento da Evapotranspiração em Alta Resolução e Calibração Internalizada (METRIC - *Mapping Evapotranspiration at High Resolution and with Internalized Calibration*), nele ocorre o processamento de imagens para mapear a evapotranspiração, assim como para combinar sensoriamento remoto de média resolução e dados de medição hídrica de irrigação para estimar e melhorar a gestão de água total nas lavouras semiáridas (FERREIRA *et al.*, 2020; FOLHES; RENNÓ; SOARES, 2009). Algo parecido com o que é feito pelo Algoritmo Simples para Recuperação de Evapotranspiração (SAFER - *Simple Algorithm for Evapotranspiration Retrieving*), em que o cálculo é feito usando bandas visíveis, infravermelho próximo e infravermelho térmico em conjunto de dados de evapotranspiração de referência a ser estimado com dados de estações meteorológicas para calcular a evapotranspiração total em plantações nas quais se utiliza a

irrigação de precisão, como é o caso do milho irrigado em áreas baianas (VENANCIO *et al.*, 2020).

A utilização de geoprocessamento também tem possibilitado o monitoramento da umidade do solo a partir do balanço energético, conseqüentemente auxilia no manejo voltado para fins de conservação da água, produtividade das lavouras, monitoramento dos processos do solo, gestão de águas subterrâneas e controle da salinização do solo (REIS *et al.*, 2019; SILVA *et al.*, 2020a). Já para Pessoa *et al.* (2016), o uso de sensoriamento remoto oferece o mapeamento da dinâmica temporal como as tendências futuras da cobertura do solo e os processos antrópicos e ambientais visando o planejamento de uso de terras e de recursos naturais.

O sensoriamento remoto pode ainda mostrar os padrões de mudança do uso do solo, das condições ambientais e da extensão dos solos degradados (SILVA *et al.*, 2020a). Assim, o uso de uma dessas tecnologias tem sido positivo principalmente durante os meses de maior déficit hídrico - setembro a novembro (correspondem à metade da evaporação total anual), neste período a vegetação fica sob forte estresse hídrico pela evapotranspiração contínua e sem a entrada de água (FOLHES; RENNÓ; SOARES, 2009; LAFAYETTE *et al.*, 2019; SILVA *et al.*, 2020e). O estresse hídrico, por exemplo, altera o metabolismo primário e secundário das videiras nordestinas, além de reduzir a qualidade/produtividade dos frutos, gerando alterações nos atributos do vinho (SANTOS; MOREIRA; RODRIGUES, 2013). Ademais, conhecer e monitorar os fatores ambientais tem possibilitado o uso mais eficiente dos recursos hídricos, ao passo que se aprimora as práticas agronômicas visando melhorar a produtividade e a maior produção nas propriedades agrícolas (GUIMARÃES *et al.*, 2018).


No Vale do São Francisco as culturas tiveram um alto grau de investimentos que culminaram com culturas bastante tecnificadas com destaque para a manga: Tommy Atkins, Kent, Keitt, Palmer e Haden (CARNEIRO *et al.*, 2019; COTRIM *et al.*, 2011; HAJI *et al.*, 2004). Tecnologias essas como os reguladores de crescimento que permitiram a indução floral em diferentes períodos, gerando a produção contínua da manga ao longo de todo o ano (CARNEIRO *et al.*, 2019).

Já a uva, é uma cultura produzida com uso de modernas tecnologias de produção que vão desde a escolha da variedade (cultivares com ou sem sementes); melhoramento dos cultivares (Itália, Piratininga, *Red Globe*, *Itália Muscat*, *Benitaka*, *Sugraone*, *Thompson Seedless* e *Crimson Seedless*); passando pelos sistemas de produção (uma e duas colheitas por ano); manejo (reguladores de crescimento: ácido giberélico - AG3 e proteção dos cachos)

(SANTOS; MOREIRA; RODRIGUES, 2013). Com isso, gerando um maior valor agregado na exportação e disponibilidade da fruta no mercado internacional durante o período de entressafra dos maiores produtores mundiais (SANTOS; MOREIRA; RODRIGUES, 2013).

No caso do algodão naturalmente colorido, nativo de clima semiárido, a tecnologia empregada para alavancar a cultura tem sido melhoramento genético via a Empresa Brasileira de Pesquisa Agropecuária (Embrapa). Essa tecnologia contribuiu para o crescimento das lavouras, assim como, queda expressiva de custos de produção; ciclos de três anos tolerante à seca e a pragas com alto rendimento e boa qualidade de fios (QUEIROZ *et al.*, 2012), ver Figura 3.4. Como resultado, mais cores de fibra: marrom, verde, rubi, safira, topázio e jade, processada em pequenas indústrias de confecção na Paraíba, com exportação para mais de dez países (BARROS *et al.*, 2020).

Figura 3.4 – Cores das fibras de cultivares brasileiras de algodão naturalmente colorido.



Nota: (a) BRS 200 Marrom registrada em 2001; (b) BRS Verde, (c) BRS Rubi e (d) BRS Safira registrados em 2004; (e) BRS Topázio e (f) BRS Jade registradas em 2017.

Fonte: Barros *et al.* (2020, p. 9).

O melhoramento do caju (*A. occidentale* L.) solucionou o caso da altura e produtividade da planta, a baixa estatura ajuda no manejo do pomar: poda, controle de pragas e colheita, gerando aumento substancial na produção de castanhas no CE, PI e RN (QUEIROZ *et al.*, 2012). O melhoramento da cebola gerou cultivares mais adaptados e com resistência aos estresses bióticos regionais, resultando na substituição das antigas sementes pelas variedades produzidas pelo Instituto Agrônomo de Pernambuco (IPA); atualmente cerca de noventa por cento de todas as plantações no semiárido são plantações das variantes do IPA (QUEIROZ *et al.*, 2012).

Já, o tomate híbrido é resistente aos principais estresses bióticos (galhas de nematoides, doenças foliares, tospovírus e geminivírus), além de apresentar um melhor

rendimento pelas boas características das plantas e frutos (QUEIROZ *et al.*, 2012). Algo que aconteceu também com a palma forrageira (*Opuntia ficus indica*, Mill.), por meio da introdução de lavouras mais resistentes ao carmin cochonilha, principal praga da palma forrageira. Essa ação, junto à produção agrícola e ao aumento do rebanho bovino, impulsionou o crescimento da agropecuária na região (SILVA *et al.*, 2020e), já que essa planta é uma fonte energética usada na alimentação e nutrição de ruminantes; sendo diretamente associada à produção do leite de vaca, cabra e ovelha em períodos de escassez ou baixa disponibilidade de alimentos (GUIMARÃES *et al.*, 2018).

A produção de mandioca também sofreu modificações, com o desenvolvimento de cultivares tolerantes ao déficit hídrico intenso, com destaques para BRS 396 - “Engana-Ladrão”, BRS 397 - “Sacaí”, BRS 398 - “Crioula”, BRS 399 - “Amansa-Burro” (VISSÉS; SENTELHAS; PEREIRA, 2018). As regiões norte e nordeste são responsáveis por mais da metade da produção (57,7%) de mandioca no país, sendo produzida por pequenos agricultores familiares e consumida em ampla maioria na forma de farinha, um dos principais alimentos das famílias pobres dessas regiões (BURNEY *et al.*, 2014).

Paralelamente à mandioca, o feijão-caupi é outra cultura de grande importância para os sistemas agrícolas nordestinos, principalmente para a agricultura familiar no semiárido (MARINHO *et al.*, 2017); o feijão-caupi tem boa capacidade de resistir a períodos secos ao conter o seu desenvolvimento e retornar com o retorno das chuvas (FREITAS *et al.*, 2019). Com o incremento de genótipos de novas plantas como o BRS Pujante possibilitou a planta uma maior produção e um alto teor de proteína nos grãos, em alguns locais associado à inoculação de rizóbio (MARINHO *et al.*, 2017). “Rizóbio é um grupo de bactérias fixadoras de nitrogênio capaz de estabelecer associações de raízes e/ou caules com leguminosas” (MARINHO *et al.*, 2017, p. 274).

Na agricultura, a cooptação é explorada pela aplicação de produtos biotecnológicos contendo bactérias selecionadas que aumentam a produtividade da cultura (FREITAS *et al.*, 2019). A inoculação de rizóbio no Vale do São Francisco se utiliza da cepa BR 3267 (*Bradyrhizobium yuanmingense*) - principal bactéria usada em inoculantes de feijão-caupi no Brasil (MARINHO *et al.*, 2017). O plantio direto também contribuiu para promover um maior rendimento de grão e eficiência no uso de água em turnos de rega de 10 ou 14 dias em detrimento ao plantio convencional, pois melhora infiltração e conservação da água no solo (FREITAS *et al.*, 2019).

Portanto, os desafios futuros desses programas tendem a ser o fortalecimento dos atuais estudos como o desenvolvimento de clones biológicos resistentes aos estresses bióticos no caso do caju, ou mesmo uma maior variação de cor da lã de algodão naturalmente colorido (QUEIROZ *et al.*, 2012). Cabe destacar a necessidade de continuidade dos programas de melhoramento como elemento chave, por exemplo, mais de cinquenta anos no caso do caju; mais de quarenta para a cebola, tomate e o algodão (BARROS *et al.*, 2020; QUEIROZ *et al.*, 2012). Por outro lado, há a necessidade de esforços adicionais no seguimento de marketing a fim de impulsionar a notoriedade do produto perante o mercado (BARROS *et al.*, 2020). Assim como, impulsionar ainda mais a implementação de tecnologias voltadas para o desenvolvimento de alternativas produtivas diante o impacto potencial das mudanças climáticas na produção agrícola na Caatinga (BURNEY *et al.*, 2014; MAIA *et al.*, 2018).

3.3.3 Discussões

Indubitavelmente o aumento da agricultura irrigada na Caatinga nos últimos anos gerou implicações socioeconômicas positivas como a multiplicação nas exportações de frutas e geração de empregos ao converter áreas marginais semiáridas em locais de significativo desenvolvimento agrícola (HAJI *et al.*, 2004; TEIXEIRA; BASTIAANSEN, 2012; TEIXEIRA; BASTIAANSEN; BASSOI, 2007). No entanto, essas atividades intensificaram os conflitos relacionados ao uso da água no bioma (FERREIRA *et al.*, 2020; FOLHES; RENNÓ; SOARES, 2009). Em alguns locais o manejo de água de irrigação não tem obedecido aos critérios técnicos, deixando na dúvida se a quantidade de água usada atualmente nas plantações tem sido adequada ou não (COTRIM *et al.*, 2011). Nesses locais irrigados ainda não há uma tecnologia sofisticada de monitoramento que permita conhecer de forma regular o volume de água dos rios utilizado nas plantações (FOLHES; RENNÓ; SOARES, 2009).

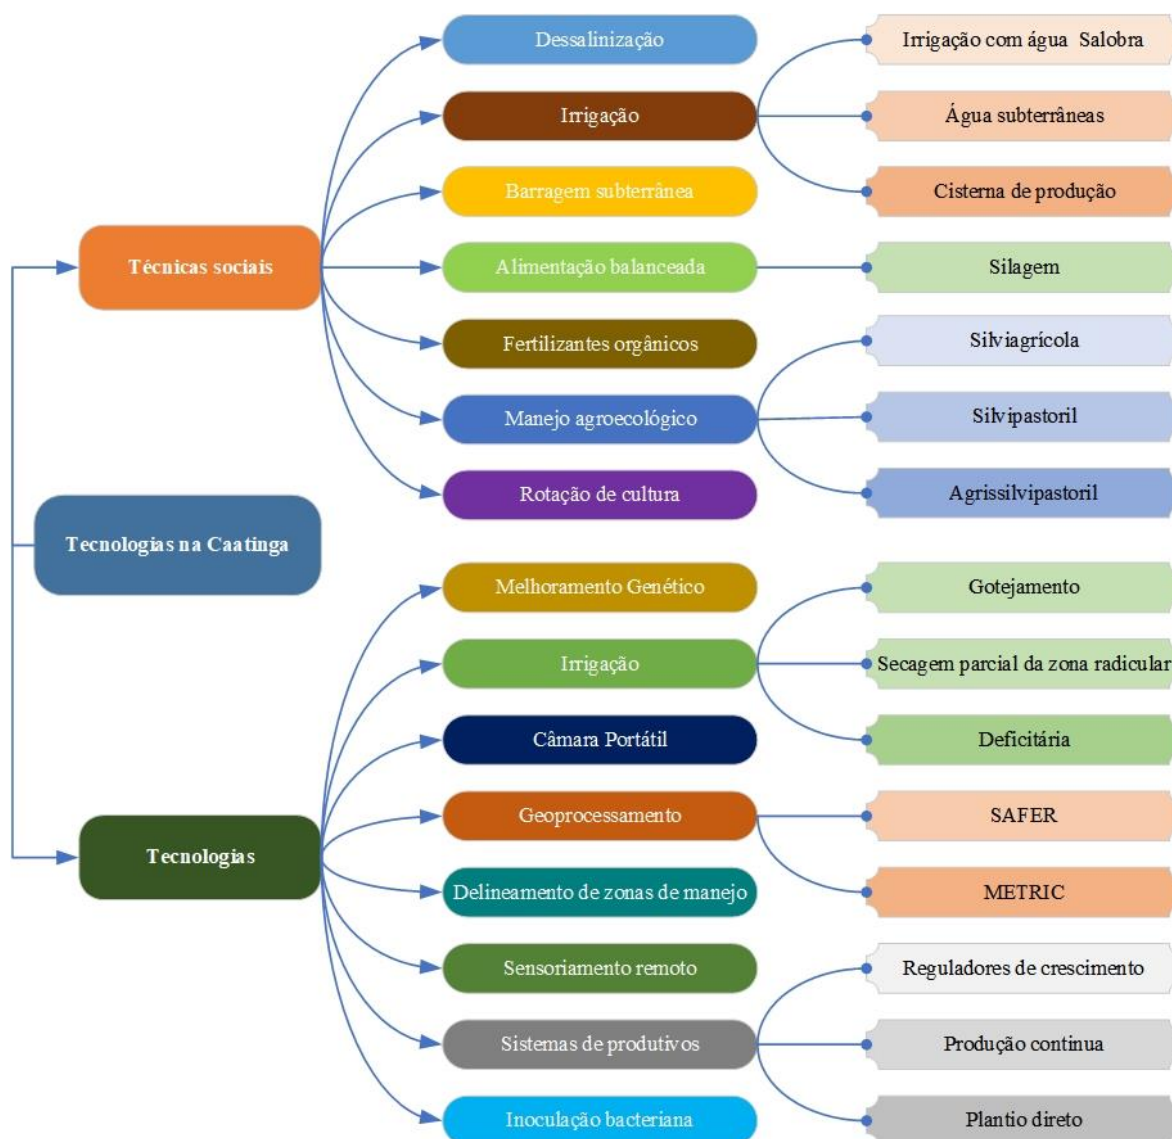
No bioma, a falta de planejamento e gestão dos recursos hídricos dos rios, podem comprometer as demandas futuras de água e aumentar a vulnerabilidade local (ANDRADE *et al.*, 2019). Assim, o uso racional do recurso hídrico é uma necessidade crescente em regiões semiáridas (SANTOS; MOREIRA; RODRIGUES, 2013). Entretanto, as alternativas já implantadas como a irrigação deficitária, zona radicular e irrigação por gotejamento têm tido êxito no controle hídrico (BURNEY *et al.*, 2014; FREITAS *et al.*, 2019; SANTOS *et*

al., 2020), ao ponto que na produção de manga na RIDE já está abaixo do recomendado - o volume real de água aplicado não pode mais ser reduzido (CARNEIRO *et al.*, 2019). Nesse caso a perspectiva é aprimorar as técnicas de cultivo para garantir a sustentabilidade e reduzir os custos de produção (SILVA *et al.*, 2020b).

Por outro lado, em decorrência dos recorrentes períodos de estiagem – último ocorrido entre os anos de 2012 a 2017 - essa economia hídrica é reduzida ao utilizar a irrigação suplementar para conter a queda na produtividade das plantações e o aumento da evapotranspiração da cultura (LINDOSO *et al.*, 2018). Por conseguinte, diretrizes políticas como controle e cobrança da água de irrigação mais eficientes são cada vez mais necessárias, visto a competição de múltiplos usuários entre setores (FOLHES; RENNÓ; SOARES, 2009). Já o monitoramento operacional exige ferramentas que auxiliem no estudo da dinâmica temporal e das tendências futuras de cobertura do solo em bacias hidrográficas; e a ampliação do uso do sensoriamento remoto na Caatinga tende a contribuir para um maior planejamento de terras e recursos naturais (SILVA *et al.*, 2020c).

Outrossim, o desenvolvimento de planos eficazes de manejo das terras semiáridas brasileiras depende de um melhor entendimento e monitoramento dos solos salinos, fator responsável pela degradação do solo em terras secas irrigadas (PESSOA *et al.*, 2016). Assim como, gerar tecnologias que viabilizem o aproveitamento de águas salinas no desenvolvimento agrícola (LIMA *et al.*, 2019). Nisso, o acesso a outras fontes da matriz energética como eólica e solar devem facilitar o uso de tecnologias de dessalinização de menor custo (ALBIERO *et al.*, 2014; CAVALCANTE JÚNIOR *et al.*, 2019; SILVA; SHARQAWY, 2020). Há de se considerar o aprimoramento de tecnologias e técnicas sociais (ver Figura 3.5), visando a difusão delas em locais pouco assistidos tecnicamente.

Figura 3.5 – Tecnologias utilizadas no agronegócio na Caatinga.



Fonte: Dados da pesquisa (2021).

Destarte, a busca por alternativas também passa por avanços científicos e tecnológicos de desenvolvimento de plantas com resistência aos principais estresses climáticos e biológicos, como também melhorias na produtividade da cultura e qualidade da matéria prima, das sementes, dos frutos e dos pseudofrutos (FOLHES; RENNÓ; SOARES, 2009; QUEIROZ *et al.*, 2012; SANTOS *et al.*, 2020b). No entanto, esses estudos necessitam de tempo para gerar resultados expressivos como o melhoramento do feijão comum, do algodão, do caju ou da uva; a continuidade desses programas com mais de três décadas tem proporcionado resultados como no algodão, a colheita de fibras mais fortes e de maior valor agregado (QUEIROZ *et al.*, 2012).

A cadeia produtiva do algodão naturalmente colorido tem se tornado importante para a economia paraibana com o fortalecimento da indústria têxtil e geração de emprego

(QUEIROZ *et al.*, 2012). Outrossim, o melhoramento genético também contribuiu para o aumento da população de animais na pecuária, fato pouco citado nos artigos, mas que teve influência na indústria de pecuária leiteira e de frangos (ANDRADE *et al.*, 2019; CARVALHO *et al.*, 2019). Nisso, as instituições de pesquisa como Embrapa, os institutos agronômicos estaduais e as universidades têm fomentado o desenvolvimento de produtos geneticamente modificados por meio de pesquisas contextuais para o semiárido (BURNEY *et al.*, 2014).

Outro ponto a destacar é o fortalecimento das ATER's nos estados - que na maioria dos estados do Nordeste se encontram desmanteladas (SILVA *et al.*, 2019), pois são elas as responsáveis principais no auxílio dos produtores na profissionalização das atividades (ANDRIEU; NOGUEIRA, 2010). Alguns relatos citam a compra de rações enriquecidas buscando aumentar a produtividade de leite, mas em decorrência da falta de informação/assistência técnica acabam por fornecer até 300% mais de proteínas do que as necessidades do animal, algo que coexiste muitas vezes com uma receita agrícola menor perante a produtividade leiteira baixa (BURNEY *et al.*, 2014; CARVALHO *et al.*, 2019).

A assistência técnica tende também a contribuir para a modernização tecnológica em vista à superação de gargalos competitivos da agropecuária (SILVA *et al.*, 2019). Mesmo que a falta de tecnificação não seja o único empecilho na atividade, o maior conhecimento e controle de qualidade na pecuária leiteira ou mesmo melhor aproveitamento da área total da propriedade para a pecuária de corte também são problemas a serem sanados (VASCONCELOS *et al.*, 2018). Na produção animal, há ainda a necessidade de alinhamento às estratégias de convivência com o semiárido, já que ocorre de forma paralela à exploração da agricultura de sequeiro (SILVA *et al.*, 2020).

A necessidade fundamentada no conhecimento reflete uma demanda local por uma agenda de pesquisa e produção em diversos setores agrícolas pela inserção da temática da inovação (SANTOS *et al.*, 2017). Os fatores como eficiência, qualidade ambiental, conservação, qualidade do produto, capital social, e o bem-estar e saúde animal refletem exemplos de carências para o uso de ferramentas técnicas e tecnológicas (BARRETO *et al.*, 2010). Assim como, para suprir o déficit por demanda de mão de obra de prestadores de serviços agrícolas ou para reparar a deficiência na infraestrutura local e a dificuldade no acesso a mercados (BURNEY *et al.*, 2014; SILVA *et al.*, 2019).

O desenvolvimento de políticas públicas específicas para o setor no bioma faz-se necessário, tendo em vista o fortalecimento de vantagens comparativas perante outras

regiões produtivas como o MATOPIBA. A região produtora de milho, soja, algodão e sorgo no Cerrado, que se tornou rentável mesmo sobre condições naturais adversas, mas que contam com prerrogativa de serem commodities – preços no mercado externo mais atrativos que o das frutas (OLIVEIRA; RODRIGUES, 2020). Seguindo essa perspectiva, um sistema de crédito bancário voltado exclusivamente para financiar a implementação de medidas adaptativas e assistência técnica tende a proporcionar ações eficazes ao desenvolvimento sustentável no bioma (MAIA *et al.*, 2018). Pois mesmo havendo o Programa Nacional de Fortalecimento da Agricultura Familiar (PRONAF), este possui impactos positivos em áreas mais desenvolvidas e eficácia questionável em áreas menos desenvolvidas (MAIA *et al.*, 2018). Ao passo que o fortalecimento de instituições como as cooperativas - pouco difundidas na região - e as agroindústrias, propende a valorização da produção agrícola familiar (LINDOSO *et al.*, 2018; OLIVEIRA; RODRIGUES, 2020). Por exemplo, por meio de estratégias de como a promoção de produtos por indicação geográfica e/ou por rastreabilidade de origem (FERNANDES *et al.*, 2020; GUIMARÃES *et al.*, 2018).

3.4 CONCLUSÕES

Neste artigo foi realizada uma revisão sistemática da literatura com o objetivo de fazer um levantamento sobre as tecnologias utilizadas no meio agrícola na área do bioma Caatinga, região de clima semiárido brasileiro. Nela foram identificadas as técnicas sociais ou técnicas de convívio com o semiárido e as tecnologias propriamente ditas. As técnicas sociais ajudam os pequenos produtores, grupos mais vulneráveis, a conviverem melhor no semiárido ao seguirem medidas de resiliência para superar os impactos da baixa precipitação pluviométrica (BURNEY *et al.*, 2014; MAIA *et al.*, 2018). Já as tecnologias têm contribuído para o aumento da produção de frutas irrigadas, tornando a região semiárida o principal polo frutícola brasileiro, ao transformar áreas marginais em locais de grande desenvolvimento agrícola capaz de fornecer frutas ao mercado internacional no período de entressafra dos maiores produtores mundiais (SANTOS *et al.*, 2017; SANTOS; MOREIRA; RODRIGUES, 2013; SILVA *et al.*, 2020b).

Os modelos climáticos atuais mostram o impacto potencial das mudanças climáticas futuras na hidrologia no bioma, afetando os fluxos dos rios, o armazenamento de água, a desertificação do solo e conseqüentemente a produção agrícola (BURNEY *et al.*, 2014; LINDOSO *et al.*, 2018; SILVA *et al.*, 2020e). Assim, produzir alimentos e produtos

derivados de alta qualidade passa pela utilização de tecnologias, insumos e mecanismos apropriados, capazes de minimizar os custos e o uso de recursos naturais. Neste sentido, o desenvolvimento de tecnologias adaptadas ao semiárido tem tido um papel importante no manejo do solo, aproveitamento da água da chuva e preparo de ração animal. Já em relação às tecnologias utilizadas principalmente nas frutas irrigadas, elas se tornaram fator dominante para a viabilidade da produtividade, diversificação, tempo de colheita e logística; ao serenar limitações naturais como clima, relevo e pluviometria na Caatinga. Outrossim, o melhoramento genético contribuiu para a propagação de culturas resistentes na agricultura e para o aumento de populações de animais na pecuária. A utilização de equipamentos de irrigação (gotejamento, aspersão etc.) ainda representam um processo importante na pegada de carbono ao atenuar o impacto nas mudanças climáticas (CARNEIRO *et al.*, 2019), mas que precisam ser aprimoradas para melhorar os resultados.

As práticas agrícolas têm sido modificadas nas últimas décadas com o desenvolvimento de novas tecnologias capazes de impulsionar a produção de alimentos, mesmo na Caatinga. Com base nas descobertas deste artigo, a atividade agrícola na Caatinga ainda se encontra nos estágios de desenvolvimento da segunda e terceira revoluções agrícola. Isso levando em consideração a baixa quantidade de estudos disponíveis sobre o uso de tecnologias no meio agrícola na Caatinga. Porém, as crescentes preocupações do público com o consumo de alimentos baseados numa interação dinâmica humano-natureza podem impulsionar as tendências para o uso de tecnologias inteligentes. A aplicação dessas não necessita estar estritamente associada à produção primária, mas em toda a cadeia de abastecimento. Assim, as tratativas para a utilização de tecnologias inteligentes e Inteligência Artificial, quarta e quinta revolução agrícola respectivamente, são atraentes, porém, os desafios técnicos e de gestão certamente precisam ser superados ao se projetar estratégias para avolumar o uso dessas tecnologias na Caatinga.

Agradecimento

O presente estudo foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

- ALBIERO, D. et al. Wind turbine for family farming in semi-arid areas with technological innovations for low wind speeds. **Revista Ciencia Agronomica**, v. 45, n. 1, p. 186–196, 2014.
- ANDRADE, C. W. L. et al. Soil moisture and discharge modeling in a representative watershed in northeastern Brazil using SWAT. **Ecohydrology and Hydrobiology**, v. 19, n. 2, p. 238–251, 2019a.
- ANDRADE, E. M. et al. Water as Capital and Its Uses in the Caatinga. In: **Caatinga**. Cham: Springer International Publishing, 2017. p. 281–302.
- ANDRADE, F. N. et al. Composição florística e estrutural de uma área de transição entre cerrado e caatinga em assentamento rural no município de Milton Brandão-PI, Brasil. **Scientia Forestalis**, v. 47, n. 122, p. 203–215, 30 jun. 2019b.
- ANDRIEU, N.; NOGUEIRA, D. M. Modeling biomass flows at the farm level: a discussion support tool for farmers. **Agronomy for Sustainable Development**, v. 30, n. 2, p. 505–513, 16 abr. 2010.
- ARAÚJO FILHO, J. A. **Manejo pastoril sustentável da Caatinga**. Recife: Projeto Dom Helder Camara, 2013.
- BARACUHY, J. G. V; FURTADO, D. A.; FRANCISCO, P. R. M. **Tecnologias de Convivência com o Semiárido Brasileiro**. Campina Grande: EDUFCEG, 2017.
- BARRETO, H. F. M. et al. Impactos ambientais do manejo agroecológico da caatinga no Rio Grande do Norte. **Pesquisa Agropecuária Brasileira**, v. 45, n. 10, p. 1073–1081, out. 2010.
- BARROS, M. A. L. et al. A Review on Evolution of Cotton in Brazil: GM, White, and Colored Cultivars. **Journal of Natural Fibers**, v. 00, n. 00, p. 1–13, 17 mar. 2020.
- BURNEY, J. et al. Climate change adaptation strategies for smallholder farmers in the Brazilian Sertão. **Climatic Change**, v. 126, n. 1-2, p. 45–59, 22 set. 2014.
- CARNEIRO, J. M. et al. Carbon and water footprints of Brazilian mango produced in the semiarid region. **International Journal of Life Cycle Assessment**, v. 24, n. 4, p. 735–752, 2019.
- CARVALHO, C. C. S. et al. Using infrared thermography to measure the body surface temperature of crossbred cows and calves in the semi-arid region of Minas Gerais, Brazil. **Journal of Animal Behaviour and Biometeorology**, v. 7, n. 3, p. 132–136, 2019.
- CAVALCANTE JÚNIOR, R. et al. Sustainable Groundwater Exploitation Aiming at the Reduction of Water Vulnerability in the Brazilian Semi-Arid Region. **Energies**, v. 12, n. 5, p. 904, 8 mar. 2019.
- COELHO JUNIOR, L. M. et al. Avaliação do uso do solo e dos recursos florestais no

semiárido do estado da Paraíba. **Ciência Florestal**, v. 30, n. 1, p. 72, 2020.

COELHO JUNIOR, L. M.; MARTINS, K. DE L. C.; CARVALHO, M. Carbon footprint associated with firewood consumption in northeast Brazil: An analysis by the IPCC 2013 GWP 100y Criterion. **Waste and Biomass Valorization**, v. 10, n. 10, p. 2985–2993, 2019.

COSTA, A. R. F. C.; MEDEIROS, J. F. DE. Nitrogen, phosphorus and potassium accumulation in watermelon cultivars irrigated with saline water. **Engenharia Agrícola**, v. 38, n. 3, p. 343–350, 2018.

COSTA, R. B.; ARRUDA, E. J.; OLIVEIRA, L. C. S. Sistemas agrossilvipastoris como alternativa sustentável para a agricultura familiar. **Interações (Campo Grande)**, 2002.

COTRIM, C. E. et al. Regulated deficit irrigation and Tommy Atkins mango orchard productivity under microsprinkling in Brazilian semi arid. **Engenharia Agrícola**, v. 31, n. 6, p. 1052–1063, 2011.

DINIZ, G. L. et al. Phytomass and quality of yellow passion fruit seedlings under salt stress and silicon fertilization. **Comunicata Scientiae**, v. 11, p. e3400–e3400, 2020.

FARIAS, J. L. S. et al. Socioeconomic analysis of smallholder producing goats and sheeps in the semiarid Cearense, Brazil. **Archivos de Zootecnia**, v. 63, n. 241, p. 13–24, 2014.

FERERES, E.; SORIANO, M. A. Deficit irrigation for reducing agricultural water use. **Journal of Experimental Botany**, v. 58, n. 2, p. 147–159, 6 nov. 2006.

FERNANDES, E. A. N. et al. Trace elements and machine learning for Brazilian beef traceability. **Food Chemistry**, v. 333, n. December 2019, p. 127462, 2020.

FERREIRA, T. R. et al. The use of remote sensing for reliable estimation of net radiation and its components: a case study for contrasting land covers in an agricultural hotspot of the Brazilian semiarid region. **Agricultural and Forest Meteorology**, v. 291, n. May, p. 108052, 2020.

FOLHES, M. T.; RENNÓ, C. D.; SOARES, J. V. Remote sensing for irrigation water management in the semi-arid Northeast of Brazil. **Agricultural Water Management**, v. 96, n. 10, p. 1398–1408, 2009.

FREITAS, R. M. O. et al. Water use of cowpea under deficit irrigation and cultivation systems in semi-arid region. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 23, n. 4, p. 271–276, 2019.

GUIMARÃES, B. V. C. et al. Prediction of “Gigante” cactus pear yield by morphological characters and artificial neural networks. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 22, n. 5, p. 315–319, maio 2018.

HAJI, F. N. P. et al. monitoring mango pests within an integrated production program in Brazil. **Acta Horticulturae**, v. 645, n. 645, p. 163–165, fev. 2004.

- HOFFMANN, R.; NEY, M. G. Estrutura fundiária e propriedade agrícola no Brasil, grandes regiões e unidades da federação. **Brasília: Ministério do Desenvolvimento Agrário**, v. 108, 2010.
- IBGE. Mapa de Biomas do Brasil. Escala 1:5.000. **Instituto Brasileiro de Geografia e Estatística (IBGE)**, 2004a.
- IBGE. Mapa de biomas do Brasil. Primeira aproximação. **Instituto Brasileiro de Geografia e Estatística (IBGE)**, 2004b.
- IBGE. Censo Agropecuário. **Instituto Brasileiro de Geografia e Estatística (IBGE)**, 2017a.
- IBGE. Mapa 1.2.5 - Semiárido. **Instituto Brasileiro de Geografia e Estatística (IBGE)**, p. 70, 2017b.
- JESUS, K. N. et al. Maize and sunflower yields and soil changes after five years of organic fertilization in the semi-arid region of Paraíba, Brazil. **Arid Land Research and Management**, v. 34, n. 4, p. 460–473, 2020.
- LACERDA, C. F. et al. Strategies for the Use of Brackish Water for Crop Production in Northeastern Brazil. In: **Saline and Alkaline Soils in Latin America**. Cham: Springer International Publishing, 2021. p. 71–99.
- LAFAYETTE, F. B. et al. Experimentation and modeling of soil evaporation in underground dam in a semiarid region. **RBRH**, v. 24, 2019.
- LIBERATI, A. et al. The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: explanation and elaboration. **PLoS medicine**, v. 6, n. 7, 2009.
- LIMA, A. O. et al. Barragens subterrâneas no semiárido Brasileiro: análise histórica e metodologias de construção. **Irriga**, v. 18, n. 2, p. 200–211, 2013.
- LIMA, G. S. et al. Photosynthesis, photochemical efficiency and growth of west Indian cherry cultivated with saline waters and nitrogen fertilization. **Bioscience Journal**, v. 35, n. 1, 2019.
- LINDOSO, D. et al. Harvesting Water for Living with Drought: Insights from the Brazilian Human Coexistence with Semi-Aridity Approach towards Achieving the Sustainable Development Goals. **Sustainability**, v. 10, n. 3, p. 622, 28 fev. 2018.
- MAIA, A. G. et al. Climate change and farm-level adaptation: the Brazilian Sertão. **International Journal of Climate Change Strategies and Management**, v. 10, n. 5, p. 729–751, 2018.
- MARINHO, R. C. N. et al. Symbiotic and agronomic efficiency of new cowpea rhizobia from Brazilian semi-arid. **Bragantia**, v. 76, n. 2, p. 273–281, 2017.

MASSRUHÁ, S. M. F. et al. **Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas**. Brasília: Embrapa, 2020.

MMA. **Biomass/Caatinga**. Disponível em: <<https://www.mma.gov.br/biomass/caatinga.html>>. Acesso em: 9 set. 2020.

MOURA, M. S. B. et al. Clima e água de chuva no Semi-Árido. **Potencialidades da água de chuva no Semiárido brasileiro**. Petrolina: Embrapa Semiárido, p. 37–59, 2007.

MUIR, J. P. et al. Value of endemic legumes for livestock production on Caatinga rangelands. **Revista Brasileira de Ciências Agrárias - Brazilian Journal of Agricultural Sciences**, v. 14, n. 2, p. 1–12, 2019.

OLDONI, H.; BASSOI, L. H. Delineation of irrigation management zones in a Quartzipsamment of the Brazilian semiarid region. **Pesquisa Agropecuária Brasileira**, v. 51, n. 9, p. 1283–1294, 2016.

OLIVEIRA, T. J. A.; RODRIGUES, W. A difusão do agronegócio nos cerrados do centro norte brasileiro e nas áreas irrigadas da caatinga nordestina. **Revista em Agronegócio e Meio Ambiente**, v. 13, n. 2, p. 525–546, 11 abr. 2020.

PENNINGTON, R. T.; LAVIN, M.; OLIVEIRA-FILHO, A. Woody Plant Diversity, Evolution, and Ecology in the Tropics: Perspectives from Seasonally Dry Tropical Forests. **Annual Review of Ecology, Evolution, and Systematics**, v. 40, n. 1, p. 437–457, dez. 2009.

PEREIRA, M. A. T.; CARMO, R. L. Fruticultura, emprego e migração: o caso da região de Petrolinas-PE e Juazeiro-BA. In: RANDOLPH, R.; SIQUEIRA, H.; OLIVEIRA, A. (Eds.). **Planejamento, políticas e experiências de desenvolvimento regional: problemáticas e desafios**. Rio Branco: Letra Capital, 2014.

PESSOA, L. G. M. et al. Spectral reflectance characteristics of soils in northeastern Brazil as influenced by salinity levels. **Environmental Monitoring and Assessment**, v. 188, n. 11, 2016.

QUEIROZ, M. A. et al. Plant breeding in the semiarid region of Brazil: examples of success. **Crop Breeding and Applied Biotechnology**, v. 12, n. spe, p. 57–66, dez. 2012.

REDDY, P. P. Climate Change Adaptation. In: **Climate Resilient Agriculture for Ensuring Food Security**. New Delhi: Springer India, 2015. p. 223–272.

REIS, M. M. et al. Empirical and learning machine approaches to estimating reference evapotranspiration based on temperature data. **Computers and Electronics in Agriculture**, v. 165, n. April, p. 104937, out. 2019.

ROCHA JÚNIOR, R. L. et al. Bivariate Assessment of Drought Return Periods and Frequency in Brazilian Northeast Using Joint Distribution by Copula Method. **Geosciences**, v. 10, n. 4, p. 135, 10 abr. 2020.

SANTOS, A. A. R. et al. Innovation dynamics: Analysis of mango innovation strategies by ride. **Revista em Agronegocio e Meio Ambiente**, v. 10, p. 91–114, 2017.

SANTOS, C. A. et al. Spatio-temporal patterns of energy exchange and evapotranspiration during an intense drought for drylands in Brazil. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, p. 101982, mar. 2020a.

SANTOS, C. M. G.; MOREIRA, M. M.; RODRIGUES, J. D. Metabolismo da videira “syrah” no semiárido nordestino sob três estratégias hídricas. **Semina: Ciências Agrárias**, v. 34, n. 6, Supl1, p. 3611, 6 dez. 2013.

SANTOS, D. L. et al. Partial root-zone drying in field-grown papaya: Gas exchange, yield, and water use efficiency. **Agricultural Water Management**, v. 243, n. July 2020, p. 106421, jan. 2020b.

SANTOS, A. P. S. et al. O semiárido brasileiro: roquezas, diversidades e saberes. **Instituto Nacional do Semiárido/Ministério da Ciencia, Tecnologia e Inovação**, p. 73, 2013.

SANTOS, P. M. et al. Mudanças Climáticas Globais e a Pecuária: Cenários Futuros para o Semiárido Brasileiro (Global Climatic Changes and Animal Production: Future Scenarios for the Brazilian Tropical Semi-arid). **Revista Brasileira de Geografia Física**, v. 4, n. 6, p. 1176, 21 mar. 2012.

SILVA, F. P. et al. Eficiência técnica e heterogeneidade tecnológica na agropecuária das regiões semiárida e não semiárida do Nordeste brasileiro. **Revista de Economia e Sociologia Rural**, v. 57, n. 3, p. 379–395, set. 2019.

SILVA, G. D. P.; SHARQAWY, M. H. Techno-economic analysis of low impact solar brackish water desalination system in the Brazilian Semiarid region. **Journal of Cleaner Production**, v. 248, p. 119255, mar. 2020.

SILVA, J. L. B. et al. Changes in the water resources, soil use and spatial dynamics of Caatinga vegetation cover over semiarid region of the Brazilian Northeast. **Remote Sensing Applications: Society and Environment**, v. 20, n. July, p. 100372, nov. 2020a.

SILVA, K. A. et al. Soil sampling optimization using spatial analysis in irrigated mango fields under brazilian semi-arid conditions. **Revista Brasileira de Fruticultura**, v. 42, n. 5, p. 1–18, 2020b.

SILVA, L. P. et al. Modeling land cover change based on an artificial neural network for a semiarid river basin in northeastern Brazil. **Global Ecology and Conservation**, v. 21, p. e00811, mar. 2020c.

SILVA, S. S. et al. Application strategies of saline water and nitrogen doses in mini watermelon cultivation. **Comunicata Scientiae**, v. 11, p. e3233–e3233, 2020d.

SILVA, M. V et al. Pilot monitoring of caatinga spatial-temporal dynamics through the action of agriculture and livestock in the brazilian semiarid. **Remote Sensing Applications: Society and Environment**, v. 19, n. July, 2020e.

SUDENE. Resolução N^o 107/2017 de 27 de julho de 2017. 2017a.

SUDENE. Resolução N^o 115 de 23 de novembro de 2017. 2017b.

TEIXEIRA, A. H. C.; BASTIAANSEN, W. G. M. Five methods to interpret field measurements of energy fluxes over a micro-sprinkler-irrigated mango orchard. **Irrigation Science**, v. 30, n. 1, p. 13–28, 31 jan. 2012.

TEIXEIRA, A. H. C.; BASTIAANSEN, W. G. M.; BASSOI, L. H. Crop water parameters of irrigated wine and table grapes to support water productivity analysis in the São Francisco River basin, Brazil. **Agricultural Water Management**, v. 94, n. 1-3, p. 31–42, dez. 2007.

VASCONCELOS, Â. M. et al. Characterize of production systems and milk quality of production units in the semiarid region of Ceará. **Ciência Animal Brasileira**, v. 19, n. 0, p. 1–13, 8 nov. 2018.

VELLOSO, A. L.; SAMPAIO, E.; PAREYN, F. G. C. Ecorregiões: propostas para o bioma caatinga. **Seminário de Planejamento Ecorregional da Caatinga. TNC/APNE Recife, Aldeia-Pernambuco**, p. 76, 2001.

VENANCIO, L. P. et al. Evapotranspiration mapping of commercial corn fields in Brazil using SAFER algorithm. **Scientia Agricola**, v. 78, n. 4, p. 1–12, 2020.

VILELA, E. F.; CALLEGARO, G. M.; FERNANDES, G. W. **Biomass e agricultura: oportunidades e desafios**. Rio de Janeiro: Vertebte Edições, 2019.

VISSES, F. A.; SENTELHAS, P. C.; PEREIRA, A. B. Yield gap of cassava crop as a measure of food security - an example for the main Brazilian producing regions. **Food Security**, v. 10, n. 5, p. 1191–1202, 11 out. 2018.

4 CAPÍTULO III - ANÁLISE DINÂMICA PARA O USO DA INTELIGÊNCIA ARTIFICIAL NO AGRONEGÓCIO NA CAATINGA - MAIOR REGIÃO SEMIÁRIDA DA AMÉRICA DO SUL

Resumo

Este estudo apresenta as perspectivas de uso da Inteligência Artificial (IA) na Caatinga pela concepção de especialistas de organizações de fomento no bioma, assim como traz a caracterização do conhecimento científico do uso de IA em áreas semiáridas. O desenvolvimento da pesquisa ocorreu por meio de entrevista semiestruturada e o levantamento sistemático da literatura de regiões com a mesma característica do bioma estudado. Os resultados levam a compreender que a adoção e o desenvolvimento da IA no Brasil ainda se encontram em fase inicial, com os agentes buscando nas pesquisas, conhecer as oportunidades dessa tecnologia frente aos negócios no setor agrícola. Na Caatinga, os estudos ainda são reduzidos, mas já há exemplos como rastreabilidade de carne, predição da produtividade da palma forrageira, delineamento de zonas de manejo ou mesmo na estimativa da evapotranspiração de referência. Contudo, há etapas que devem ser superadas até a integração da IA, como a habilidade de entender e manusear as ferramentas com IA e a integração dos sistemas dentro da cadeia de suprimentos. Já os resultados do levantamento sistemático apresentam ações como modelagem e previsão do fluxo de água; evapotranspiração; variabilidade, avaliação de terra; previsão de época ótima de semeadura e seleção de cultivares. Assim, os achados apresentam os diferentes usos da IA, com iniciativas de sustentabilidade habilitadas por mudanças no sistema agrícola atual.

Palavras-chaves: Inovação agrícola. Tecnologia da Informação. Aprendizado de Máquinas. Nordeste brasileiro. Gestão de recursos.

Abstract

This study presents the perspectives of using Artificial Intelligence (AI) in the Caatinga by the conception of a specialist of development organizations in the biome, as well as the characterization of the scientific knowledge of the use of AI in semi-arid areas. The development of the research took place through semi-structured research and the systematic survey of the literature of regions with the same characteristic of the studied biome. The results lead us to understand that the adoption and development of AI in Brazil are still at an early stage, with agents seeking in research to know the opportunities of this technology in the face of business in the agricultural sector. In the Caatinga, studies are still very limited, but there are already examples such as meat traceability, prediction of forage cactus productivity, delineation of management zones or even in the estimation of reference evapotranspiration. However, there are steps that must be overcome until the integration of AI such as the ability to understand and handle the tools with AI and the integration of systems within the supply chain. On the other hand, the results of the systematic survey present actions such as modeling and forecasting the water flow; evapotranspiration; variability, land assessment; prediction of optimal sowing time and selection of cultivars.

So, the findings present the different uses of AI, with sustainability initiatives enabled by changes in the current agricultural system.

Keywords: Agricultural innovation. Information technology. Machine learning. Brazilian Northeast. Resource management.

4.1 INTRODUÇÃO

O uso de Inteligência Artificial (IA) tem aumentado desde meados do século XX, visto sua aplicação para a resolução de problemas nas diferentes áreas científicas (ALZOUBI; ALMALIKI; MIRZAEI, 2019; FERREIRA *et al.*, 2021; YASEEN *et al.*, 2015). Nas últimas duas décadas, houve um aumento considerável na direção do desenvolvimento e aplicação de tipos de abordagens de IA como aprendizado de máquina (*Machine Learning*), visão computacional ou mesmo sistemas especialistas (BILALI; TALEB, 2020). Essas abordagens estão contribuindo para a agricultura inteligente, por meio da mineração, análise dos dados e conseqüentemente suporte à gestão e à tomada de decisão nas fazendas (RUPNIK *et al.*, 2019).

A IA é a capacidade do sistema para interpretar corretamente dados externos, aprender a partir desses dados e utilizar essa aprendizagem para atingir objetivos e tarefas específicas por meio de adaptação flexível (KAPLAN; HAENLEIN, 2019). A aplicação de modelos de IA utiliza técnicas neurais para lidar com processos complexos e não lineares, o que possibilita ser menos sensíveis a erros e ruídos nos parâmetros de entrada em comparação aos modelos estatísticos tradicionais (BAYATVARKESHI *et al.*, 2020). Essa vantagem deriva da capacidade de buscar soluções gradativamente para o problema examinado, em vez de fornecer soluções diretas por meio de derivadas parciais dos parâmetros dos modelos tradicionais acerca de dados de entrada e saída (YASEEN *et al.*, 2016). Nesse sentido, os métodos de IA possuem melhor desempenho do que as metodologias tradicionais quantitativas em suas formas originais e calibradas em cenários locais e regionais (FERREIRA *et al.*, 2021).

A IA tem permitido também, o tratamento de dados complexos (*Big Data*) por meio de modelos como redes neurais artificiais, aprendizado profundo e aprendizado de máquina (centenas de neurônios), apoiados pela programação e tecnologia computacional (CHANTRE *et al.*, 2018; CHEN; LIN, 2014). No meio agrícola, a IA torna a análise de dados mais eficiente ao prever com precisão fatores como modelagem e previsão do fluxo

de água; evapotranspiração; variabilidade climática; avaliação de terra; previsão de época ótima de semeadura e seleção de cultivares (DEO *et al.*, 2017; LAQUI *et al.*, 2019; SARANYA; NAGARAJAN, 2020).

A análise apurada desses fatores pode contribuir para gestão dos recursos em regiões semiáridas, locais de ambientes frágeis como o do bioma Caatinga (SOUSA *et al.*, 2013). Os fenômenos como redução das chuvas e aumento de temperatura, causados pela mudança climática, têm resultado na necessidade da modelagem mais eficiente dos parâmetros qualitativos e quantitativos (POURSAEID *et al.*, 2021). As mudanças dos padrões de chuvas ao longo da última década têm afetado significativamente a produtividade das safras (ULLAH *et al.*, 2018). Ao mesmo tempo que a onda de calor reduz os rendimentos das culturas incluindo problemas de redução da biomassa das lavouras, ciclos de vida mais curtos, menos peso seco do caule e problema na formação de semente - as safras de sequeiras são particularmente as mais afetadas (ELBELTAGI *et al.*, 2020; ULLAH *et al.*, 2018). De modo geral, a IA tem tido, por meio dos diferentes métodos, um progresso significativo na previsão e modelagem do conjunto de dados, visando apresentar alternativas e solução perante as ferramentas atuais e tradicionais (ELBELTAGI *et al.*, 2020). De modo que, a utilização da IA no semiárido tende a reduzir custos e otimizar o tempo de processamento dos dados, aumentando a capacidade de tomadores de decisão e planejadores por meio da seleção das melhores informações para o uso da terra em favor do agronegócio (BOUDIBI *et al.*, 2021).

Contudo, a aplicação de IA tem apresentado maior previsibilidade e/ou autocorrelação mais forte em locais úmidos (BAYATVARKESHI *et al.*, 2020; TABARI; TALAEE; WILLEMS, 2015). Em ambientes semiáridos os constantes desafios como dados escassos, bacias hidrográficas altamente modificadas pelo homem e o fluxo de água exhibe fortes respostas não lineares à chuva (COSTA *et al.*, 2021). Logo, o desenvolvimento da IA na Caatinga passa por variáveis ajustadas ao ambiente, visando a melhora na autocorrelação dos indicadores.

O potencial da utilização da IA deve permitir o desenvolvimento econômico e, ao mesmo tempo, melhorar os indicadores de sustentabilidade (PALMER, 2017; PYKA, 2017). A digitalização do campo e as máquinas autônomas devem aumentar maciçamente a eficiência produtiva, reduzindo assim o consumo de recursos (UNRUH, 2000). Tendência essa fortalecida ainda mais na última década à medida que houve forte avanço na economia de serviços perante o rápido crescimento das TIC (Tecnologias de Informação e

Comunicação) e conseqüentemente da IA no meio agrícola (TIEN, 2017; VAN DE GEVEL; NOUSSAIR, 2013). As inovações, as forças de mercado e as mudanças estruturais fazem parte da solução criativa capaz de reformar fundamentalmente a economia no sentido de sustentabilidade, apoiando assim as conquistas dos objetivos para o desenvolvimento sustentável (ONU, 2015), bem como assegurar crescimento e desenvolvimento agrícola paralelamente (MAZZUCATO; PEREZ, 2014).

Neste contexto, o presente artigo traz uma análise dinâmica preditiva para o uso da IA no agronegócio na Caatinga, objetivando apresentar estudos científicos e a visão de especialistas que permitam o delineamento de perspectivas acerca da aplicabilidade da ferramenta tecnológica. Assim, além da introdução, esse artigo possui a seção dos aspectos metodológicos com o delineamento metódico da pesquisa. Os resultados apresentam a visão dos especialistas seguido pelo levantamento científico da IA em ambientes semiáridos. Já as discussões tratam das contendas em torno dos estudos atuais no bioma intercaladas dos estudos da seção anterior. Por fim, as considerações finais, com uma síntese geral desse estudo.

4.2 ASPECTOS METODOLÓGICOS

Esta pesquisa do ponto de vista dos objetivos é classificada como exploratória, uma vez que essa investigação leva em consideração uma área na qual há pouco conhecimento acumulado e sistematizado (VERGARA, 2013). Em relação à técnica de pesquisa, foi desenvolvida por meio de estudo de caso, selecionando a região da Caatinga para a realização da análise. Esse método é aconselhado quando uma situação geral pode ser melhor entendida, a partir da análise em profundidade de uma situação particular (YIN, 2015). Nesse caso, uma análise para aplicação da IA no agronegócio da Caatinga. O estudo de caso foi apoiado por meio de entrevistas com especialistas representantes de empresas brasileiras de fomento ao desenvolvimento agrícola na Caatinga. Considerando o atual estágio da IA na Caatinga e a existência de poucas empresas dedicadas ao assunto, foi realizado entrevistas com quatro representantes de empresas brasileiras com atuação no bioma. O número de especialistas entrevistados, mesmo baixo, possibilitou uma visão satisfatória do cenário de IA na Caatinga. Para a definição dessa quantidade de entrevistados, seguiu-se o conceito de saturação, que é quando a coleta de novos dados não contribui para mais informações relacionadas ao tema a ser investigado (MASON, 2010). Os representantes foram escolhidos

por estarem à frente de pesquisas e estudos sobre a temática nas instituições, ver Figura 4.1. Houve ainda, a tentativa de contato com representantes de duas empresas do setor financeiro, duas instituições de desenvolvimento regional local e outra de assistência e extensão rural estadual, mas sem retorno.

Figura 4.1 – Perfis dos especialistas entrevistados.

Especialista	Descrição do Perfil
Especialista I	Doutor em Geologia, pesquisador nos Projetos Mapbiomas Caatinga, Mapbiomas Árida com foco em visão computacional e delimitação de zonas de manejo, Feira de Santana, BA.
Especialista II	Doutora em Engenharia Agrícola pela Universidade Federal do Ceará, pesquisadora na área de aprendizado de máquinas para a classificação do uso e cobertura da terra no bioma Caatinga, Fortaleza, CE.
Especialista III	Doutora em Engenharia de Processos, pesquisadora na área de Tecnologia e Inovação para Agropecuária no Instituto Nacional do Semiárido - INSA, Campina Grande, PB.
Especialista IV	Doutora em Computação Aplicada, pesquisadora na área de análise de sistemas da Embrapa Agricultura Digital, Campinas, SP.

Fonte: Dados da pesquisa (2021).

As entrevistas foram realizadas de forma individual e por videoconferência, com uma duração média de quarenta minutos cada (gravadas com autorização dos entrevistados), e posteriormente transcritas em editor de texto para apreciação crítica. Seguindo um roteiro de perguntas preestabelecidas, mas sem uma ordem combinada: quais são as tendências de mercado agrícola para o desenvolvimento de IA na Caatinga; quais produtos e serviços na área de IA têm sido pensados e desenvolvidos no bioma; quais as barreiras para o desenvolvimento dessas novas tecnologias na Caatinga - IA; quais são as barreiras para os produtores rurais adotarem essas ferramentas e tecnologias. Após a realização das entrevistas os passos seguintes foram: análise, exploração do material, tratamento dos resultados e interpretação.

O local de estudo corresponde à região brasileira de clima semiárido - Caatinga, que engloba parte dos estados de Alagoas, Bahia, Ceará, Maranhão, Paraíba, Pernambuco, Piauí, Rio Grande do Norte e Sergipe, (Região Nordeste do Brasil) e parte do norte de Minas Gerais (Região Sudeste do Brasil) (MMA, 2019). A área do Bioma é de 844.453 km², estando situada entre os paralelos 3° e 17°S e meridianos 35° e 45°W, e cobre 9,92% do território nacional (IBGE, 2004). A precipitação anual varia de 300 a 1200 mm/ano, se concentrando aproximadamente noventa por cento no período de noventa dias no ano (ANDRADE *et al.*, 2017). A Caatinga foi selecionada como área de estudo por ser uma das mais populosas regiões de clima semiárida no mundo – apresentando uma porcentagem predominante da população rural e dependente da atividade agrícola em mais de quarenta e seis por cento dos municípios localizados no bioma, esses cobrem quarenta e nove por cento da região e

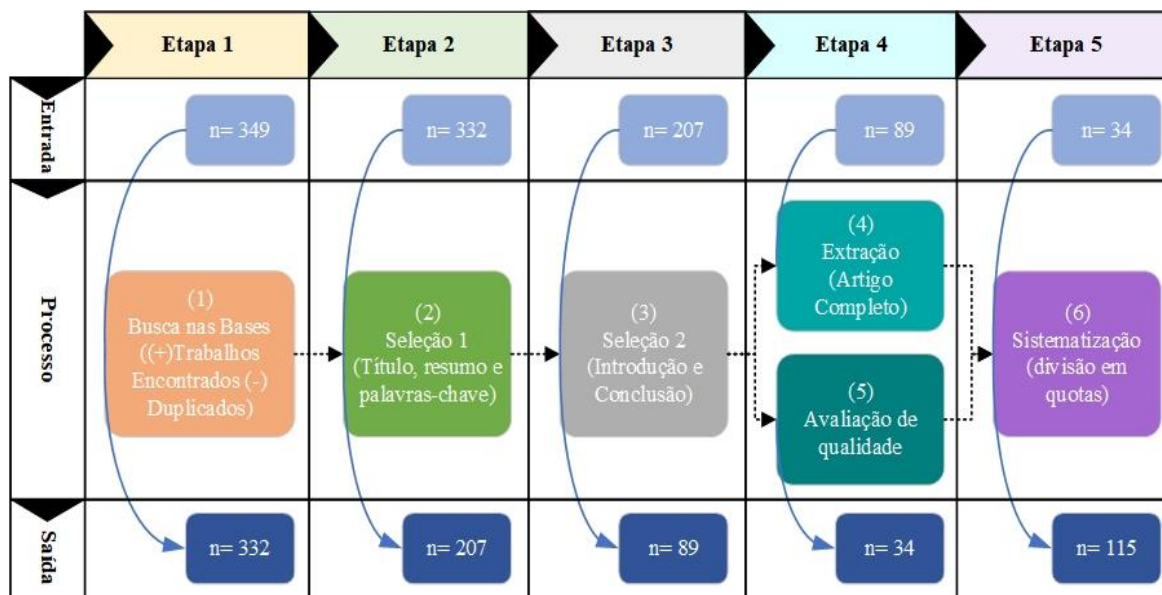
compreendem vinte e sete por cento da população (MMA, 2019). Mesmo com esses números, a quantidade de pesquisas relacionadas à Caatinga ainda é pouco expressiva em relação aos demais biomas nas principais bases de dados. A população rural na Caatinga depende da agricultura, a qual contribui com mais de dez por cento da atividade econômica local (BUAINAIN; GARCIA, 2013), sendo a maior parte demográfica, trabalhadores praticantes da agricultura de subsistência e sua produção negociada em mercados informais (SILVA *et al.*, 2017).

Em função da baixa quantidade de estudos sobre IA na Caatinga, foi realizada uma revisão sistemática com o intuito de apresentar estudos dessa tecnologia ligada a ambientes semiáridos, com forma de complementar e mostrar alternativas já desenvolvidas como direcionadores de ações futuras no bioma. Assim, a revisão sistemática contou com o levantamento de artigos na literatura feito a partir da busca de dados nas principais bases de dados bibliográficos: *Science Direct*, *Scopus*, *Springer Link* e *Web of Science*. As bases de dados foram escolhidas em decorrência de sua ampla cobertura de literatura relevante ao tema proposto, e ainda por recursos bibliométricos avançados, como sugerir literatura relacionada ou citações. A busca foi realizada usando a combinação de caracteres em inglês: [(semi-arid OR semiarid) AND (artificial intelligence) AND (agric* OR agribusiness)]. A pesquisa correspondeu a todo o período de publicação encontrado até o ano de 2021 (1991-2021). Teve como critérios de inclusão: ser artigo completo, ter acesso livre e publicado em inglês, uma vez que inglês representa o idioma com maior número de publicações nas bases referidas.

A revisão sistemática foi desenvolvida em cinco etapas: (i) busca nas bases bibliográficas com a combinação dos caracteres, seleção total dos artigos em cada base e geração do arquivo *bibtex*, conseqüentemente importado para o software Start 3.3 para organização dos dados e identificação dos artigos duplicados; (ii) leitura do título e resumo com o intuito de selecionar os artigos que tinham alguma ligação à pergunta de pesquisa; (iii) leitura da introdução e conclusão - sendo selecionados os artigos que possuíam na introdução ou na conclusão indícios que respondessem à questão da revisão; (iv) leitura dos artigos completos para contemplar a seleção e extração dos artigos finais, logo após, foi realizada uma nova releitura dos artigos selecionados para contemplar a avaliação da qualidade dos artigos finais por meio da escala de Likert ((1) discordo totalmente, (2) discordo, (3) indiferente (ou neutro), (4) concordo e (5) concordo totalmente), com a escolha dos artigos agrupados na escalas (4) e (5); e (v) sistematização com a escolhas das quotas –

frases ou parágrafos destaques dentro dos artigos ligadas à pergunta pesquisa. As etapas da sistematização da revisão são detalhadas na Figura 4.2.

Figura 4.2 – Processos da Revisão Sistemática.



Fonte: Dados da pesquisa (2021).

A revisão seguiu o protocolo de Principais Itens para Relatar Revisões Sistemáticas e Meta-análises - PRISMA (2009), por ser uma estrutura metodológica bastante utilizada nesse tipo de pesquisa e que permite o desenvolvimento das etapas de forma clara e que possibilita replicações. O desenvolvimento da pesquisa ocorreu no período de setembro a dezembro de 2021, sendo apoiadas pelos softwares: StArt (3.3 Beta 03) para a organização dos dados e seleção dos artigos; e Mendeley (1.19.4) para a gestão bibliográfica.

4.3 RESULTADOS

4.3.1 Perspectiva da IA na Caatinga na concepção dos especialistas

Esta seção apresenta os resultados qualitativos obtidos em entrevistas com especialistas, fornecendo uma visão geral de suas perspectivas acerca do uso da IA na Caatinga. Cabe ressaltar que a temática do estudo ainda se encontra em fase embrionária no bioma. Logo, a transcrição das entrevistas visa apresentar como estão as pesquisas e suas principais barreiras. A ordem dos especialistas segue a abordagem cronológica ou temporal das entrevistas – exemplo, o especialista I - foi o primeiro entrevistado, o especialista II - foi o segundo entrevistado, e assim por diante.

Especialista I

O especialista I, descreveu que a aplicação da IA na atividade agrícola na Caatinga está condicionada a iniciativas particulares, das quais os proprietários já possuem alguma ferramenta e tecnologia próprias: máquinas e equipamentos baseados em telemetria, sistemas de automação de máquinas e equipamentos (por exemplo, sistemas de orientação por satélite, mecanismos de regulação, como controladores de fluxo de sementes, fertilizantes e pesticidas), sistemas de coleta de dados (por exemplo, sensores de entrada e registros de variáveis meteorológicas) e amostragem de solo georreferenciada para mapear a fertilidade dos campos de cultivo (seguido pela prescrição e aplicação de corretivos em quantidades que variam de acordo com as condições de fertilidade de cada local).

Na Caatinga, segundo o especialista I, as iniciativas partem de áreas específicas, algumas dessas não estão diretamente ligadas ao setor agrícola, mas à conservação de áreas, como o caso de ONGs (ex. mapbiomas.org). O uso de IA nessa iniciativa se faz por meio do sensoriamento remoto baseado em algoritmos de aprendizado de máquinas profundos e Rede Neural de Convolução (CNN, do inglês: *Convolution Neural Network*), na interpretação com precisão de imagens de satélite visando apresentar informações acerca de mudanças na cobertura da terra no bioma. Alguns dos resultados levaram a considerações acerca de áreas agravadas pelo risco de desertificação ou suscetíveis à desertificação em 112 municípios (9% do bioma); os quais são classificados como áreas suscetíveis à desertificação – status muito grave e grave e com cerca de trezentos mil hectares de vegetação nativa perdida nos últimos trinta anos (SARAIVA *et al.*, 2020). Algo que corrobora com o resultado de alguns estudos sobre a degradação do solo associada ao aumento da temperatura, bem como às práticas de uso não sustentável do solo – forte pressão das atividades agrícolas, desmatamento, queima de recursos naturais principalmente em épocas de forte estiagem (MARENGO; TORRES; ALVES, 2017; MARTINS *et al.*, 2018; SILVA *et al.*, 2020a; SILVA *et al.*, 2020e).

Há também estudos voltados para o monitoramento e mapeamento de áreas irrigadas por pivôs centrais. Esses estudos ainda não estão sendo realizados na Caatinga, mas já existe ramificações para um uso a curto espaço de tempo nas áreas irrigadas no bioma. As áreas irrigadas são encontradas em diferentes pontos de disponibilidade de água como açudes e, principalmente, ao longo do Rio São Francisco (QUEIROZ *et al.*, 2012). Nessas áreas desenvolve-se o plantio por gotejamento de uva, mamão, manga, melão, melancia, caju, coco

e abacaxi (OLIVEIRA; RODRIGUES, 2020). Uma das vantagens para o monitoramento e mapeamento de áreas irrigadas por visão computacional é a não necessidade de ida a campo. Nesse mapeamento há o levantamento de informações de fatores como: contexto espacial do alvo de mapeamento, textura e forma. O treinamento para a validação desse modelo leva em média vinte e duas horas para ser concluído, sendo esse tempo afetado pelo tamanho do lote de imagens processadas. O uso desse método no bioma pode ser útil para monitorar o crescimento das áreas irrigadas, quantidade de equipamentos de irrigação instalado e para a estimativa de demanda de água doce utilizada na atividade agrícola (SARAIVA *et al.*, 2020).

Para concluir, o especialista I citou a falta de conhecimento como sendo a principal dificuldade. O nível de escolaridade dos trabalhadores rurais na Caatinga é um dos principais desafios para a incorporação de tecnologias. Esse conhecimento compreende a base educacional e a sofisticação tecnológica fundamental para manusear de forma correta as ferramentas, algo que tende a não gerar o melhor resultado pós implantação (BOLFE *et al.*, 2020).

Especialista II

Na atividade agrícola do semiárido o uso de tecnologias disruptivas ou inteligentes ainda é de baixa significância. A falta de estudos e, conseqüentemente, a aplicação de tecnologias torna o cenário agrícola ainda mais incerto acerca da modernidade dos processos. Para o especialista II, as características do bioma dificultam ainda mais a produção de estudos. Por exemplo, no uso de algoritmos para a previsão de cobertura do solo é algo pouco usual em ambientes áridos. Alguns estudos descrevem que a habilidade dos modelos inteligentes em trabalhar com variáveis de locais úmidos foi melhor do que em locais áridos, pois a cobertura de nuvens é uma restrição para obtenção de dados orbitais ópticos (BAYATVARKESHI *et al.*, 2020; COUTO *et al.*, 2019; MONTEIRO JUNIOR *et al.*, 2019).

A utilização de IA na Caatinga está atualmente associada a estudos do uso da terra e mudanças na cobertura do solo por meio de sistemas de informação geográfica e sensoriamento remoto. Esses estudos visam fornecer suporte à tomada de decisão ao caracterizar as condições singulares de degradação ambiental, ocupação do solo e as crescentes mudanças nas condições da terra no bioma. Para isso, os algoritmos seguem as etapas como previsão, simulação e validação dos resultados por meio de variáveis que controlam as mudanças na cobertura da terra como variáveis independentes e as imagens da

cobertura da terra como variáveis dependentes. Os resultados podem ainda, auxiliar na formulação de políticas públicas voltadas para a conservação dos recursos ambientais, conseqüentemente, minimizar os riscos de degradação do solo. Podem também, servir de base para novos estudos sobre a previsão dos fatores hidrológicos, climáticos e sedimentológicos em que a região pode estar sujeita e que influenciam toda a dinâmica ambiental das bacias hidrográficas.

O especialista II menciona que há uma lacuna a ser superada entre o conhecimento dos agricultores/nível tecnológico nas fazendas e o desenvolvimento de tecnologias inteligentes. Essa barreira afeta diretamente a comunicação da informação ao longo da atividade agrícola na região, de modo que a ênfase no desenvolvimento de sistema de informação deve ser colocada, proporcionalmente, menos na concepção e mais na aprendizagem dos agricultores e produtores a fim de aumentar a eficiência e eficácia na hora de utilizar essa tecnologia.

Especialista III

Na concepção do especialista III, a questão da transformação digital no campo, especificamente no Brasil, se encontra um pouco atrasada em relação às tendências e tecnologias para otimização dos processos, desenvolvimento de ferramentas específicas para melhorar o dia a dia do produtor e também dos outros atores relacionados à cadeia produtiva, como por exemplo aquelas que facilitem ao consumidor rastrear e verificar a saudabilidade e qualidade dos alimentos. Isso se apoia em estudos que tratam da necessidade do aumento da rastreabilidade em sistemas alimentares, pois mover produtos dos agricultores para os usuários finais é um dos desafios que os atores da cadeia de abastecimento enfrentam junto com a transparência e a sustentabilidade (GARDAS *et al.*, 2019; LEHMANN; REICHE; SCHIEFER, 2012).

Se tratando da IA, é notório o aumento das discussões sobre sua aplicabilidade nos processos cotidianos. Uma tecnologia disruptiva chave que pode transformar os sistemas agroalimentares. A atividade agrícola passa a ter oportunidades de construir as bases da agricultura digital que facilite a vida no âmbito rural. Assim como, auxilie no tratamento de dados oriundos das ferramentas digitais como forma de tornar a resposta mais rápida e mais eficaz. A aplicação da IA no meio agrícola apresenta caminhos de estudos voltados ao gerenciamento da saúde da cultura (visão computacional, aprendizado de máquinas,

reconhecimento de padrões); automação das operações (robótica); e desenvolvimento de cadeias de suprimentos orientadas pela demanda (reconhecimento de padrões, classificação e previsão, processamento de linguagem natural). Demandas essas que estão se tornando mais comuns no setor agroalimentar.

De acordo com o Especialista III, sua empresa busca alinhar as pesquisas em IA, em vistas de fornecer apoio aos parceiros de negócios e provedores de serviço como prestadores de serviço, agentes agrícolas e produtores rurais estão sendo consideradas no desenvolvimento de sistemas de tratamento de dados. Algo que tende a permitir uma maior comunicação entre as partes interessadas dentro do sistema agrícola. Para o especialista III, a barreira da comunicação é hoje um dos principais gargalos a ser superado. No bioma, a infraestrutura de telecomunicação torna a transmissão de dados por meio dos aparelhos, algo pouco confiável. Os sistemas inteligentes requererem uma conexão em tempo real com internet que permita o uso de informações. De modo que, as melhorias nessa infraestrutura tendem a propiciar novas oportunidades de sistemas.

Especialista IV

Em relação às perspectivas da IA no contexto brasileiro, o Especialista IV apontou que as ferramentas e as tecnologias disponíveis para a tecnificação da atividade agrícola nacional ainda não estão presentes para a maioria. Há alguns focos que estão diretamente ligadas ao poderio de investimento financeiro pessoal como forma de implementação dos primeiros protótipos em fazendas integradas. Segundo ele, o mercado passa por um processo inicial de desenvolvimento de tecnologias inteligentes, com diversos agentes entrando e buscando oportunidades na geração de inovações. A exemplo da Embrapa - Empresa Brasileira de Pesquisa Agropecuária – Unidade Agricultura Digital que anteriormente chamava-se Informática Agropecuária, mas passou por um reposicionamento da marca a ser alinhada ao contexto de transformação digital na agricultura atual; mostrando um movimento direcionado à promoção e desenvolvimento de projetos de pesquisa como modelagem e simulação, reconhecimento de padrões e geoprocessamento, Inteligência Artificial, big data e internet das coisas. Mais especificamente em relação à IA, a Embrapa vislumbra a instalação de Centros de Pesquisa Aplicada (CPAs) em IA, que se dedicarão ao desenvolvimento de pesquisas orientadas à resolução de problemas por meio da IA. Os CPAs serão criados com a cooperação do Ministério da Ciência, Tecnologia e Inovação, da

Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) e do Comitê Gestor de Internet no Brasil (CGI).

Atualmente, a empresa está desenvolvendo tecnologia que permite a máquinas agrícolas fazer o reconhecimento de plantas de forma automática por meio da robótica e da IA. Também são empregadas o aprendizado de máquina e o aprendizado profundo. Sendo capaz de identificar as culturas e diferenciar frutos, cachos ou espigas das demais estruturas vegetais. O estudo inicial está sendo desenvolvido em uma vinícola e em um milharal no estado de São Paulo, estudo esse que pode depois ser aplicado em outros locais como os pomares na Caatinga. Há também, pesquisas na área de fenotipagem para reconstruir espécies vegetais em diferentes dimensões também no estado de São Paulo. Já, no estado do Mato Grosso do Sul, tem-se o desenvolvimento de pesquisa para a contagem e detecção automática de plantas e linhas de plantio nas lavouras por meio de imagens de drones apoiadas por CNN. Ou mesmo, na identificação individual de animais no campo por meio de imagens, tecnologia similar à do reconhecimento facial, experimento esse desenvolvido na região pantaneira também do Mato Grosso do Sul.

As afirmações do especialista IV estão de acordo com os resultados apresentados em algumas pesquisas, reforçando que o uso de métodos relacionados à IA ainda estão em desenvolvimento inicial, mas com possibilidades diversas (FERREIRA *et al.*, 2021; OLIVEIRA *et al.*, 2021). Na agricultura, o desenvolvimento e a incorporação de novas tecnologias ocorrem de forma mais lenta do que em outras áreas, como a indústria em geral e também a eletrônica, automobilística e alimentícia (MASSRUHÁ *et al.*, 2020). Para o especialista IV, há um longo caminho a percorrer até que ocorra a incorporação e difusão em grande escala da IA e de outras tecnologias que transformem a atividade agrícola em conceitos inteligentes. Nessa perspectiva, a Embrapa por meio da Startup Agritech Semiárido busca fomentar o desenvolvimento na Caatinga de soluções voltadas ao agronegócio com a promoção de mentorias com especialistas em tecnologia e negócios a possibilitar conexão entre os diferentes setores produtivos.

Na percepção do Especialista IV, uma das barreiras para a adoção da IA passa pela falta de habilidade dos agricultores e produtores nas ferramentas inteligentes, paralelamente a isto, a manipulação dos dados obtidos nos equipamentos torna-se fator crucial para o sucesso da implantação. Uma vez que após implementação, elas irão gerar uma quantidade relevante de dados, e saber converter esses dados em informações carecem de sistemas mais

acessíveis ao usuário, sendo necessário aos envolvidos no processo produtivo aprender a manejar esses sistemas e as novas disponibilidades de dados e informações.

4.3.2 Explorando a literatura científica acerca do uso de IA em zonas semiáridas

Nos últimos anos, como resultado das mudanças climáticas, houve a redução das chuvas principalmente em regiões áridas e semiáridas, logo a modelagem de parâmetros qualitativos e quantitativos referentes aos recursos torna-se cada vez mais importante (POURSAEID *et al.*, 2021). A escassez de água, por exemplo, tem acarretado uma série de problemas como a mudança na produção agrícola, a qual, requer uma alta demanda hídrica (BAYATVARKESHI *et al.*, 2020; ELBELTAGI *et al.*, 2020). Em alguns locais semiáridos, a agricultura consome entre setenta e oitenta por cento da água doce disponível (ROSEGRANT; CAI, 2009; SARWAR; PETERS; MOHAMED, 2020). Sendo assim, a gestão eficiente e precisa de recursos hídricos - superficiais e subterrâneos - para fins agrícola faz-se necessário, tanto na produção de culturas como também no manejo dos rebanhos (NOURANI; ELKIRAN; ABDULLAHI, 2020; ZARE; KOCH, 2021).

A capacidade de modelos de IA como a Rede Neural Artificial (ANN, do inglês: *Artificial Neural Network*) inclui a alta velocidade em computação paralela, com a remoção do ruído e a identificação de padrões entre variáveis de entrada e saída (NOZARI; AZADI, 2019). A exemplo da modelagem e previsão do fluxo de água por meio de ANN, estudada na província iraniana de Khozestan, a qual idealizou cenários de mudança temporal de águas subterrâneas para a previsão hídrica do dreno temporal e para o cálculo de salinidade em diferentes níveis de profundidades/espacamento de drenagem (NOZARI; AZADI, 2019). Esses resultados são alcançados a partir da entrada de dados de observação – chuva, evaporação, umidade relativa, temperatura, descarga do canal de irrigação e recarga de água subterrânea – e a saída, estimando o nível futuro do lençol freático (CHITSAZAN; RAHMANI; NEYAMADPOUR, 2015). Já, em estudo na planície de Mashhad, a ANN serviu para indicar a porcentagem da salinidade do solo – baixa concentração na parte ocidental e a alta concentração na parte oriental – por meio de covariáveis ambientais e de campo (BOUDIBI *et al.*, 2021). Em áreas semiáridas a conservação das águas subterrâneas é de suma importância devido à falta de abastecimento de água potável (POURSAEID *et al.*, 2021), já a salinidade do solo é um dos perigos ambientais mais predominantes na degradação dos solos agrícolas (BOUDIBI *et al.*, 2021).

Outrossim, a estimativa precisa de fatores como a evapotranspiração influi em ações como o planejamento do sistema de irrigação ou mesmo na operação eficiente de níveis de reservatórios (YASEEN *et al.*, 2016; YU *et al.*, 2020). O processo de evapotranspiração é um dos principais elementos do ciclo hidrológico (AGHAJANLOO; SABZIPARVAR; TALAEI, 2013; LAQUI *et al.*, 2019), sendo um determinante para avaliar a variabilidade temporal e tendências no longo prazo, como o mecanismo de feedback climático ou mesmo na análise dinâmica das secas (BYAKATONDA; PARIDA; KENABATHO, 2018; ELBELTAGI *et al.*, 2020). A evapotranspiração é um fenômeno não linear e complexo – necessita de inúmeras variáveis climáticas e conseqüentemente a análise dos efeitos mútuos das variáveis entre si (SARWAR; PETERS; MOHAMED, 2020). A ANN é uma ferramenta para modelar sistemas não lineares e complexos, como no estudo das incertezas da evapotranspiração de referência diária no noroeste da China (YU *et al.*, 2020). Os resultados desses estudos confirmam o papel indispensável da temperatura como função predominante no processo de evapotranspiração, e que esses métodos de IA são confiáveis na tentativa de compreender o mecanismo intrínseco ou a análise das incertezas desse fenômeno natural (AGHAJANLOO; SABZIPARVAR; TALAEI, 2013; YU *et al.*, 2020). Ademais, a combinação do SVR Suporte (SVR, do inglês: *Support Vector Regression*) -Aprendizado de Máquina Extremo (ELM, do inglês: *Extreme Learning Machine*), mostrou-se bem robusto na estimativa de evapotranspiração, mesmo em caso de conjunto de dados meteorológicos incompletos (YU *et al.*, 2020). O ELM é capaz de treinar dados de forma individual ou mesmo um conjunto de dados, eliminando dados redundantes (POURSAEID *et al.*, 2021). Os resultados revelam-se promissores ao combinar os métodos SVR-ELM para estimativa da evapotranspiração de referência, melhorando a precisão na simulação ao alinhar as entradas não lineares dos bancos de dados - precipitação, temperatura, umidade relativa, velocidade do vento e radiação solar (NOURANI; ELKIRAN; ABDULLAHI, 2020).

A ANN produziu resultados satisfatórios no cálculo de economia de água em sistemas de irrigação no Egito, resultando no planejamento eficiente dos recursos hídricos e na programação do balanço hidrológico em vista ao alcance de sistemas mais sustentáveis (AGHAJANLOO; SABZIPARVAR; TALAEI, 2013; NOZARI; AZADI, 2019). Em suma, estudos para a previsão e gerenciamento de cenários para o uso de água nas culturas tende ao aumento potencial de produção agrícola (ELBELTAGI *et al.*, 2020). Esses estudos, corroboram para o monitoramento da variabilidade climática em regiões semiáridas, por meio da avaliação da persistência ou reversão no longo prazo de fatores naturais.

A dinâmica das secas é uma dessas variáveis que impactam na resposta dos sistemas hidrológicos (BYAKATONDA; PARIDA; KENABATHO, 2018). A seca é um fenômeno natural que ocorre quando a precipitação é menor, consistindo em um acidente de ocorrência imprevisível, mas de recorrência reconhecível (BELAYNEH; ADAMOWSKI; KHALIL, 2016). A seca não é específica da região semiárida, no entanto, esses locais já possuem recursos hídricos disponíveis de forma escassa mesmo em condições normais (AZADI; SEPASKHAH, 2012). Assim, o uso de técnicas e métodos de otimização, alocação e até simulação de recursos torna-se um fator de planejamento e gestão de soluções frente a situações futuras (ZARE; KOCH, 2021). Como no estudo realizado na região semiárida da Botswana, na África Austral, o qual determinou por ANN uma escala de tempo comum para o monitoramento da seca como parte da mitigação do fenômeno natural, sendo capaz de estabelecer tendências de seca e sua variabilidade (BYAKATONDA; PARIDA; KENABATHO, 2018).

No semiárido mexicano (KIM; VALDÉS, 2003) e indiano (MISHRA; DESAI, 2005), foi utilizada a combinação dos métodos ANN-Regressão do Vetor de Suporte (SVR, do inglês: *Support Vector Regression*), para analisar a previsibilidade da seca nesses dois ambientes. Eles aprendem usando observações históricas para aplicar peso apropriado aos componentes do modelo em diferentes padrões (NOURANI; ELKIRAN; ABDULLAHI, 2020). Esta combinação apresentou como resultado uma projeção das condições geralmente secas para os próximos quarenta meses, indicando melhora significativa na capacidade de prever secas regionais, por meio da indicação precoce de um possível período sem chuva, ajudando assim na definição de estratégias e medidas de mitigação da seca com certa antecedência (BYAKATONDA; PARIDA; KENABATHO, 2018; KIM; VALDÉS, 2003; MISHRA; DESAI, 2005). A previsão pode ser uma ferramenta valiosa para fornecer um aviso prévio em vista de reduzir os impactos de um evento iminente, assim como, ser capaz de produzir informações direcionadoras às áreas de gestão de recursos hídricos, avaliação da qualidade da água e implementação de práticas agrícolas sustentáveis (YASEEN *et al.*, 2016).

Outra função atribuída à ANN é a avaliação e aptidão da terra para a produção de culturas – realizada para estimular a adequação da terra para um uso específico como agricultura arável ou agricultura irrigada (BAGHERZADEH *et al.*, 2016). A avaliação da terra compara os valores do índice de terra de ambos os modelos com a produtividade observada da cultura, a fim de validar a precisão dos modelos de forma prática (BOUDIBI

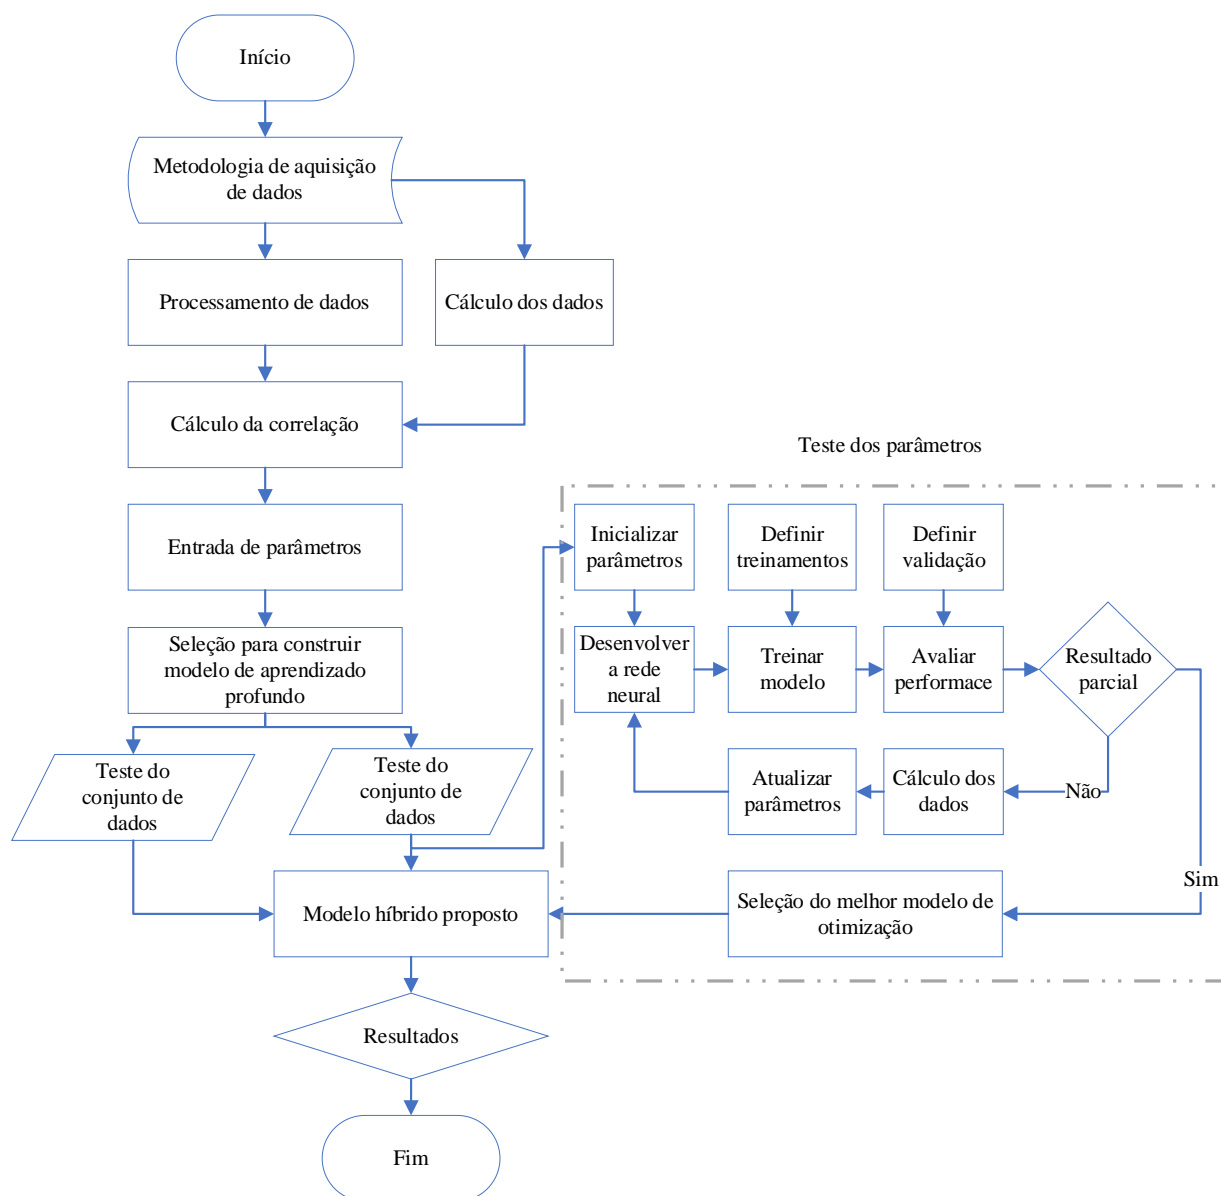
et al., 2021). Encontrar o terreno adequado para cultura específica é uma questão chave para produzir rendimentos de insumos relativamente baixos, existindo dois estágios para encontrar o terreno adequado para uma cultura: (a) levantar os requisitos da cultura junto aos atributos locais e do solo que influenciam adversamente a cultura; (b) identificar e delinear o terreno com os atributos desejáveis (BAGHERZADEH *et al.*, 2016). Já, em trabalho desenvolvido por pesquisadores indianos, o modelo ANN foi capaz de melhorar a previsão de rendimentos/produktividade de milho e soja por meio de dados multitemporais de satélite (SARANYA; NAGARAJAN, 2020). A fim de beneficiar a gestão com informações disponíveis em tempo real, consequentemente facilitando a tomada de decisão nas diferentes perspectivas gerenciais (CHANTRE *et al.*, 2018).

Em estudo desenvolvido para avaliar a aptidão de terra para produção de soja irrigada na planície de Neyshabour, nordeste do Irã, fez-se o uso de ANN-Fuzzy (BAGHERZADEH *et al.*, 2016). Esse método permite a divisão de campos de cultivo em áreas menores e mais homogêneas, o que pode ser útil para auxiliar a alocação de ponto de amostragem mais representativa da cultura com uma maior precisão (SILVA, K. A. *et al.*, 2020). Esse estudo contou com o levantamento preciso das propriedades morfológicas e físico-químicas, apresentando a fertilidade do solo como um dos principais fatores limitantes para o cultivo de soja em ambientes semiárido (BAGHERZADEH *et al.*, 2016). Uma previsão espacial precisa de terras agrícolas contribui para agricultores e tomadores de decisão desenvolverem mecanismos apropriados para prevenir a perda de solo fértil e aumentar a produção (BOUDIBI *et al.*, 2021). No entanto, essa combinação pouco permite o trabalho com dados não lineares, fato este que gera uma diminuição de resultados precisos, de modo que, o treinamento dos dados pode melhorar a precisão da previsão dos métodos ANN-Fuzzy (BILALI; TALEB, 2020; SHIRI *et al.*, 2014).

Outro exemplo do modelo combinado de ANN-Algoritmo Genético (GA, do inglês: *Genetic Algorithms*), o GA é um algoritmo de busca estocástica que começa a partir de um conjunto inicial aleatório de soluções chamadas de cromossomos, composto de elementos chamados genes, esse processo inclui a seleção, crossover e mutação (ULLAH *et al.*, 2018). Empregando uma estrutura de ‘árvore de análise’ na busca de soluções por meio das relações entre as variáveis dependentes e independentes usando vários operadores para modelar o fenômeno estudado (SHIRI *et al.*, 2014; ULLAH *et al.*, 2018). A combinação ANN-GA foi utilizada para a seleção de cultivares e previsão de época ótima para semeadura de gramíneas em diferentes regiões da China (PI *et al.*, 2015). No uso para a previsão e manejo de

emergência de ervas daninhas no semiárido argentino (CHANTRE *et al.*, 2018). A combinação de mais de uma rede neural é possível, pois elas são capazes de identificar em um conjunto de parâmetros uma regra de aprendizagem híbrida que combinam as potencialidades dos dois métodos para trabalharem em conjunto ou como ratificador dos resultados (SHIRI *et al.*, 2014), ver Figura 4.3.

Figura 4.3 – Sequenciamento para uso de modelos híbridos de IA.



Fonte: Adaptado de Sharma, Singh e Jain (2021).

A promoção de sistemas combinados (mais de um método), funciona como complemento no tratamento de dados ou mesmo como validadores dos resultados (CHANTRE *et al.*, 2018; POURSAEID *et al.*, 2021; SARANYA; NAGARAJAN, 2020; YASEEN *et al.*, 2016). Outros métodos de menor popularidade também são citados nos estudos, a exemplo da Rede Neural de Convolução (CNN, do inglês: *Convolution Neural*

Network), uma rede de aprendizado profundo que usa técnicas como fusão, modelagem e segmentação de imagens baseadas no sensoriamento remoto (CHEN *et al.*, 2020); esse método é capaz de identificar em uma imagem, área com certas peculiaridades como cobertura florestal, áreas urbanas ou mesmo áreas propensas à erosão (SHARMA; SINGH; JAIN, 2021). Outrossim, a Rede Neural Wavelet (WNN, do inglês: Wavelet Neural Network), oferece perspectiva preditiva de estimação de fatores ambientais baseadas em dados de radiação solar, temperatura e velocidade do vento (ELBELTAGI *et al.*, 2020). Foi utilizada também na avaliação da mudança climática para a produção de milho em Punjab no Paquistão, prevendo os impactos negativos da produção em decorrência do aquecimento futuro (ULLAH *et al.*, 2018). Esses estudos também citam como alternativa ao GA o método da Colônia Artificial de Abelhas (ABC, do inglês: *Artificial Bee Colony*), pois possui estrutura parecida ao GA e que também é capaz de reduzir o tempo de execução dos dados, assim como calibrar a porcentagem de erros na escolha dos clusters ótimos (SARANYA; NAGARAJAN, 2020).

Outros exemplos de combinação de algoritmos de aprendizagem de máquinas: Perceptron Multicamadas (MLP, do inglês: Multilayer Perceptron); Floresta Aleatória; e Árvore de Classificação e Regressão (CART, do inglês: *Random Forest e Classification and Regression Tree*). Esses algoritmos geraram regras de classificação capazes de discriminar para o processamento, a carne bovina brasileira produzida nos biomas da Amazônia, Caatinga, Cerrado, Pampa e Pantanal (FERNANDES *et al.*, 2020). O desenvolvimento desse estudo visa superar um dos principais desafios na rastreabilidade de carne bovina, perda das informações sobre o animal no processo de abate e/ou comercialização (FERNANDES *et al.*, 2020). Esse estudo visa também, impulsionar os avanços tecnológicos no processo produtivo, algo também estudado por meio de ANN/Sistema Especialista. Esses algoritmos são utilizados para apoiar o diagnóstico de falhas em máquinas agrícolas e de processamento (MISHRA; SATAPATHY, 2021), em que os fatores como as condições de trabalho, tipo e quantidade de processamento e resistência operacional são considerados a fim de monitorar o desempenho das máquinas..

Essa atividade também pode ser desenvolvida a partir do uso de algoritmos como aprendizado de máquinas no diagnóstico e detecção de falhas, melhorando a eficiência energética e reduzindo custos de manutenção de veículos na distribuição de produtos do campo (SHU *et al.*, 2017). Algo feito a partir do mapeamento do trajeto, cabendo ao algoritmo selecionar os pontos mais apropriados em um processo de autoaprendizagem,

agregando valor à base de conhecimento existente e orientando os tomadores de decisão para melhorar o desempenho da cadeia de suprimentos agrícolas (GARDAS *et al.*, 2019). Wang *et al.* (2017) utilizam o Aprendizado de Máquina para caracterizar e prever o comportamento dos usuários dentro dos veículos autônomos, como forma de melhorar a comunicação veículo e usuário. Já Bonaccorsi *et al.* (2017) apresentam estudo com máquinas de armazenamento inteligentes, capazes de adotar comportamento ecológico e energético, ao realizarem (por meio de sensores com Visão Computacional) o reconhecimento automático de alimentos, bem como a localização dentro do espaço interno, assim como monitorar o uso do aparelho, evitando problemas de temperatura e umidade em uso indevido. Feng (2019) fez uso de algoritmo de colônia de formigas para encontrar o caminho de distribuição ideal, isso calculado com base no modelo de custos em diferentes métodos de entrega que facilitem a logística de comércio eletrônico rural.

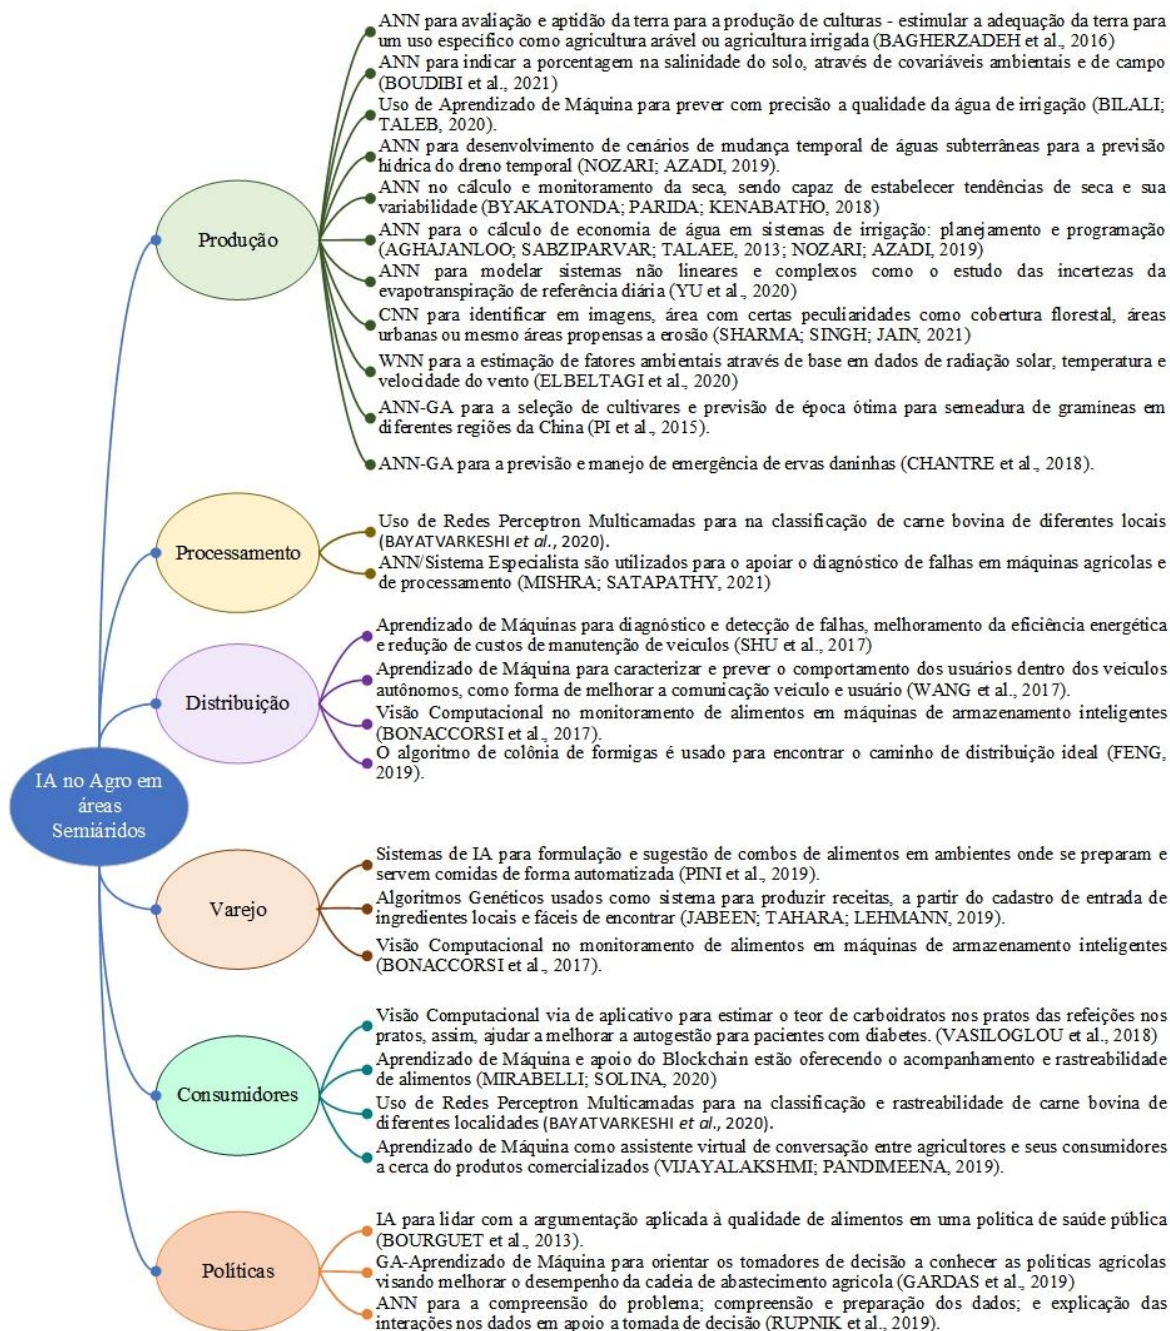
Já no setor de varejo a abordagem de Algoritmo Genético foi empregada para desenvolver um sistema que produza receitas novas e válidas automaticamente, a partir do cadastro de entrada de ingredientes locais e fáceis de encontrar (JABEEN; TAHARA; LEHMANN, 2019). As abordagens de aprendizado de máquina podem ser empregadas para prever as classificações das receitas filhas automaticamente. Em suma, a pesquisa apresentada possui estrutura de nível bem experimental, assim como uma outra que trata da aplicação da criatividade computacional, ou seja, sistemas de IA para formulação e sugestão de combos de alimentos em ambientes onde se preparam e servem comidas de forma automatizada (PINI *et al.*, 2019).

Em relação aos consumidores, a IA por meio do Aprendizado de Máquina e apoio do Blockchain, e está oferecendo cenários de acompanhamento e rastreabilidade de alimentos como forma de garantir: confiabilidade, transparência e imutabilidade das informações contidas nas embalagens (MIRABELLI; SOLINA, 2020). Vasiloglou *et al.* (2018) usaram a visão computacional, por meio de aplicativo de *smartphone*, para estimar de forma precisa e em tempo real o teor de carboidratos nos pratos das refeições, assim, ajudar a melhorar a autogestão, por exemplo, para pacientes com diabetes. E Vijayalakshmi e Pandimeena (2019) utilizaram o Aprendizado de Máquina para desenvolver um assistente virtual de conversação que oferece a agricultores e seus consumidores uma melhor oportunidade de entregar e obter informações dos produtos comercializados, por meio do qual o emissor e usuários podem se comunicar diretamente (VIJAYALAKSHMI; PANDIMEENA, 2019).

Gardas *et al.* (2019), utilizam o modelo integrado GA-Aprendizado de Máquina para orientar os tomadores de decisão e políticas agrícolas para melhorar o desempenho da cadeia de abastecimento agrícola na Índia. Esse modelo integrado foi capaz de mapear informações de forma rápida, dando algumas recomendações acerca de políticas de tarifação de produtos e serviços no país asiático de acordo com a necessidade do usuário. Outras concepções se voltam para o uso da IA na argumentação aplicada para permitir a formalização do conhecimento disponível como elemento para a tomada de decisão: micro - estrutura interna de um argumento; macro - relações entre argumentos; e retórica - considerações do público sobre os argumentos (BOURGUET *et al.*, 2013).

Essa abordagem pode ser aplicada, por exemplo, para analisar a argumentação sobre a qualidade de alimentos em uma política de saúde pública, considerando tomar decisões bem equilibradas, considerando os dados disponíveis - sociais, ambientais e econômicos. Por fim, Rupnik *et al.* (2019) apresentam um sistema destinado a fornecer suporte aos sistemas agrícolas e à tomada de decisão junto aos agricultores de maneira acessível. Esse sistema é projetado a partir da ANN para a compreensão do problema; compreensão e preparação dos dados; e explicação das interações nos dados - visando apresentar soluções e previsões para cenários simulados (RUPNIK *et al.*, 2019). Em suma, a revisão desses estudos forneceu uma variedade de alternativas em toda a cadeia (ver Figura 4.4) que resume todas as instâncias encontradas onde a IA foi empregada em ambientes semiáridos.

Figura 4.4 – Aplicações de IA em sistemas agrícolas.



Fonte: Dados da pesquisa (2022).

As descobertas apresentam os vários usos da IA, com iniciativas de sustentabilidade habilitadas por mudanças no sistema atual agrícola. Ao fornecer uma caixa de ferramenta de suporte às atividades e consequentemente à tomada de decisões (BILALI; TALEB, 2020; RUPNIK et al., 2019). Este levantamento reflete o potencial para alavancagem da IA no estabelecimento das interações humano-tecnologia-ambiente em regiões semiáridas ao longo de todas as etapas da cadeia. No entanto, deve-se mencionar que, essa tecnologia carece de maior expansão e testes em vistas de haver uma diminuição de ruídos em sua

capacidade de popularização junto à população nesses ambientes. De modo que as abordagens multidisciplinares são necessárias como elos que abrangem todos os campos mencionados acima e considerados no escopo desta revisão.

4.3.3 Discussões

Os resultados dessa pesquisa levam a compreender que a adoção e o desenvolvimento de IA na agricultura brasileira ainda se encontra em fase inicial, com agentes buscando conhecer as oportunidades dessa ferramenta para os negócios no setor agrícola. E que o fornecimento e desenvolvimento de ferramentas IA estão atualmente concentrados em máquinas e equipamentos, tendo as instituições de pesquisa o papel de desenvolvimento e implantação dos protótipos em áreas integradas como os CPAs. Esses centros se dedicaram ao desenvolvimento de pesquisas científicas, tecnológicas e de inovação para a resolução de problemas por meio de IA (MASSRUHÁ *et al.*, 2020). Na Caatinga, os estudos são bem reduzidos, mas já há exemplos validos como no uso algoritmos de aprendizado de máquina para a geração de regras e classificação de carne bovina brasileira produzida nos biomas: Amazônia, Caatinga, Cerrado, Pampa e Pantanal. Os resultados mostraram a viabilidade de combinar algoritmos para a rastreabilidade de carne em função da origem geográfica; com destaque para o melhor desempenho de classificação obtido para os biomas Amazônia e Caatinga (FERNANDES *et al.*, 2020).

Guimarães *et al.* (2018) desenvolveram estudo com ANN, voltado a predição da produtividade da palma forrageira (*Opuntia ficus indica*, Mill.) por meio da análise da área total do cladódio, altura da planta, espessura do cladódio e comprimento do cladódio; resultando na estimação com alta eficiência da produtividade da palma forrageira no município de Guanambi/BA (GUIMARÃES *et al.*, 2018), mas se mostra importante para o planejamento de pequenos e médios produtores rurais na Caatinga em períodos de escassez ou baixa disponibilidade de alimentos para a nutrição animal.

O estudo de Silva *et al.* (2020) trata do uso de técnicas de delineamento de zonas de manejo e modelagem dinâmica da cobertura do solo baseada em uma MLP-ANN em Taperoá/PB. De modo geral, a análise em relação ao comportamento da cobertura do solo parte da identificação de áreas mais vulneráveis e pode contribuir para a formulação de políticas públicas voltadas à conservação dos recursos ambientais, por exemplo em bacias hidrográficas, conseqüentemente, diminuir os riscos de degradação de recursos naturais. O

uso de algoritmos computacionais para o monitoramento de mudanças na cobertura do solo também foi utilizado por Sousa *et al.* (2013) no município de Iguatu/CE, o qual mostrou-se apto à classificação de padrões, ao conhecimento das propriedades e à distribuição espacial da terra visando o manejo adequado dos recursos em ambientes frágeis como o do bioma Caatinga.

Outrossim, Reis *et al.* (2019) utilizam o ELM para a estimativa da evapotranspiração de referência em região semiárida de Minas Gerais como ferramenta de estimação precisa das necessidades hídricas das culturas em propriedades irrigadas, bem como, facilitar o planejamento/gestão dos recursos hídricos e da produção agrícola em casos de indisponibilidade de dados meteorológicos.

A análise dos termos na literatura evidenciou diferentes compreensões atribuídas ao uso da IA, entre aquelas observadas pelos especialistas e aquelas observadas na literatura científica. Dadas as condições atuais, as perspectivas para a IA no agronegócio na Caatinga são um tanto incertas. Fatores como baixo uso de tecnologias na maior parte do bioma, pouca produtividade da terra e do trabalho tem resultado na depreciação da atividade agrícola (BRAINER, 2021; MATTOS *et al.*, 2020). A grande parte da força de trabalho rural vive em condições precárias, associadas a isso, a migração de trabalhadores mais capacitados para outras regiões ou centros urbanos regionais (ALENCAR *et al.*, 2021; MACIEL; MACIEL; GOMES, 2021). Mesmo assim, com o desenvolvimento de áreas e polos agrícolas de alto impacto, o agronegócio na caatinga tem gerado mudanças na perspectiva de adoção tecnológica na região e transformado áreas marginais semiáridas em locais de alto desenvolvimento agrícola (HAJI *et al.*, 2004; TEIXEIRA; BASTIAANSSEN, 2012; TEIXEIRA; BASTIAANSSEN; BASSOI, 2007).

No aspecto científico, os estudos ligados ao uso de IA em atividades agrícolas em regiões semiáridas tende a expansão, à medida que essa tecnologia é aplicada e difundida nessas regiões. A previsão do rendimento de plantas estratégicas como arroz, feijão e milho aliadas a vários fatores sazonais é um dos resultados possíveis desse desenvolvimento (SARANYA; NAGARAJAN, 2020). Com o conhecimento e as ferramentas certas é possível modificar indicadores como aumento da produtividade e a sustentabilidade dos recursos nessas terras (BAGHERZADEH *et al.*, 2016; ELBELTAGI *et al.*, 2020; ULLAH *et al.*, 2018). A aplicação de modelos de IA corrobora também para o planejamento e execução da atividade agrícola, nos diferentes níveis, sendo uma ferramenta eficiente e estratégica na tomada de decisão na produção rural, principalmente em períodos de escassez

ou baixa disponibilidade de recursos (GUIMARÃES *et al.*, 2018; KESHAVARZI *et al.*, 2016; NOURANI; ELKIRAN; ABDULLAHI, 2020; YU *et al.*, 2021). Por fim, o desenvolvimento dessa tecnologia infere a integração com outros fatores tecnológicos, de gestão e de meio ambiente. Integrar essas variáveis tende a possibilitar avanços na perspectiva da sustentabilidade na Caatinga.

4.4 CONCLUSÕES

Este artigo traz uma análise preditiva para o uso de IA no agronegócio na Caatinga, tendo por objetivo apresentar a visão de especialistas junto com a sistematização de pesquisas científicas que permitam delinear as perspectivas da aplicabilidade da ferramenta no bioma semiárido brasileiro. Os achados levam a compreender que a sociedade atravessa um momento em que as realidades sociais, políticas e econômicas estão mudando e que um crescente reconhecimento da responsabilidade coletiva pode ser apoiado pelas modernas tecnologias da informação. E que a aplicação da IA avança significativamente no campo da agricultura nos últimos anos.

No bioma, a IA já se faz presente em alguns estudos científicos, mas é notório a necessidade de expansão da temática, assim como deve ocorrer em outros locais semiáridos. Na perspectiva dos especialistas, a transformação digital tende a otimizar os processos desde a produção até o consumidor final, assim como contribuir para o uso mais eficiente dos recursos naturais na Caatinga. No entanto, ainda há etapas que devem ser superadas até a devida aplicação da IA no bioma como um todo. Para os especialistas, o local carece do abrandamento de barreiras estruturais.

Entre as barreiras citadas pelos especialistas para o desenvolvimento e adoção da IA na Caatinga, os fatores referem-se a à educação, habilidade para entender e manusear as ferramentas com IA. O baixo nível de escolaridade rural da força de trabalho disponível limita a difusão dessa tecnologia na atividade agrícola no semiárido. Essa barreira requer ações macroeconômicas relativas ao desenvolvimento de políticas públicas que melhorem o acesso à educação, além de treinamentos e cursos por empresas e/ou associações/cooperativas que fornecem esses serviços e produtos tecnológicos aos agricultores. Políticas públicas dessa natureza já foram vinculadas ao governo federal, mas a intensificação das práticas como sistemas de crédito, fortalecimento de cooperativas, industrialização e extensão rural vinculadas a pacotes tecnológicos faz-se necessário

(LINDOSO *et al.*, 2018). O cooperativismo, embora pouco difundido na região, apresenta impactos positivos e substanciais de assistência técnicas/financeira, bem como na integração com o mercado consumidor, como nos casos da pecuária de corte e produção de leite (MAIA *et al.*, 2018).

Outro fator, refere-se à falta de integração entre os diferentes sistemas dentro da cadeia de suprimentos. Essa barreira pode ser atenuada por meio de alianças estratégicas público-privado, com o intuito de fomentar o desenvolvimento de soluções inovadoras para problemas do agronegócio no bioma: inovação, empreendedorismo, infraestrutura de conectividade, comunicação e capacitação profissional (BOLFE *et al.*, 2020). Uma dessas iniciativas está sendo promovida pela Embrapa Agricultura Digital por meio da Agritech Semiárido, uma startup para promover mentorias e conexão com especialistas do agro, de tecnologia e de negócios que possibilitem uma conexão com os setores produtivos (MASSRUHÁ *et al.*, 2020).

A perspectiva da IA na Caatinga é atraente, mas os desafios anteriormente precisam ser abordados em vista de sua aplicação. E embora existam essas questões estruturais a serem resolvidas, em alguns núcleos ou áreas dentro do bioma já é possível intensificar as ações nessa vertente que podem servir mais tarde como indicadores para as demais áreas. Assim, para pesquisas futuras pode ser valioso o olhar para este assunto de uma perspectiva mais restritiva de inovação em setor ou em atividade específica. Contribui também para dar ideias a novos pesquisadores para expandir os estudos de IA associados aos ramos do agronegócio na Caatinga.

Agradecimento

O presente artigo foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

AGHAJANLOO, M. B.; SABZIPARVAR, A. A.; TALAEE, P. H. Artificial neural network–genetic algorithm for estimation of crop evapotranspiration in a semi-arid region of Iran. **Neural Computing and Applications**, v. 23, n. 5, p. 1387–1393, 20 out. 2013.

ALENCAR, P G et al. Semiárido piauiense: expansão da cajucultura e transformações no território. *Revista Geográfica de América Central*, v. 1, n. 68, p. 413-443, 2022.

ALZOUBI, I.; ALMALIKI, S.; MIRZAEI, F. Prediction of environmental indicators in land leveling using artificial intelligence techniques. **Chemical and Biological Technologies in Agriculture**, v. 6, n. 1, p. 4, 27 dez. 2019.

ANDRADE, E. M. et al. Water as Capital and Its Uses in the Caatinga. In: **Caatinga**. Cham: Springer International Publishing, 2017. p. 281–302.

AZADI, S.; SEPASKHAH, A. R. Annual precipitation forecast for west, southwest, and south provinces of Iran using artificial neural networks. **Theoretical and Applied Climatology**, v. 109, n. 1–2, p. 175–189, 24 jul. 2012.

BAGHERZADEH, A. et al. Land suitability modeling by parametric-based neural networks and fuzzy methods for soybean production in a semi-arid region. **Modeling Earth Systems and Environment**, v. 2, n. 2, p. 104, 16 jun. 2016.

BAYATVARKESHI, M. et al. A new wavelet conjunction approach for estimation of relative humidity: wavelet principal component analysis combined with ANN. **Neural Computing and Applications**, v. 32, n. 9, p. 4989–5000, 28 maio 2020.

BELAYNEH, A.; ADAMOWSKI, J.; KHALIL, B. Short-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet transforms and machine learning methods. **Sustainable Water Resources Management**, v. 2, n. 1, p. 87–101, 17 mar. 2016.

BILALI, A. EL; TALEB, A. Prediction of irrigation water quality parameters using machine learning models in a semi-arid environment. **Journal of the Saudi Society of Agricultural Sciences**, v. 19, n. 7, p. 439–451, out. 2020.

BOLFE, E. L. et al. Agricultura digital no Brasil: tendências, desafios e oportunidades: resultados de pesquisa online. **Campinas: Embrapa**, 2020.

BONACCORSI, M. et al. “HighChest”: An Augmented Freezer Designed for Smart Food Management and Promotion of Eco-Efficient Behaviour. **Sensors**, v. 17, n. 6, p. 1357, 11 jun. 2017.

BOUDIBI, S. et al. Spatial prediction and modeling of soil salinity using simple cokriging, artificial neural networks, and support vector machines in El Outaya plain, Biskra, southeastern Algeria. **Acta Geochimica**, v. 40, n. 3, p. 390–408, 7 jun. 2021.

BOURGUET, J.-R. et al. An artificial intelligence-based approach to deal with argumentation applied to food quality in a public health policy. **Expert Systems with Applications**, v. 40, n. 11, p. 4539–4546, set. 2013.

BUAINAIN, A. M. et al. **O mundo rural no Brasil do século 21: a formação de um novo padrão agrário e agrícola**. Brasília, DF: Embrapa, 2014., 2014.

BUAINAIN, A. M.; GARCIA, J. R. Pobreza rural e desenvolvimento do Semiárido Nordeste: resistência, reprodução e transformação. In: **A nova cara da pobreza rural**:

desenvolvimento e a questão regional. Brasília: IICA. Curitiba: IICA, 2013. p. 217–305.

BYAKATONDA, J.; PARIDA, B. P.; KENABATHO, P. K. Relating the dynamics of climatological and hydrological droughts in semiarid Botswana. **Physics and Chemistry of the Earth**, v. 105, n. February, p. 12–24, 2018.

CHANTRE, G. R. et al. A flexible and practical approach for real-time weed emergence prediction based on Artificial Neural Networks. **Biosystems Engineering**, v. 170, p. 51–60, jun. 2018.

CHEN, X.-W.; LIN, X. Big Data Deep Learning: Challenges and Perspectives. **IEEE Access**, v. 2, p. 514–525, 2014.

CHEN, Z. et al. Temporal convolution-network-based models for modeling maize evapotranspiration under mulched drip irrigation. **Computers and Electronics in Agriculture**, v. 169, p. 105206, fev. 2020.

CHITSAZAN, M.; RAHMANI, G.; NEYAMADPOUR, A. Forecasting groundwater level by artificial neural networks as an alternative approach to groundwater modeling. **Journal of the Geological Society of India**, v. 85, n. 1, p. 98–106, 30 jan. 2015.

COSTA, A. C. et al. Monthly and seasonal streamflow forecasting of large dryland catchments in Brazil. **Journal of Arid Land**, v. 13, n. 3, p. 205–223, 15 mar. 2021.

COUTO, A. A. et al. Land use changes associated with the expansion of sugar cane crops and their influences on soil removal in a tropical watershed in São Paulo State (Brazil). **CATENA**, v. 172, p. 313–323, jan. 2019.

DEO, R. C. et al. Forecasting effective drought index using a wavelet extreme learning machine (W-ELM) model. **Stochastic Environmental Research and Risk Assessment**, v. 31, n. 5, p. 1211–1240, 2017.

ELBELTAGI, A. et al. Modeling long-term dynamics of crop evapotranspiration using deep learning in a semi-arid environment. **Agricultural Water Management**, v. 241, n. March, p. 106334, 2020.

FENG, Z. Constructing rural e-commerce logistics model based on ant colony algorithm and artificial intelligence method. **Soft Computing**, v. 8, 2019.

FERNANDES, E. A. N. et al. Trace elements and machine learning for Brazilian beef traceability. **Food Chemistry**, v. 333, n. December 2019, p. 127462, 2020.

FERREIRA, L. B. et al. Generalizability of machine learning models and empirical equations for the estimation of reference evapotranspiration from temperature in a semiarid region. **Anais da Academia Brasileira de Ciências**, v. 93, n. 1, p. 1–15, 2021.

GARDAS, B. B. et al. A hybrid decision support system for analyzing challenges of the agricultural supply chain. **Sustainable Production and Consumption**, v. 18, p. 19–32, abr. 2019.

GUIMARÃES, B. V. C. et al. Prediction of “Gigante” cactus pear yield by morphological characters and artificial neural networks. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 22, n. 5, p. 315–319, maio 2018.

IBGE. Mapa de Biomas do Brasil. Escala 1:5.000. **Instituto Brasileiro de Geografia e Estatística (IBGE)**, 2004.

JABEEN, H.; TAHARA, N.; LEHMANN, J. EvoChef: Show Me What to Cook! Artificial Evolution of Culinary Arts. In: **International Conference on Computational Intelligence in Music, Sound, Art and Design (Part of EvoStar)**. Springer, Cham, 2019. p. 156-172.

KAPLAN, A.; HAENLEIN, M. Siri, Siri, in my hand: Who’s the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. **Business Horizons**, v. 62, n. 1, p. 15–25, 2019.

KESHAVARZI, A. et al. Modeling of soil exchangeable sodium percentage using easily obtained indices and artificial intelligence-based models. **Modeling Earth Systems and Environment**, v. 2, n. 3, p. 1–10, 2016.

KIM, T.-W.; VALDÉS, J. B. Nonlinear Model for Drought Forecasting Based on a Conjunction of Wavelet Transforms and Neural Networks. **Journal of Hydrologic Engineering**, v. 8, n. 6, p. 319–328, nov. 2003.

LAQUI, W. et al. Can artificial neural networks estimate potential evapotranspiration in Peruvian highlands? **Modeling Earth Systems and Environment**, v. 5, n. 4, p. 1911–1924, 2019.

LEHMANN, R. J.; REICHE, R.; SCHIEFER, G. Future internet and the agri-food sector: State-of-the-art in literature and research. **Computers and Electronics in Agriculture**, v. 89, p. 158–174, nov. 2012.

LIBERATI, A. et al. The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: explanation and elaboration. **PLoS medicine**, v. 6, n. 7, 2009.

LINDOSO, D. et al. Harvesting Water for Living with Drought: Insights from the Brazilian Human Coexistence with Semi-Aridity Approach towards Achieving the Sustainable Development Goals. **Sustainability**, v. 10, n. 3, p. 622, 28 fev. 2018.

MAIA, A. G. et al. Climate change and farm-level adaptation: the Brazilian Sertão. **International Journal of Climate Change Strategies and Management**, v. 10, n. 5, p. 729–751, 2018.

MACIEL, H. M.; MACIEL, W. M.; GOMES, M. A. A desertificação e a seca: efeitos sobre a produção e renda agrícolas no estado do Ceará. **Brazilian Journal of Development**, v. 7, n. 2, p. 17824-17843, 2021.

MARENGO, J. A.; TORRES, R. R.; ALVES, L. M. Drought in Northeast Brazil—past,

present, and future. **Theoretical and Applied Climatology**, v. 129, n. 3–4, p. 1189–1200, 9 ago. 2017.

MARTINS, M. A. et al. Improving drought management in the Brazilian semiarid through crop forecasting. **Agricultural Systems**, v. 160, p. 21–30, fev. 2018.

MASON, M. **Sample size and saturation in PhD studies using qualitative interviews**. Forum qualitative Sozialforschung/Forum: qualitative social research. **Anais...2010**

MASSRUHÁ, S. M. F. et al. **Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas**. Brasília: Embrapa, 2020.

MATTOS, L. C. et al. A saga do algodão no semiárido nordestino: histórico, declínio e as perspectivas de base agroecológica. **Desenvolvimento e Meio Ambiente**, v. 55, 2020.

MIRABELLI, G.; SOLINA, V. Blockchain and agricultural supply chains traceability: research trends and future challenges. **Procedia Manufacturing**, v. 42, p. 414–421, 2020.

MISHRA, A. K.; DESAI, V. R. Drought forecasting using stochastic models. **Stochastic Environmental Research and Risk Assessment**, v. 19, n. 5, p. 326–339, 21 nov. 2005.

MISHRA, D.; SATAPATHY, S. Reliability and maintenance of agricultural machinery by MCDM approach. **International Journal of System Assurance Engineering and Management**, 21 ago. 2021.

MMA. **Biomass/Caatinga**. Disponível em:

<<https://www.mma.gov.br/biomass/caatinga.html>>. Acesso em: 9 set. 2020.

MONTEIRO JUNIOR, J. J. et al. Dynamical spatial modeling to simulate the forest scenario in Brazilian dry forest landscapes. **Geology, Ecology, and Landscapes**, v. 3, n. 1, p. 46–52, 2 jan. 2019.

NOURANI, V.; ELKIRAN, G.; ABDULLAHI, J. Multi-step ahead modeling of reference evapotranspiration using a multi-model approach. **Journal of Hydrology**, v. 581, p. 124434, 2020.

NOZARI, H.; AZADI, S. Experimental evaluation of artificial neural network for predicting drainage water and groundwater salinity at various drain depths and spacing. **Neural Computing and Applications**, v. 31, n. 4, p. 1227–1236, 2019.

OLIVEIRA, D. A. B. et al. A review of deep learning algorithms for computer vision systems in livestock. **Livestock Science**, v. 253, p. 104700, nov. 2021.

OLIVEIRA, T. J. A.; RODRIGUES, W. A difusão do agronegócio nos cerrados do centro norte brasileiro e nas áreas irrigadas da caatinga nordestina. **Revista em Agronegócio e Meio Ambiente**, v. 13, n. 2, p. 525–546, 11 abr. 2020.

PI, E. et al. Application of Genetic Algorithm to Predict Optimal Sowing Region and Timing for Kentucky Bluegrass in China. **PLOS ONE**, v. 10, n. 7, p. e0131489, 8 jul. 2015.

PINI, A. et al. **AI Inspired Recipes: Designing Computationally Creative Food Combos**. Extended Abstracts of the 2019 CHI Conference on Human Factors in Computing Systems. **Anais...**New York, NY, USA: ACM, 2 maio 2019Disponível em: <<https://dl.acm.org/doi/10.1145/3290607.3312948>>

POURSAEID, M. et al. Modelling qualitative and quantitative parameters of groundwater using a new wavelet conjunction heuristic method: wavelet extreme learning machine versus wavelet neural networks. **Water and Environment Journal**, v. 35, n. 1, p. 67–83, 14 fev. 2021.

QUEIROZ, M. A. et al. Plant breeding in the semiarid region of Brazil: examples of success. **Crop Breeding and Applied Biotechnology**, v. 12, n. spe, p. 57–66, dez. 2012.

REIS, M. M. et al. Empirical and learning machine approaches to estimating reference evapotranspiration based on temperature data. **Computers and Electronics in Agriculture**, v. 165, n. April, p. 104937, out. 2019.

ROSEGRANT, M. W.; CAI, X. Global Water Demand and Supply Projections. **Water International**, v. 27, n. 2, p. 170–182, jun. 2009.

RUPNIK, R. et al. AgroDSS: A decision support system for agriculture and farming. **Computers and Electronics in Agriculture**, v. 161, p. 260–271, jun. 2019.

SARAIVA, M. et al. Automatic Mapping of Center Pivot Irrigation Systems from Satellite Images Using Deep Learning. **Remote Sensing**, v. 12, n. 3, p. 558, 7 fev. 2020.

SARANYA, C. P.; NAGARAJAN, N. Efficient agricultural yield prediction using metaheuristic optimized artificial neural network using Hadoop framework. **Soft Computing**, v. 24, n. 16, p. 12659–12669, 2020.

SARWAR, A.; PETERS, R. T.; MOHAMED, A. Z. Linear mixed modeling and artificial neural network techniques for predicting wind drift and evaporation losses under moving sprinkler irrigation systems. **Irrigation Science**, v. 38, n. 2, p. 177–188, 2020.

SHARMA, G.; SINGH, A.; JAIN, S. A hybrid deep neural network approach to estimate reference evapotranspiration using limited climate data. **Neural Computing and Applications**, 12 nov. 2021.

SHIRI, J. et al. Comparison of heuristic and empirical approaches for estimating reference evapotranspiration from limited inputs in Iran. **Computers and Electronics in Agriculture**, v. 108, p. 230–241, 2014.

SHU, L. H. et al. Design for reduced resource consumption during the use phase of products. **CIRP Annals**, v. 66, n. 2, p. 635–658, 2017.

SILVA, J. L. B. et al. Changes in the water resources, soil use and spatial dynamics of Caatinga vegetation cover over semiarid region of the Brazilian Northeast. **Remote Sensing Applications: Society and Environment**, v. 20, n. July, p. 100372, nov. 2020a.

- SILVA, K. A. et al. Soil sampling optimization using spatial analysis in irrigated mango fields under brazilian semi-arid conditions. **Revista Brasileira de Fruticultura**, v. 42, n. 5, p. 1–18, 2020b.
- SILVA, L. P. et al. Modeling land cover change based on an artificial neural network for a semiarid river basin in northeastern Brazil. **Global Ecology and Conservation**, v. 21, p. e00811, mar. 2020c.
- SILVA, J. M. C. DA et al. The Caatinga: Understanding the Challenges. In: **Caatinga**. Cham: Springer International Publishing, 2017. p. 3–19.
- SILVA, M. V et al. Pilot monitoring of caatinga spatial-temporal dynamics through the action of agriculture and livestock in the brazilian semiarid. **Remote Sensing Applications: Society and Environment**, v. 19, n. July, 2020d.
- SOUSA, B. F. S. et al. Avaliação de classificadores baseados em aprendizado de máquina para a classificação do uso e cobertura da terra no bioma Caatinga. **Revista Brasileira de Cartografia**, v. 62, 2013.
- TABARI, H.; TALAEI, P. H.; WILLEMS, P. Short-term forecasting of soil temperature using artificial neural network. **Meteorological Applications**, v. 22, n. 3, p. 576–585, jul. 2015.
- ULLAH, A. et al. Prediction of effective climate change indicators using statistical downscaling approach and impact assessment on pearl millet (*Pennisetum glaucum* L.) yield through Genetic Algorithm in Punjab, Pakistan. **Ecological Indicators**, v. 90, n. April, p. 569–576, 2018.
- VASILOGLOU, M. et al. A Comparative Study on Carbohydrate Estimation: GoCARB vs. Dietitians. **Nutrients**, v. 10, n. 6, p. 741, 7 jun. 2018.
- VERGARA, S. C. **Projetos e relatórios de pesquisa em administração**. São Paulo: Editora Atlas SA, 2013.
- VIJAYALAKSHMI, J.; PANDIMEENA, K. Agriculture talkbot using AI. **International Journal of Recent Technology and Engineering**, v. 8, n. 2 Special Issue 5, p. 186–190, 2019.
- WANG, T. et al. A bayesian framework for learning rule sets for interpretable classification. **The Journal of Machine Learning Research**, v. 18, n. 1, p. 2357–2393, 2017.
- YASEEN, Z. M. et al. Artificial intelligence based models for stream-flow forecasting: 2000–2015. **Journal of Hydrology**, v. 530, p. 829–844, nov. 2015.
- YASEEN, Z. M. et al. Stream-flow forecasting using extreme learning machines: A case study in a semi-arid region in Iraq. **Journal of Hydrology**, v. 542, p. 603–614, 2016.

YIN, R. K. **Estudo de Caso: Planejamento e Métodos**. Rio de Janeiro: Bookman editora, 2015.

YU, H. et al. Uncertainty analysis of artificial intelligence modeling daily reference evapotranspiration in the northwest end of China. **Computers and Electronics in Agriculture**, v. 176, n. May, p. 105653, set. 2020.

YU, Y. et al. Spatiotemporal changes in water, land use, and ecosystem services in Central Asia considering climate changes and human activities. **Journal of Arid Land**, v. 13, n. 9, p. 881–890, 2021.

ZARE, M.; KOCH, M. Hybrid signal processing/machine learning and PSO optimization model for conjunctive management of surface–groundwater resources. **Neural Computing and Applications**, v. 33, n. 13, p. 8067–8088, 2021.

5 CONSIDERAÇÕES FINAIS

Esta seção compreende as considerações gerais dos três capítulos, em uma espécie de síntese desse manuscrito. O primeiro capítulo correspondeu ao levantamento do uso de Inteligência Artificial na atividade agrícola. Nele foram identificadas as ramificações da IA e sua aplicabilidade. Os resultados apresentaram, por exemplo, o uso de Visão de Máquina através de Sistema Agrícola Virtual, SVM e ELM na detecção precoce do patógeno de pragas e doenças; FIS e MLP para a exploração de culturas; propagação reversa para monitoramento dos limites da fazenda; ANN e MFNN para análise de estruturas de irrigação; e Árvore da Decisão e TDNN para a vigilância do rebanho com os dispositivos integrados no sistema de produção agrícola. Assim como, a adoção de métodos de IA na pecuária demonstraram seu potencial por meio das previsões em tempo real da saúde, bem-estar, nutrição e reprodução em nível individual e de grupo. Esses métodos podem ser bem mais eficazes se integrados a um sistema de informação geral, constituído por ações que podem ser geridas pelo proprietário agrícola.

Ao aplicar os métodos da IA no meio agrícola, os estudos apontaram para a perspectiva de os sistemas das fazendas passarem a oferecer recomendações e insights mais ricos para a tomada de decisões e melhoria das etapas da cadeia de suprimentos agrícola. Essa relação forma um registro automatizado de dados, análise, implementação e gestão agrícola baseada no conhecimento. Para esse escopo, espera-se que o uso dos métodos de IA seja ainda mais difundido, permitindo a integração dos métodos. Avanços no aprendizado de máquina; robótica; visão computacional; processamento de linguagem natural; planejamento, programação e otimização; sistemas especialistas; e fala - tendem a permitir um maior desenvolvimento e a implementação de sistemas tecnológicos inteligentes no meio rural. Capaz de fornecer, quando são integrados, as informações efetivas e eficientes da atividade, em vistas de atender à crescente demanda por alimentos - fator este, vital para a prosperidade econômica do setor agrícola e segurança alimentar. E a iniciativa de utilizar essas tecnologias para converter os dados precisos em conhecimento para apoiar e impulsionar a complexa tomada de decisões na fazenda e ao longo da cadeia de valor permitirá mudança significativas desde a agricultura de precisão até a agricultura de decisão. O gerenciamento e a tomada de decisão se tornarão cada vez mais precisos; otimizando a lucratividade, a produtividade e a sustentabilidade por meio da compreensão do conjunto de dados.

O segundo capítulo tratou da descrição das tecnologias agrícolas utilizadas na Caatinga: tecnologias e técnicas sociais. Os resultados apresentam inicialmente as tecnologias de convivência com o semiárido ou técnicas sociais, com destaque para os métodos de manejo do solo, aproveitamento da água da chuva e preparo de ração animal. Já em relação às tecnologias propriamente ditas, as evidências convergem para a utilização tecnológica direcionada à viabilidade da produção, diversificação e tempo de colheita principalmente de culturas irrigadas. Outrossim, o melhoramento genético também contribuiu para a propagação de culturas resistentes e para o aumento da população de animais. Ao mesmo tempo que foi possível identificar o nível tecnológico da atividade agrícola na Caatinga, a qual, na maior parte do bioma, apresenta baixo uso de tecnologias caracterizado por atividades de subsistência, mão de obra familiar e monocultura, por outro lado, em polos locais agrícolas ocorre a utilização de sistemas integrados e agropecuária de base biológica.

Certamente, a busca por alternativas no bioma passa por avanços científicos e tecnológicos de desenvolvimento de plantas com resistência aos principais estresses climáticos e biológicos, como também melhorias na produtividade da cultura e qualidade da matéria prima, das sementes, dos frutos e dos pseudofrutos (FOLHES; RENNÓ; SOARES, 2009; QUEIROZ *et al.*, 2012; SANTOS *et al.*, 2020). Algo que requer tempo para gerar resultados expressivos, como o melhoramento do feijão comum, do algodão, do caju ou da uva; a continuidade desses programas com mais de três décadas tem proporcionado resultados como no caso do algodão naturalmente colorido, uma reedição da significativa cadeia produtiva para a economia paraibana pela geração de emprego e o fortalecimento da indústria têxtil (QUEIROZ *et al.*, 2012). Outrossim, o melhoramento genético também contribuiu para o aumento da população de animais na pecuária, fato pouco citado nos artigos, mas que teve influência na indústria da pecuária leiteira e de frangos (ANDRADE *et al.*, 2019; CARVALHO *et al.*, 2019). Nisso, as instituições de pesquisa como Embrapa, os institutos agrônômicos estaduais e as universidades têm fomentado o desenvolvimento de produtos geneticamente modificados por meio de pesquisas contextuais para o semiárido (BURNEY *et al.*, 2014).

O terceiro capítulo trata de uma análise preditiva para o uso da IA no agronegócio na Caatinga. Os resultados obtidos nessa fase do estudo permitem inferir que a adoção e o desenvolvimento de IA na agricultura brasileira ainda se encontram em fase inicial, com agentes buscando conhecer as oportunidades dessa ferramenta para os negócios no setor

agrícola. E que o fornecimento e desenvolvimento de ferramentas IA estão atualmente concentrados em máquinas e equipamentos, tendo as instituições de pesquisa o papel de desenvolvimento e implantação dos protótipos em áreas integradas como os CPAs. Esses centros se dedicaram ao desenvolvimento de pesquisas científicas, tecnológicas e de inovação para a resolução de problemas por meio de IA (MASSRUHÁ *et al.*, 2020). Na Caatinga, os estudos são bem reduzidos, sendo notório a necessidade de expansão da temática, assim como deve ocorrer em outros locais semiáridos.

A necessidade fundamentada no conhecimento reflete uma demanda local por uma agenda de pesquisa e produção em diversos setores agrícolas pela inserção da temática da inovação (SANTOS *et al.*, 2017). Os fatores como eficiência, qualidade ambiental, conservação, qualidade do produto, capital social, e o bem-estar e saúde animal refletem exemplos de carências para o uso de ferramentas técnicas e tecnológicas (BARRETO *et al.*, 2010). Assim como, para suprir o déficit por demanda de mão de obra de prestadores de serviços agrícolas ou para reparar a deficiência na infraestrutura local e a dificuldade no acesso a mercados (BURNEY *et al.*, 2014; SILVA *et al.*, 2019).

A compreensão da perspectiva para o uso da IA no agronegócio na Caatinga é atraente, mas os desafios acima precisam ser abordados para aumentar a aceitação de aplicações da IA. Assim, há etapas que devem ser superadas até a devida aplicação da IA no bioma, de modo que o local carece do abrandamento de barreiras estruturais. Fatores como baixo uso de tecnologias na maior parte do bioma, pouca produtividade da terra e do trabalho tem resultado na depreciação da atividade agrícola (BRAINER, 2021; MATTOS *et al.*, 2020). Alinhado a esses fatores, deve-se considerar ainda os desafios: econômicos e sociais como custos das tecnologias digitais, conectividade no campo, sucessão familiar rural, desenvolvimento rural sustentável; científicos e tecnológicos como serviços digitais *online*, gestão e monitoramento da produção animal e vegetal, gerenciamento das bases de dados da atividade agrícola. Objetivando alcançar as oportunidades e tendências como mercado consumidor na era digital, plataformas digitais e multiverso, sistemas de cenários de riscos futuros, rastreabilidade e certificações, capacitações em agricultura digital e autônomas, tecnologias digitais disruptivas, e sociedade 5.0.

As práticas agrícolas têm sido modificadas nas últimas décadas com o desenvolvimento de novas tecnologias capazes de impulsionar a produção de alimentos, mesmo na Caatinga. Com base nas descobertas, a atividade agrícola na Caatinga ainda se encontra nos estágios de desenvolvimento da segunda e terceira revoluções agrícola. Isso

levando em consideração a baixa quantidade de estudos disponíveis sobre o uso de tecnologias no meio agrícola na Caatinga. Porém, as crescentes preocupações do público com o consumo de alimentos baseados numa interação dinâmica humano-natureza podem impulsionar as tendências para o uso de tecnologias inteligentes. A aplicação dessas não necessita estar estritamente associada à produção primária, mas em toda a cadeia de abastecimento. Assim, as tratativas para a utilização de tecnologias inteligentes e Inteligência Artificial, quarta e quinta revolução agrícola respectivamente, são atraentes, porém, os desafios técnicos e de gestão certamente precisam ser superados ao se projetar estratégias para avolumar o uso dessas tecnologias na Caatinga.

Um ponto a destacar é a necessidade do fortalecimento das ATER's estaduais - a maioria dos estados do Nordeste possuem ações que se encontram sucateadas (SILVA *et al.*, 2019), uma vez que são elas as responsáveis principais no auxílio dos produtores na profissionalização das atividades (ANDRIEU; NOGUEIRA, 2010). A assistência técnica tende também a contribuir para a modernização tecnológica em vista à superação de gargalos competitivos da agropecuária (SILVA *et al.*, 2019). Mesmo que a falta de tecnificação não seja o único empecilho na atividade, o maior conhecimento e controle de qualidade na pecuária leiteira ou mesmo melhor aproveitamento da área total da propriedade para a pecuária de corte também são problemas a serem sanados (VASCONCELOS *et al.*, 2018). Na produção animal, há ainda a necessidade de alinhamento às estratégias de convivência com o semiárido, já que ocorre de forma paralela à exploração da agricultura de sequeiro (SILVA *et al.*, 2020). Ao passo que também deve ser fomentado o fortalecimento de instituições como as cooperativas - pouco difundidas na região - e as agroindústrias que propende a valorização da industrialização da produção da agrícola familiar (LINDOSO *et al.*, 2018; OLIVEIRA; RODRIGUES, 2020).

Prevê-se que o impacto das mudanças climática ultrapasse as fronteiras das culturas, sistemas de cultivo, rotações e biota, afetando com isso os fatores econômicas, sociais, culturais e principalmente ambientais. De modo que a manutenção do equilíbrio no sistema passa pela imprescindibilidade de novos conhecimentos, políticas alternativas e mudanças socioambientais. Assim, no enfrentamento dos desafios faz-se necessário novos paradigmas na pesquisa agrícola e na transferência tecnológica que faça uso da ciência e tecnologias modernas como IA em conjunto com o conhecimento tradicional (técnicas sociais). Mas, isso exige mais investimento por parte do poder público e apoio das organizações de fomento a sustentabilidade na Caatinga, em vistas, de ancorar as pesquisas integradas e os esforços

de desenvolvimento sustentável com a participação da comunidade local. Já que essa abordagem pode permitir que as comunidades das áreas de sequeiro usem os recursos naturais na perspectiva de convivência com o semiárido.

Os desafios da agricultura exigem amplas alternativas por meio de tecnologias disruptivas; e novas tendências permitem abordar várias soluções. No geral, este estudo contribui para a propagação de pesquisas que estão sendo realizadas em torno do agronegócio na Caatinga e da agricultura 5.0. As limitações desta pesquisa passam por pontos como as bases de artigos online apresentam os estudos e descobertas a serem analisadas sob a ótica dos autores, a compreensão por meio de outras questões podem gerar outros resultados. Já em relação as entrevistas realizadas com uma quantidade maior de pesquisadores tendem a gerar mais informações inovativas das atividades de produção e de serviços. Em ambos os casos, é provável que as novas descobertas complementem esse estudo. Para trabalhos futuros, os bancos de dados e aspectos de pesquisa adicionais devem ser considerados especificadas para fornecer uma visão holística de aplicação e difusão da IA no agronegócio na Caatinga.

REFERÊNCIAS

- AGHAJANLOO, M. B.; SABZIPARVAR, A. A.; TALAEE, P. H. Artificial neural network–genetic algorithm for estimation of crop evapotranspiration in a semi-arid region of Iran. **Neural Computing and Applications**, London, v. 23, n. 5, p. 1387–1393, 2013. Disponível em: <http://link.springer.com/10.1007/s00521-012-1087-y>. Acesso em: 12 dez. 2021.
- AHMAD, U. *et al.* Technology and data fusion methods to enhance site-specific crop monitoring. **Agronomy**, Basel, v. 12, n. 3, [art.] 555, 2022. Disponível em: <https://www.mdpi.com/2073-4395/12/3/555>. Acesso em: 28 nov. 2021.
- ALAGHA, J. S. *et al.* Integrating an artificial intelligence approach with k-means clustering to model groundwater salinity: the case of Gaza coastal aquifer (Palestine). **Hydrogeology Journal**, Berlin, v. 25, n. 8, p. 2347–2361, 2017.
- ALBIERO, D. *et al.* Wind turbine for family farming in semi-arid areas with technological innovations for low wind speeds. **Revista Ciência Agronômica**, Fortaleza, v. 45, n. 1, p. 186–196, 2014.
- ALENCAR, P. G. *et al.* Semiárido piauiense: expansão da cajucultura e transformações no território. **Revista Geográfica de América Central**, Heredia, v. 1, n. 68, p. 413–443, 2021. Disponível em: <https://www.revistas.una.ac.cr/index.php/geografica/article/view/14674>. Acesso em: 10 jul. 2021.
- ALTHOFF, K. D. German journal on artificial intelligence. **KI - Künstliche Intelligenz**, Munchen, v. 27, n. 2, p. 89–91, 2013. Disponível em: <http://link.springer.com/10.1007/s13218-013-0251-6>. Acesso em: 10 out 2021.
- ALWIS, S. *et al.* A survey on smart farming data, applications and techniques. **Computers in Industry**, Amsterdam, v. 138, [art.] 103624, 2022. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0166361522000197>. Acesso em: 28 nov. 2021.
- ALZOUBI, I.; ALMALIKI, S.; MIRZAEI, F. Prediction of environmental indicators in land leveling using artificial intelligence techniques. **Chemical and Biological Technologies in Agriculture**, Heidelberg, v. 6, [art.] 4, 2019. Disponível em: <https://doi.org/10.1186/s40538-019-0142-7>. Acesso em: 28 nov. 2021.
- ALZU'BI, S. *et al.* An efficient employment of internet of multimedia things in smart and future agriculture. **Multimedia Tools and Applications**, Ancara, v. 78, n. 20, p. 29581–29605, 2019.
- AMPATZIDIS, Y.; BELLIS, L.; LUVISI, A. Pathology: robotic applications and management of plants and plant diseases. **Sustainability**, Basel, v. 9, n. 6, p. 1–14, 2017.
- ANDRADE, F. N. *et al.* Composição florística e estrutural de uma área de transição entre

cerrado e caatinga em assentamento rural no município de Milton Brandão-PI, Brasil. **Scientia Forestalis**, Piracicaba, v. 47, n. 122, p. 203–215, 2019. Disponível em: <http://www.ipef.br/publicacoes/scientia/leitura.asp?Article=04&Number=122>. Acesso em: 10 jul. 2021.

ANDRADE, C. W. L. *et al.* Soil moisture and discharge modeling in a representative watershed in northeastern Brazil using SWAT. **Ecohydrology and Hydrobiology**, Wrocław, v. 19, n. 2, p. 238–251, 2019.

ANDRADE, E. M. *et al.* Water as capital and its uses in the caatinga. In: SILVA, J. M. C.; LEAL, I. R.; TABARELLI, M. (ed.). **Caatinga**. Cham: Springer, 2017. p. 281–302. *E-book*. Disponível em: http://link.springer.com/10.1007/978-3-319-68339-3_10. Acesso em: 11 jul. 2021.

ANDRIEU, N.; NOGUEIRA, D. M. Modeling biomass flows at the farm level: a discussion support tool for farmers. **Agronomy for Sustainable Development**, Les Ulis, v. 30, n. 2, p. 505–513, 2010. Disponível em: <http://link.springer.com/10.1051/agro/2009047>. Acesso em: 15 set. 2021.

ANDRITOIU, D. *et al.* Agriculture autonomous monitoring and decisional mechatronic system. In: INTERNATIONAL CARPATHIAN CONTROL CONFERENCE – ICC, 19., 2018, Szilvásvárad, Hungary. **Proceedings of the [...]**. Piscataway: IEEE, 2018. p. 241–246.

ARAÚJO FILHO, J. A. **Manejo pastoril sustentável da caatinga**. Recife: Projeto Dom Helder Camara, 2013.

ATWELL, M. A.; WUDDIVIRA, M. N. Soil organic carbon characterization in a tropical ecosystem under different land uses using proximal soil sensing technique. **Archives of Agronomy and Soil Science**, Berlin, v. 68, n. 3, p. 297–310, 2022. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/03650340.2020.1831693>. Acesso em: 22 dez. 2021.

AZADI, S.; SEPASKHAH, A. R. Annual precipitation forecast for west, southwest, and south provinces of Iran using artificial neural networks. **Theoretical and Applied Climatology**, Wien, v. 109, n. 1/2, p. 175–189, 2012. Disponível em: <http://link.springer.com/10.1007/s00704-011-0575-9>. Acesso em: 14 set. 2021.

BAGHERZADEH, A. *et al.* Land suitability modeling by parametric-based neural networks and fuzzy methods for soybean production in a semi-arid region. **Modeling Earth Systems and Environment**, Berlin, v. 2, n. 2, [art.] 104, 2016. Disponível em: <http://link.springer.com/10.1007/s40808-016-0152-4>. Acesso em: 12 set. 2021.

BALAN, K. C. S. Robotic-based agriculture for rural renaissance: drones and biosensors. **Comprehensive Analytical Chemistry**, Amsterdam, v. 74, p. 363–375, 2016. Disponível em: <http://dx.doi.org/10.1016/bs.coac.2016.04.017>. Acesso em: 14 out. 2021.

BARACUHY, J. G. V; FURTADO, D. A.; FRANCISCO, P. R. M. **Tecnologias de convivência com o semiárido brasileiro**. Campina Grande: EDUFPG, 2017.

BARBOSA, A. C. B. *et al.* Genetic improvement of Nellore cattle in the semi-arid region of northeastern Brazil. **Acta Scientiarum. Animal Sciences**, Maringá, v. 37, n. 4, p. 429-435, 2015.

BARRETO, H. F. M. *et al.* Impactos ambientais do manejo agroecológico da caatinga no Rio Grande do Norte. **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 45, n. 10, p. 1073–1081, 2010. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-204X2010001000004&lng=pt&tlng=pt. Acesso em: 14 dez. 2021.

BARROS, M. A. L. *et al.* A review on evolution of cotton in Brazil: GM, white, and colored cultivars. **Journal of Natural Fibers**, New York, v. 19, n. 1, p. 209-221, 2022. Disponível em: <https://doi.org/10.1080/15440478.2020.1738306>. Acesso em: 12 fev. 2022.

BAYATVARKESHI, M. *et al.* A new wavelet conjunction approach for estimation of relative humidity: wavelet principal component analysis combined with ANN. **Neural Computing and Applications**, London, v. 32, n. 9, p. 4989–5000, 2020. Disponível em: <http://link.springer.com/10.1007/s00521-018-3916-0>. Acesso em: 19 jun. 2021.

BAYINDIR, L. A review of swarm robotics tasks. **Neurocomputing**, Oxford, v. 172, p. 292–321, 2016.

BELAYNEH, A.; ADAMOWSKI, J.; KHALIL, B. Short-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet transforms and machine learning methods. **Sustainable Water Resources Management**, Berlin, v. 2, n. 1, p. 87–101, 2016. Disponível em: <http://link.springer.com/10.1007/s40899-015-0040-5>. Acesso em: 14 set. 2021.

BENTHAM, M. J. Farm smart 2000: a multi-agent decision support system for crop production. *In: INTERNATIONAL CONFERENCE ON COMPUTERS IN AGRICULTURE, 7.*, 1998, Hong Kong. **Proceedings of the [...]**. St. Joseph, Mich.: American Society of Agricultural Engineers, 1998. p. 469–479.

BERMEO-ALMEIDA, O. B. *et al.* Blockchain in agriculture: a systematic literature review. *In: VALENCIA-GARCÍA, R. et al.* (ed). **Technologies and innovation: 4th International Conference, CITI 2018**, Guayaquil, Ecuador, November 6-9, 2018, Proceedings. Cham: Springer, 2018. p. 44–56. Disponível em: <http://link.springer.com/10.1007/978-3-319-67283-0>. Acesso em: 11 dez. 2022.

BHAGAT, B.; BARUAH, P.; MUKHERJEE, K. Application of nanosensors in food inspection. *In: DENIZLI, A. et al.* (ed.). **Nanosensors for smart agriculture: micro and nano technologies**. Amsterdam: Elsevier, 2022. p. 705–735. *E-book*. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/B9780128245545000306>. Acesso em: 27 set. 2021.

BILALI, A. El; TALEB, A. Prediction of irrigation water quality parameters using machine learning models in a semi-arid environment. **Journal of the Saudi Society of Agricultural Sciences**, Amsterdam, v. 19, n. 7, p. 439–451, 2020. Disponível em:

<https://linkinghub.elsevier.com/retrieve/pii/S1658077X20300503>. Acesso em: 13 nov. 2021.

BITTAR, R. D.; ALVES, S. M. F.; MELO, F. R. Estimation of physical and chemical soil properties by artificial neural networks. **Revista Caatinga**, Mossoró, v. 31, n. 3, p. 704–712, 2018.

BOLFE, E. L. *et al.* **Agricultura digital no Brasil: tendências, desafios e oportunidades: resultados de pesquisa online**. Campinas: Embrapa, 2020.

BONACCORSI, M. *et al.* “HighChest”: an augmented freezer designed for smart food management and promotion of eco-efficient behaviour. **Sensors**, Basel, v. 17, n. 6, [art.] 1357, 2017. Disponível em: <http://www.mdpi.com/1424-8220/17/6/1357>. Acesso em: 14 abr. 2020.

BONIECKI, P. *et al.* Detection of the granary weevil based on X-ray images of damaged wheat kernels. **Journal of Stored Products Research**, Oxford, v. 56, p. 38–42, 2014. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0022474X13000829>. Acesso em: 10 fev. 2021.

BOUDIBI, S. *et al.* Spatial prediction and modeling of soil salinity using simple cokriging, artificial neural networks, and support vector machines in El Outaya plain, Biskra, southeastern Algeria. **Acta Geochimica**, Beijing, v. 40, n. 3, p. 390–408, 2021. Disponível em: <https://link.springer.com/10.1007/s11631-020-00444-0>. Acesso em: 27 dez. 2021.

BOURGUET, J.-R. *et al.* An artificial intelligence-based approach to deal with argumentation applied to food quality in a public health policy. **Expert Systems with Applications**, Oxford, v. 40, n. 11, p. 4539–4546, 2013. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0957417413000912>. Acesso em: 14 fev. 2022.

BRAINER, M. S. C. P. Silvicultura. **Caderno Setorial Etene/Banco do Nordeste**, [Fortaleza], v. 154, n. 6, p. 1–11, 2021.

BRASIL. Ministério da Integração Nacional. Gabinete do Ministro. Superintendência do Desenvolvimento do Nordeste (SUDENE). Resolução N^o 115 de 23 de Novembro de 2017. Aprova a Proposição n^o 113/2017, que acrescenta municípios a relação aprovada pela Resolução CONDEL n^o 107, e 27 de julho de 2017. **Diário Oficial da União: Seção 1**, Brasília, DF, n. 232, p. 26-34, 5 dez. 2017a. Disponível em: https://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/739568/do1-2017-12-05-resolucao-n-115-de-23-de-novembro-de-2017-739564. Acesso em: 20 fev. 2022.

BRASIL. Ministério da Integração Nacional. Superintendência do Desenvolvimento do Nordeste. Conselho Deliberativo. Resolução N^o 107, de 27 de julho de 2017. Estabelece critérios técnicos e científicos para a delimitação do Semiárido Brasileiro e procedimentos para revisão de sua abrangência. **Diário Oficial da União: Seção 1**, Brasília, DF, n. 176, p. 48, 13 set. 2017b. Disponível em: https://www.in.gov.br/materia/-/asset_publisher/Kujrw0TZC2Mb/content/id/19287874/do1-2017-09-13-resolucao-n-107-de-27-de-julho-de-2017-19287788. Acesso em: 19 fev. 2022.

BRASIL. Ministério do Meio Ambiente. **Caatinga**. Brasília, DF: MMA, 2019. Disponível em: <https://www.antigo.mma.gov.br/biomas/caatinga.html>. Acesso em: 9 set. 2020.

BRONSON, K.; KNEZEVIC, I. Big Data in food and agriculture. **Big Data & Society**, London, v. 3, n. 1, 2016. Disponível em: <https://doi.org/10.1177/2053951716648174>. Acesso em: 11 set. 2021.

BUAINAIN, A. M.; GARCIA, J. R. Pobreza rural e desenvolvimento do semiárido nordestino: resistência, reprodução e transformação. *In*: BUAINAIN, A. M.; DEDECCA, C. (ed.). **A nova cara da pobreza rural: desenvolvimento e a questão regional**. Brasília, DF: IICA, 2013. p. 217–305.

BU, F.; WANG, X. A smart agriculture IoT system based on deep reinforcement learning. **Future Generation Computer Systems**, New York, v. 99, p. 500–507, 2019. Disponível em: <https://doi.org/10.1016/j.future.2019.04.041>. Acesso em: 22 dez. 2021.

BUGHIN, J. *et al.* Notes from the AI frontier: modeling the global economic impact of AI. **McKinsey Global Institute**, New York, p. 1–64, 4 Sept. 2018. Disponível em: <https://www.mckinsey.com/featured-insights/artificial-intelligence/notes-from-the-ai-frontier-modeling-the-impact-of-ai-on-the-world-economy>. Acesso em: 23 dez. 2021.

BURNEY, J. *et al.* Climate change adaptation strategies for smallholder farmers in the Brazilian Sertão. **Climatic Change**, Dordrecht, v. 126, n. 1/2, p. 45–59, 2014. Disponível em: <http://link.springer.com/10.1007/s10584-014-1186-0>. Acesso em: 14 dez. 2021.

BYAKATONDA, J.; PARIDA, B. P.; KENABATHO, P. K. Relating the dynamics of climatological and hydrological droughts in semiarid Botswana. **Physics and Chemistry of the Earth**, Oxford, v. 105, p. 12–24, 2018. Disponível em: <https://doi.org/10.1016/j.pce.2018.02.004>. Acesso em: 24 nov. 2021.

CAMARÉNA, S. Artificial intelligence in the design of the transitions to sustainable food systems. **Journal of Cleaner Production**, Amsterdam, v. 271, [art.] 122574, 2020. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0959652620326214>. Acesso em: 10 jul. 2021.

CARNEIRO, J. M. *et al.* Carbon and water footprints of Brazilian mango produced in the semiarid region. **International Journal of Life Cycle Assessment**, Landsberg, v. 24, n. 4, p. 735–752, 2019.

CARVALHO, C. C. S. *et al.* Using infrared thermography to measure the body surface temperature of crossbred cows and calves in the semi-arid region of Minas Gerais, Brazil. **Journal of Animal Behaviour and Biometeorology**, Mossoró, v. 7, n. 3, p. 132–136, 2019. Disponível em: <https://www.jabbnet.com/article/doi/10.31893/2318-1265jabb.v7n3p132-136>. Acesso em: 14 set. 2021.

CAVALCANTE JÚNIOR, R. *et al.* Sustainable groundwater exploitation aiming at the reduction of water vulnerability in the Brazilian semi-arid region. **Energies**, Torrance, v. 12, n. 5, [art.] 904, 2019. Disponível em: <https://www.mdpi.com/1996-1073/12/5/904>.

Acesso em: 19 out. 2021.

CHANTRE, G. R. *et al.* A flexible and practical approach for real-time weed emergence prediction based on Artificial Neural Networks. **Biosystems Engineering**, London, v. 170, p. 51–60, 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1537511017306335>. Acesso em: 19 out. 2021.

CHEN, Z. *et al.* Temporal convolution-network-based models for modeling maize evapotranspiration under mulched drip irrigation. **Computers and Electronics in Agriculture**, Amsterdam, v. 169, [art.] 105206, 2020. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169919318010>. Acesso em: 10 fev. 2022.

CHEN, S. H.; JAKEMAN, A. J.; NORTON, J. P. Artificial intelligence techniques: an introduction to their use for modelling environmental systems. **Mathematics and Computers in Simulation**, Amsterdam, v. 78, n. 2/3, p. 379–400, 2008.

CHEN, X.-W.; LIN, X. Big data deep learning: challenges and perspectives. **IEEE Access**, Piscataway, v. 2, p. 514–525, 2014. Disponível em: <http://ieeexplore.ieee.org/document/6817512/>. Acesso em: 14 jul. 2021.

CHIA, M. Y. *et al.* Recent advances in evapotranspiration estimation using artificial intelligence approaches with a focus on hybridization techniques—A review. **Agronomy**, Basel, v. 10, [art.] 101, 2020. Disponível em: <https://www.mdpi.com/2073-4395/10/1/101>. Acesso em: 12 jan. 2022.

CHITSAZAN, M.; RAHMANI, G.; NEYAMADPOUR, A. Forecasting groundwater level by artificial neural networks as an alternative approach to groundwater modeling. **Journal of the Geological Society of India**, New Delhi, v. 85, n. 1, p. 98–106, 2015. Disponível em: <http://link.springer.com/10.1007/s12594-015-0197-4>. Acesso em: 23 jan. 2022.

CHUI, M. *et al.* **Notes from the AI Frontier**: insights from hundreds of use cases. New York: McKinsey Global Institute, 2018. Disponível em: <https://www.mckinsey.com/~media/mckinsey/featured-insights/artificial-intelligence/notes-from-the-ai-frontier-applications-and-value-of-deep-learning/notes-from-the-ai-frontier-insights-from-hundreds-of-use-cases-discussion-paper.ashx>. Acesso em: 12 fev. 2022.

CHUKWU, N. C. E. Applications of artificial intelligence in agriculture: a review. **Engineering, Technology & Applied Science Research**, Patras, v. 9, n. 4, p. 4377–4383, 2019.

COELHO JUNIOR, L. M. *et al.* Avaliação do uso do solo e dos recursos florestais no semiárido do estado da Paraíba. **Ciência Florestal**, Santa Maria, v. 30, n. 1, p. 72–88, 2020.

COELHO JUNIOR, L. M.; MARTINS, K. L. C.; CARVALHO, M. Carbon footprint associated with firewood consumption in northeast Brazil: An analysis by the IPCC 2013 GWP 100y Criterion. **Waste and Biomass Valorization**, Dordrecht, v. 10, n. 10, p. 2985–2993, 2019.

CORTÉS, U. *et al.* Artificial intelligence and environmental decision support systems. **Applied Intelligence**, Amsterdam, v. 13, n. 1, p. 77–91, 2000.

COSTA, A. C. *et al.* Monthly and seasonal streamflow forecasting of large dryland catchments in Brazil. **Journal of Arid Land**, Beijing, v. 13, n. 3, p. 205–223, 2021. Disponível em: <https://link.springer.com/10.1007/s40333-021-0097-y>. Acesso em: 10 jul. 2021.

COSTA, R. B.; ARRUDA, E. J.; OLIVEIRA, L. C. S. Sistemas agrossilvipastoris como alternativa sustentável para a agricultura familiar. **Interações**, Campo Grande, v. 3, n. 5, p. 25-32, set. 2002.

COSTA, A. R. F. C.; MEDEIROS, J. F. Nitrogen, phosphorus and potassium accumulation in watermelon cultivars irrigated with saline water. **Engenharia Agrícola**, Jaboticabal, v. 38, n. 3, p. 343–350, 2018.

COTRIM, C. E. *et al.* Regulated deficit irrigation and Tommy Atkins mango orchard productivity under microsprinkling in Brazilian semi arid. **Engenharia Agrícola**, Jaboticabal, v. 31, n. 6, p. 1052–1063, 2011.

COUTO, A. A. *et al.* Land use changes associated with the expansion of sugar cane crops and their influences on soil removal in a tropical watershed in São Paulo State (Brazil). **CATENA**, Cremlingen, v. 172, p. 313–323, 2019. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0341816218303680>. Acesso em: 12 jan. 2022.

DEEPA, N.; GANESAN, K. Hybrid rough fuzzy soft classifier based multi-class classification model for agriculture crop selection. **Soft Computing**, Berlin, v. 23, n. 21, p. 10793–10809, 2019. Disponível em: <https://doi.org/10.1007/s00500-018-3633-8>. Acesso em: 13 set. 2021.

DEFRA - DEPARTMENTE FOR ENVIRONMENT, FOOD & RURAL AFFAIRS. **The future farming and environment evidence compendium**. London: UK Government Statistical Service, 2018.

DENGEL, A. Special issue on artificial intelligence in agriculture. **KI - Künstliche Intelligenz**, Munchen, v. 27, n. 4, p. 309–311, 2013.

DEO, R. C. *et al.* Forecasting effective drought index using a wavelet extreme learning machine (W-ELM) model. **Stochastic Environmental Research and Risk Assessment**, Heidelberg, v. 31, n. 5, p. 1211–1240, 2017. Disponível em: <http://dx.doi.org/10.1007/s00477-016-1265-z>. Acesso em: 12 jan. 2022.

DINIZ, G. L. *et al.* Phytomass and quality of yellow passion fruit seedlings under salt stress and silicon fertilization. **Comunicata Scientiae**, Bom Jesus, PI, v. 11, p. e3400–e3400, 2020.

DIXON, B. Applicability of neuro-fuzzy techniques in predicting ground-water vulnerability: a GIS-based sensitivity analysis. **Journal of Hydrology**, Amsterdam, v. 309, n. 1/4, p. 17–38, 2005.

DONGRE, V. B.; GANDHI, R. S. Applications of artificial neural networks for enhanced livestock productivity: a review. **Indian Journal of Animal Sciences**, New Delhi, v. 86, n. 11, p. 1232–1237, 2016. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84998865619&partnerID=40&md5=363aef2063a6ea7d2f06f968acc40367>. Acesso em: 21 jun. 2022.

DORNELLES, E. F. *et al.* Artificial intelligence in seeding density optimization and yield simulation for oat. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campo Grande, v. 22, n. 3, p. 183–188, 2018.

DOSI, G. **Technical change and industrial transformation: the theory and an application to the semiconductor industry**. Sussex: Springer, 1984.

DUTRA, D. S.; SILVA, J. R. Product-Service Architecture (PSA): toward a service engineering perspective in industry 4.0. **IFAC-PapersOnLine**, Wien, v. 49, n. 31, p. 91–96, 2016. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2405896316328385>. Acesso em: 27 jun. 2021.

ELBELTAGI, A. *et al.* Modeling long-term dynamics of crop evapotranspiration using deep learning in a semi-arid environment. **Agricultural Water Management**, Amsterdam, v. 241, [art.] 106334, 2020. Disponível em: <https://doi.org/10.1016/j.agwat.2020.106334>. Acesso em: 15 jul. 2021.

EVANS, K. J.; TERHORST, A.; KANG, B. H. From data to decisions: helping crop producers build their actionable knowledge. **Critical Reviews in Plant Sciences**, Boca Raton, v. 36, n. 2, p. 71–88, 2017. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85025144288&doi=10.1080%2f07352689.2017.1336047&partnerID=40&md5=0c2da04f43a95a5a013a82307c871eb0>. Acesso em: 11 dez. 2021.

FARIAS, J. L. S. *et al.* Socioeconomic analysis of smallholder producing goats and sheeps in the semiarid Cearense, Brazil. **Archivos de Zootecnia**, Córdoba, v. 63, n. 241, p. 13–24, 2014.

FENG, Z. Constructing rural e-commerce logistics model based on ant colony algorithm and artificial intelligence method. **Soft Computing**, Berlin, v. 24, n. 11, p. 7937–7946, 2020. Disponível em: <https://doi.org/10.1007/s00500-019-04046-8>. Acesso em: 21 nov. 2021.

FERERES, E.; SORIANO, M. A. Deficit irrigation for reducing agricultural water use. **Journal of Experimental Botany**, Oxford, v. 58, n. 2, p. 147–159, 2006. Disponível em: <https://academic.oup.com/jxb/article-lookup/doi/10.1093/jxb/erl165>. Acesso em: 12 dez. 2021.

FERNANDES, E. A. N. *et al.* Trace elements and machine learning for Brazilian beef traceability. **Food Chemistry**, London, v. 333, [art.] 127462, 2020. Disponível em: <https://doi.org/10.1016/j.foodchem.2020.127462>. Acesso em: 22 dez. 2021.

FERREIRA, L. B. *et al.* Generalizability of machine learning models and empirical equations for the estimation of reference evapotranspiration from temperature in a semiarid region. **Anais da Academia Brasileira de Ciências**, Rio de Janeiro, v. 93, n. 1, p. 1–15, 2021. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0001-37652021000101506&tlng=en. Acesso em: 21 nov. 2021.

FERREIRA, T. R. *et al.* The use of remote sensing for reliable estimation of net radiation and its components: a case study for contrasting land covers in an agricultural hotspot of the Brazilian semiarid region. **Agricultural and Forest Meteorology**, Amsterdam, v. 291, [art.] 108052, 2020. Disponível em: <https://doi.org/10.1016/j.agrformet.2020.108052>. Acesso em: 27 nov. 2021.

FOLHES, M. T.; RENNÓ, C. D.; SOARES, J. V. Remote sensing for irrigation water management in the semi-arid Northeast of Brazil. **Agricultural Water Management**, Amsterdam, v. 96, n. 10, p. 1398–1408, 2009.

FRASER, E. D. G.; CAMPBELL, M. Agriculture 5.0: reconciling production with planetary health. **One Earth**, Cambridge, v. 1, n. 3, p. 278–280, 2019. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2590332219301368>. Acesso em: 11 dez. 2021.

FREEMAN, C. Structural crises of adjustment: business cycles and investment behaviour. In: DOSS, G. *et al.* (ed.). **Technical change and economic theory**. London: Pinter, 1989.

FREITAS, R. M. O. *et al.* Water use of cowpea under deficit irrigation and cultivation systems in semi-arid region. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 23, n. 4, p. 271–276, 2019.

GARCIA, S. *et al.* The sustainability awareness of Brazilian consumers of cotton clothing. **Journal of Cleaner Production**, Amsterdam, v. 215, p. 1490–1502, 2019. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0959652619300800>. Acesso em: 12 set. 2021.

GARDAS, B. B. *et al.* A hybrid decision support system for analyzing challenges of the agricultural supply chain. **Sustainable Production and Consumption**, Amsterdam, v. 18, p. 19–32, 2019. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2352550918303129>. Acesso em: 12 set. 2021.

GENG, L.; DONG, T. An agricultural monitoring system based on wireless sensor and depth learning algorithm. **International Journal of Online Engineering**, Kassel, v. 13, n. 12, p. 127–137, 2017.

GOLDSMITH, J.; BURTON, E. Why Teaching ethics to ai practitioners is important. **The AAAI-17 workshop on AI, Ethics, and Society**, California, v. 2, p. 110–114, 2017.

GÖTZ, S. *et al.* Simulation of agricultural logistic processes with k-nearest neighbors algorithm. **Agricultural Engineering International: CIGR Journal**, Bonn, n. 2015, p. 241–245, 2015.

GRANATA, F. Evapotranspiration evaluation models based on machine learning

algorithms—A comparative study. **Agricultural Water Management**, Amsterdam, v. 217, p. 303–315, 2019. Disponível em: <https://doi.org/10.1016/j.agwat.2019.03.015>. Acesso em: 22 set. 2021.

GRIEVE, B. D. *et al.* The challenges posed by global broadacre crops in delivering smart agri-robotic solutions: a fundamental rethink is required. **Global Food Security**, New York, v. 23, p. 116–124, 2019. Disponível em: <https://doi.org/10.1016/j.gfs.2019.04.011>. Acesso em: 23 set. 2021.

GUBBI, J. *et al.* Internet of Things (IoT): a vision, architectural elements, and future directions. **Future Generation Computer Systems**, Amsterdam, v. 29, n. 7, p. 1645–1660, 2013. Disponível em: <http://dx.doi.org/10.1016/j.future.2013.01.010>. Acesso em: 12 set. 2021.

GUIMARÃES, B. V. C. *et al.* Prediction of “Gigante” cactus pear yield by morphological characters and artificial neural networks. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 22, n. 5, p. 315–319, 2018. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662018000500315&lng=en&tlng=en. Acesso em: 11 dez. 2021.

HAJI, F. N. P. *et al.* Monitoring mango pests within an integrated production program in Brazil. **Acta Horticulturae**, The Hague, v. 645, p. 163–165, 2004. Disponível em: https://www.actahort.org/books/645/645_12.htm. Acesso em: 19 jun. 2021.

HASHIMOTO, Y. *et al.* Intelligent systems for agriculture in Japan. **IEEE Control Systems Magazine**, New York, v. 21, n. 5, p. 71–85, 2001.

HOFFMANN, R.; NEY, M. G. **Estrutura fundiária e propriedade agrícola no Brasil: grandes regiões e unidades da federação**. Brasília, DF: Ministério do Desenvolvimento Agrário, 2010.

HUTSON, M. AI Glossary: artificial intelligence, in so many words. **Science**, New York, v. 357, n. 6346, p. 19, 2017. Disponível em: <http://www.sciencemag.org/lookup/doi/10.1126/science.357.6346.19>. Acesso em: 12 set. 2021.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo Agropecuário**. Rio de Janeiro: IBGE, 2017.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Mapa de biomas do Brasil**. 1 mapa. Escala 1:5.000. Rio de Janeiro: IBGE, 2004. Disponível em: http://geoftp.ibge.gov.br/informacoes_ambientais/estudos_ambientais/biomas/vetores/Biomas_250mil.zip. Acesso em: 12 dez. 2021.

ILIADIS, L. S.; MARIS, F. An Artificial Neural Network model for mountainous water-resources management: the case of Cyprus mountainous watersheds. **Environmental Modelling and Software**, Amsterdam, v. 22, n. 7, p. 1066–1072, 2007.

JABEEN, H.; TAHARA, N.; LEHMANN, J. EvoChef: show me what to cook! Artificial

- evolution of culinary arts. *In*: EKÁRT, A.; LIAPIS, A.; PENA, M. L. C. (ed.). **Computational intelligence in music, sound, art and design**: 8th International Conference, EvoMUSART 2019, held as part of EvoStar 2019, Leipzig, Germany, April 24-26, 2019, proceedings. Cham: Springer, 2019. p. 156–172. *E-book*. Disponível em: https://link.springer.com/10.1007/978-3-030-16667-0_11. Acesso em: 27 jul. 2021.
- JARRAHI, M. H. Artificial intelligence and the future of work: Human-AI symbiosis in organizational decision making. **Business Horizons**, Amsterdam, v. 61, n. 4, p. 577–586, 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0007681318300387>. Acesso em: 19 dez. 2021.
- JESUS, K. N. *et al.* Maize and sunflower yields and soil changes after five years of organic fertilization in the semi-arid region of Paraiba, Brazil. **Arid Land Research and Management**, London, v. 34, n. 4, p. 460–473, 2020. Disponível em: <https://doi.org/10.1080/15324982.2020.1763515>. Acesso em: 15 nov. 2021.
- KAMBLE, S. S.; GUNASEKARAN, A.; GAWANKAR, S. A. Achieving sustainable performance in a data-driven agriculture supply chain: a review for research and applications. **International Journal of Production Economics**, Amsterdam, v. 219, p. 179–194, 2020. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0925527319302038>. Acesso em: 14 out. 2021.
- KANG, M.; WANG, F. Y. From parallel plants to smart plants: intelligent control and management for plant growth. **IEEE/CAA Journal of Automatica Sinica**, New York, v. 4, n. 2, p. 161–166, 2017.
- KAPLAN, A.; HAENLEIN, M. Siri, Siri, in my hand: who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. **Business Horizons**, Amsterdam, v. 62, n. 1, p. 15–25, 2019. Disponível em: <https://doi.org/10.1016/j.bushor.2018.08.004>. Acesso em: 11 set. 2021.
- KARGAR, A. H. B.; SHIRZADIFAR, A. M. Automatic weed detection system and smart herbicide sprayer robot for corn fields. *In*: 2013 First RSI/ISM INTERNATIONAL CONFERENCE ON ROBOTICS AND MECHATRONICS (ICRoM), 2013, Tehran. **[Proceedings ...]**. Piscataway: IEEE, 2013. p. 468–473. Disponível em: <http://ieeexplore.ieee.org/document/6510152/>. Acesso em: 14 dez. 2021.
- KEATING, B. A. *et al.* Modelling sugarcane production systems. I. Development and performance of the sugarcane module. **Field Crops Research**, Amsterdam, v. 61, p. 253–271, 1999.
- KESHAVARZI, A. *et al.* Modeling of soil exchangeable sodium percentage using easily obtained indices and artificial intelligence-based models. **Modeling Earth Systems and Environment**, Berlin, v. 2, n. 3, p. 1–10, 2016. Disponível em: <http://dx.doi.org/10.1007/s40808-016-0185-8>. Acesso em: 12 dez. 2021.
- KIM, T.-W.; VALDÉS, J. B. Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. **Journal of Hydrologic Engineering**, New York, v. 8, n. 6, p. 319–328, 2003. Disponível em:

<http://ascelibrary.org/doi/10.1061/%28ASCE%291084-0699%282003%298%3A6%28319%29>. Acesso em: 30 abr. 2021.

KOUADIO, L. *et al.* Artificial intelligence approach for the prediction of Robusta coffee yield using soil fertility properties. **Computers and Electronics in Agriculture**, Amsterdam, v. 155, p. 324–338, 2018. Disponível em: <https://doi.org/10.1016/j.compag.2018.10.014>. Acesso em: 21 fev. 2021.

KUMAR, A. V. S. P.; BHRAMARAMBA, R. Adapting mining into agriculture sector with machine learning techniques. **International Journal of Control and Automation**, Seoul, v. 10, n. 7, p. 13–22, 2017.

LACERDA, C. F. *et al.* Strategies for the use of brackish water for crop production in northeastern Brazil. In: TALEISNIK, E.; LAVADO, R. S. (ed.). **Saline and alkaline soils in Latin America**. Cham: Springer International, 2021. p. 71–99. *E-book*. Disponível em: http://link.springer.com/10.1007/978-3-030-52592-7_4. Acesso em: 27 nov. 2021.

LAFAYETTE, F. B. *et al.* Experimentation and modeling of soil evaporation in underground dam in a semiarid region. **Revista Brasileira de Recursos Hídricos -RBRH**, Porto Alegre, v. 24, [art.] e2, 2019. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S2318-03312019000100204&tlng=en. Acesso em: 17 dez. 2021.

LAQUI, W. *et al.* Can artificial neural networks estimate potential evapotranspiration in Peruvian highlands? **Modeling Earth Systems and Environment**, Berlin, v. 5, n. 4, p. 1911–1924, 2019. Disponível em: <https://doi.org/10.1007/s40808-019-00647-2>. Acesso em: 18 dez. 2021.

LATORRE-BIEL, J. I. *et al.* Decision support in the rioja wine production sector. **International Journal of Food Engineering**, Berlin, v. 9, n. 3, p. 267–278, 2013.

LEHMANN, R. J.; REICHE, R.; SCHIEFER, G. Future internet and the agri-food sector: state-of-the-art in literature and research. **Computers and Electronics in Agriculture**, Amsterdam, v. 89, p. 158–174, 2012. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S016816991200227X>. Acesso em: 30 nov. 2021.

LEZOCHE, M. *et al.* Agri-food 4.0: A survey of the supply chains and technologies for the future agriculture. **Computers in Industry**, Amsterdam, v. 117, [art.] 103187, 2020.

LIAKOS, K. G. *et al.* Machine learning in agriculture: a review. **Sensors**, Basel, v. 18, n. 8, [art.] 2674, [p. 1–29], 2018.

LI, D.; YANG, H. State-of-the-art review for internet of things in agriculture. **Transactions of the Chinese Society of Agricultural Machinery**, Beijing, v. 49, n. 1, p. 1–20, 2018. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85047731474&doi=10.6041%2fj.issn.1000-1298.2018.01.001&partnerID=40&md5=c21999e48ae5bbc24f306e604eec147b>. Acesso em: 31 out. 2021.

- LIBERATI, A. *et al.* The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: explanation and elaboration. **PLoS Medicine**, San Francisco, v. 6, n. 7, [art.] e1000100, 2009.
- LIMA, A. O. *et al.* Barragens subterrâneas no semiárido brasileiro: análise histórica e metodologias de construção. **Irriga**, Botucatu, v. 18, n. 2, p. 200–211, 2013.
- LIMA, G. S. *et al.* Photosynthesis, photochemical efficiency and growth of west indian cherry cultivated with saline waters and nitrogen fertilization. **Bioscience Journal**, Uberlândia, v. 35, n. 1, p. 67-78, 2019.
- LINDOSO, D. *et al.* Harvesting water for living with drought: insights from the brazilian human coexistence with semi-aridity approach towards achieving the sustainable development goals. **Sustainability**, Basel, v. 10, [art.] 622, 2018. Disponível em: <http://www.mdpi.com/2071-1050/10/3/622>. Acesso em: 31 out. 2021.
- LIU, P. **The future of food and agriculture: trends and challenges**. Rome: FAO, 2017. Disponível em: <http://www.fao.org/3/a-i6583e.pdf>. Acesso em: 30 nov. 2021.
- MACIEL, H. M.; MACIEL, W. M.; GOMES, M. A. A desertificacao e a seca: efeitos sobre a produção e renda agrícolas no Estado do Ceará. **Brazilian Journal of Development**, Curitiba, v. 7, n. 2, p. 17824–17843, 2021.
- MAHMOUD, M.; RAFEA, M.; RAFEA, A. Using expert systems technology to increase agriculture production and water conservation. *In*: INTERNATIONAL CONFERENCE ON DIGITAL INFORMATION MANAGEMENT, ICDIM, 3., 2008, London, UK. [Proceedings of the ...]. Piscataway: IEEE, 2008. p. 1–7.
- MAIA, A. G. *et al.* Climate change and farm-level adaptation: the Brazilian Sertão. **International Journal of Climate Change Strategies and Management**, Bingley, v. 10, n. 5, p. 729–751, 2018.
- MARENGO, J. A.; TORRES, R. R.; ALVES, L. M. Drought in Northeast Brazil—past, present, and future. **Theoretical and Applied Climatology**, Wien, v. 129, n. 3/4, p. 1189–1200, 2017. Disponível em: <http://link.springer.com/10.1007/s00704-016-1840-8>. Acesso em: 12 dez. 2021.
- MARINHO, R. C. N. *et al.* Symbiotic and agronomic efficiency of new cowpea rhizobia from Brazilian semi-arid. **Bragantia**, Campinas, v. 76, n. 2, p. 273–281, 2017.
- MARTINS, M. A. *et al.* Improving drought management in the Brazilian semiarid through crop forecasting. **Agricultural Systems**, Barking, v. 160, p. 21–30, 2018. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0308521X16308204>. Acesso em: 11 set. 2021.
- MASON, M. Sample size and saturation in PhD studies using qualitative interviews. **Forum: Qualitative Social Research**, Berlin, v. 11, n. 3, [art.] 8, 2010.

MASSRUHÁ, S. M. F. *et al.* **Agricultura digital**: pesquisa, desenvolvimento e inovação nas cadeias produtivas. Brasília, DF: Embrapa, 2020. *E-book*. Disponível em: www.embrapa.br/fale-conosco/sac. Acesso em: 12 dez. 2021.

MATTOS, L. C. *et al.* A saga do algodão no semiárido nordestino: histórico, declínio e as perspectivas de base agroecológica. **Desenvolvimento e Meio Ambiente**, Curitiba, v. 55, p. 556-580, 2020.

MAY, D. B.; SIVAKUMAR, M. Prediction of urban stormwater quality using artificial neural networks. **Environmental Modelling and Software**, Amsterdam, v. 24, n. 2, p. 296–302, 2009. Disponível em: <http://dx.doi.org/10.1016/j.envsoft.2008.07.004>. Acesso em: 30 jul. 2021.

MAZZUCATO, M.; PEREZ, C. Innovation as growth policy: the challenge for Europe. *In*: FAGERBERG, J.; LAESTADIUS, S.; MARTIN, B. (ed.). **The triple challenge for Europe**: economic development, climate change, and governance. Oxford: SPRU - Science Policy Research Unit, 2014. (SPRU Working Paper Series). *E-book*. Disponível em: <https://econpapers.repec.org/RePEc:sru:ssewps:2014-13>. Acesso em: 30 jun. 2021.

MEHDIZADEH, S. Estimation of daily reference evapotranspiration (ET_o) using artificial intelligence methods: offering a new approach for lagged ET_o data-based modeling. **Journal of Hydrology**, Amsterdam, v. 559, p. 794–812, 2018. Disponível em: <https://doi.org/10.1016/j.jhydrol.2018.02.060>. Acesso em: 12 jul. 2021.

MIRABELLI, G.; SOLINA, V. Blockchain and agricultural supply chains traceability: research trends and future challenges. **Procedia Manufacturing**, Amsterdam, v. 42, p. 414–421, 2020. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2351978920306181>. Acesso em: 10 abr. 2021.

MISHRA, A. K.; DESAI, V. R. Drought forecasting using stochastic models. **Stochastic Environmental Research and Risk Assessment**, Heidelberg, v. 19, n. 5, p. 326–339, 2005. Disponível em: <http://link.springer.com/10.1007/s00477-005-0238-4>. Acesso em: 31 jul. 2021.

MISHRA, D.; SATAPATHY, S. Reliability and maintenance of agricultural machinery by MCDM approach. **International Journal of System Assurance Engineering and Management**, New Delhi, 21 Aug. 2021. Disponível em: <http://link.springer.com/10.1007/s13198-021-01256-y>. Acesso em: 14 nov. 2021.

MOLOTKOVA, N. V. *et al.* Improving Russian agribusiness competitiveness within the digital transformation framework. *In*: ASHMARINA, S. I.; VOCHOZKA, M.; MANTULENKO, V. V. (org.). **International scientific conference “digital transformation of the economy: challenges, trends, new opportunities”**. Cham: Springer, 2020. p. 342–350.

MONTEIRO JUNIOR, J. J. *et al.* Dynamical spatial modeling to simulate the forest scenario in Brazilian dry forest landscapes. **Geology, Ecology, and Landscapes**, Abingdon, v. 3, n. 1, p. 46–52, 2019. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/24749508.2018.1481658>. Acesso em: 7 abr.

2020.

MORALES, I. R. *et al.* Early warning in egg production curves from commercial hens: a SVM approach. **Computers and Electronics in Agriculture**, Amsterdam, v. 121, p. 169–179, 2016.

MOURA, M. S. B. *et al.* Clima e água de chuva no semi-árido. *In*: BRITO, L. T. L.; MOURA, M. S. B.; GAMA, G. F. B. **Potencialidades da água de chuva no semiárido brasileiro**. Petrolina: Embrapa Semiárido, 2007. p. 37–59.

MUIR, J. P. *et al.* Value of endemic legumes for livestock production on Caatinga rangelands. **Revista Brasileira de Ciências Agrárias**, Recife, v. 14, n. 2, p. 1–12, 2019.

NARAYAN, K. A.; SCHLEEGER, C.; BRISTOW, K. L. Modelling seawater intrusion in the Burdekin Delta irrigation area, North Queensland, Australia. **Agricultural Water Management**, Amsterdam, v. 89, n. 3, p. 217–228, 2007.

NAVULUR, S.; SASTRY, A. S. C. S.; PRASAD, M. N. G. Agricultural management through wireless sensors and internet of things. **International Journal of Electrical and Computer Engineering**, Jakarta, v. 7, n. 6, p. 3492–3499, 2017. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85032181535&doi=10.11591%2fijece.v7i6.pp3492-3499&partnerID=40&md5=d03d42ab56ae340f7e478a375aaf6819>. Acesso em: 10 mar. 2020.

NOURANI, V.; ELKIRAN, G.; ABDULLAHI, J. Multi-step ahead modeling of reference evapotranspiration using a multi-model approach. **Journal of Hydrology**, Amsterdam, v. 581, [art.] 124434, 2020. Disponível em: <https://doi.org/10.1016/j.jhydrol.2019.124434>. Acesso em: 28 nov. 2021.

NOZARI, H.; AZADI, S. Experimental evaluation of artificial neural network for predicting drainage water and groundwater salinity at various drain depths and spacing. **Neural Computing and Applications**, London, v. 31, n. 4, p. 1227–1236, 2019. Disponível em: <http://dx.doi.org/10.1007/s00521-017-3155-9>. Acesso em: 29 set. 2021.

OGUNDE, A. O.; OLANBO, A. R. A web-based decision support system for evaluating soil suitability for cassava cultivation. **Advances in Science, Technology and Engineering Systems**, Walnut, v. 2, n. 1, p. 42–50, 2017.

ÖHMAN, C.; FLORIDI, L. An ethical framework for the digital afterlife industry. **Nature Human Behaviour**, London, v. 2, n. 5, p. 318–320, 2018. Disponível em: <http://www.nature.com/articles/s41562-018-0335-2>. Acesso em: 30 out. 2020.

OLDONI, H.; BASSOI, L. H. Delineation of irrigation management zones in a Quartzipsamment of the Brazilian semiarid region. **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 51, n. 9, p. 1283–1294, 2016.

OLIVEIRA, D. A. B. *et al.* A review of deep learning algorithms for computer vision systems in livestock. **Livestock Science**, Amsterdam, v. 253, [art.] 104700, 2021.

Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S1871141321003085>. Acesso em: 19 dez. 2020.

OLIVEIRA, R. C.; MOREIRA, J. M.; FERREIRA, C. A. Agribusiness intelligence: grape production forecast using data mining techniques. *In: WORLD CONFERENCE ON INFORMATION SYSTEMS AND TECHNOLOGIES - WorldCIST'18*, 18., 2018, Porto. **Proceedings of the [...]**. Cham: Springer, 2018. p. 3–8. Disponível em: http://link.springer.com/10.1007/978-3-319-77700-9_1. Acesso em: 11 nov. 2021.

OLIVEIRA, T. J. A.; RODRIGUES, W. A difusão do agronegócio nos cerrados do centro norte brasileiro e nas áreas irrigadas da caatinga nordestina. **Revista em Agronegócio e Meio Ambiente**, Maringá, v. 13, n. 2, p. 525–546, 2020. Disponível em: <https://periodicos.unicesumar.edu.br/index.php/rama/article/view/6854>. Acesso em: 10 abr. 2020.

ONU. **Transforming our world: the 2030 agenda for sustainable development**. New York: ONU, 2015. Disponível em: https://www.unfpa.org/sites/default/files/resource-pdf/Resolution_A_RES_70_1_EN.pdf. Acesso em: 2 abr. 2021.

ONU. **World population prospects: the 2019 highlights**. New York: ONU, 2019. Disponível em: <http://www.ncbi.nlm.nih.gov/pubmed/12283219>. Acesso em: 17 fev. 2021.

PALMER, G. Energetic implications of a post-industrial information economy: the case study of Australia. **BioPhysical Economics and Resource Quality**, Cham, v. 2, n. 2, p. 1–9, 2017. Disponível em: <http://dx.doi.org/10.1007/s41247-017-0021-4>. Acesso em: 11 nov. 2021.

PATRÍCIO, D. I.; RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: a systematic review. **Computers and Electronics in Agriculture**, Amsterdam, v. 153, n. April, p. 69–81, 2018.

PELESARAEI, A. N. *et al.* Resource management in cropping systems using artificial intelligence techniques: a case study of orange orchards in north of Iran. **Stochastic Environmental Research and Risk Assessment**, Heidelberg, v. 30, n. 1, p. 413–427, 2016. Disponível em: <http://dx.doi.org/10.1007/s00477-015-1152-z>. Acesso em: 22 dez. 2021.

PENNINGTON, R. T.; LAVIN, M.; OLIVEIRA-FILHO, A. Woody plant diversity, evolution, and ecology in the tropics: perspectives from seasonally dry tropical forests. **Annual Review of Ecology, Evolution, and Systematics**, New York, v. 40, n. 1, p. 437–457, 2009. Disponível em: <http://www.annualreviews.org/doi/10.1146/annurev.ecolsys.110308.120327>. Acesso em: 7 set. 2021.

PEREIRA, M. A. T.; CARMO, R. L. Fruticultura, emprego e migração: o caso da região de Petrolinas-PE e Juazeiro-BA. *In: RANDOLPH, R.; SIQUEIRA, H.; OLIVEIRA, A. (org.). Planejamento, políticas e experiências de desenvolvimento regional: problemáticas e desafios*. Rio Branco: Letra Capital, 2014. p. 287-304.

- PERINI, A.; SUSI, A. Developing a decision support system for integrated production in agriculture. **Environmental Modelling and Software**, Amsterdam, v. 19, n. 9, p. 821–829, 2004.
- PESSOA, L. G. M. *et al.* Spectral reflectance characteristics of soils in northeastern Brazil as influenced by salinity levels. **Environmental Monitoring and Assessment**, Dordrecht, v. 188, n. 11, [art.] 616, 2016. Disponível em: <http://dx.doi.org/10.1007/s10661-016-5631-6>. Acesso em: 7 set. 2021.
- PI, E. *et al.* Application of genetic algorithm to predict optimal sowing region and timing for kentucky bluegrass in China. **PLOS ONE**, San Francisco, v. 10, n. 7, [art.] e0131489, 2015. Disponível em: <https://dx.plos.org/10.1371/journal.pone.0131489>. Acesso em: 13 dez. 2021.
- PINI, A. *et al.* AI inspired recipes: designing computationally creative food combos. *In*: 2019 CHI CONFERENCE ON HUMAN FACTORS IN COMPUTING SYSTEMS, 2019, New York. **Extended Abstracts of the [...]**. New York: ACM, 2019. p. 1–6. Disponível em: <https://dl.acm.org/doi/10.1145/3290607.3312948>. Acesso em: 13 set. 2021.
- PIVOTO, D. *et al.* Scientific development of smart farming technologies and their application in Brazil. **Information Processing in Agriculture**, Amsterdam, v. 5, n. 1, p. 21–32, 2018. Disponível em: <http://www.sciencedirect.com/science/article/pii/S2214317316301184>. Acesso em: 7 set. 2021.
- POURSAEID, M. *et al.* Modelling qualitative and quantitative parameters of groundwater using a new wavelet conjunction heuristic method: wavelet extreme learning machine versus wavelet neural networks. **Water and Environment Journal**, Amsterdam, v. 35, n. 1, p. 67–83, 2021. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/wej.12595>. Acesso em: 22 dez. 2021.
- PURDY, M.; DAUGHERTY, P. **How ai boosts industry profits and innovation**. Dublin: Accenture, 2017. 28 p. Disponível em: <https://www.accenture.com/no-en/insight-ai-industry-growth>. Acesso em: 6 out. 2021.
- PYKA, A. Dedicated innovation systems to support the transformation towards sustainability: creating income opportunities and employment in the knowledge-based digital bioeconomy. **Journal of Open Innovation: Technology, Market, and Complexity**, Cham, v. 3, n. 27, [art.] 27, 2017.
- QUEIROZ, M. A. *et al.* Plant breeding in the semiarid region of Brazil: examples of success. **Crop Breeding and Applied Biotechnology**, Viçosa, MG, v. 12, p. 57–66, 2012. Número especial. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1984-70332012000500007&lng=en&tlng=en. Acesso em: 7 set. 2021.
- RAJANAYAKA, C.; SAMARASINGHE, S.; KULASIRI, D. Solving the inverse problem in stochastic groundwater modelling with Artificial Neural Networks. *In*: INTERNATIONAL CONGRESS ON ENVIRONMENTAL MODELLING AND

SOFTWARE - iEMSs 2002, 2002, Lugano, Switzerland. **Proceedings of iEMSs 2002 – Integrated Assessment and Decision Support**. Utah: Brigham Young University, 2002. p. 154–159.

RATHOD, S. *et al.* Modeling and forecasting of oilseed production of India through artificial intelligence techniques. **The Indian Journal of Agricultural Sciences**, New Delhi, v. 88, n. 1, p. 22–27, 2018.

REDDY, P. P. Climate change adaptation. *In*: REDDY, P. P. **Climate resilient agriculture for ensuring food security**. New Delhi: Springer India, 2015. p. 223–272. *E-book*. Disponível em: http://link.springer.com/10.1007/978-81-322-2199-9_12. Acesso em: 17 dez. 2021.

REIS, M. M. *et al.* Empirical and learning machine approaches to estimating reference evapotranspiration based on temperature data. **Computers and Electronics in Agriculture**, Amsterdam, v. 165, [art.] 104937, 2019. Disponível em: <https://doi.org/10.1016/j.compag.2019.104937>. Acesso em: 7 set. 2021.

ROCHA JÚNIOR, R. L. *et al.* Bivariate assessment of drought return periods and frequency in brazilian northeast using joint distribution by Copula Method. **Geosciences**, Basel, v. 10, n.4, [art.] 135, 2020. Disponível em: <https://www.mdpi.com/2076-3263/10/4/135>. Acesso em: 22 nov. 2021.

ROOH, U. A.; LI, A.; ALI, M. M. Fuzzy, neural network and expert systems methodologies and applications - A review. **Journal of Mobile Multimedia**, Gistrup, v. 11, n. 1/2, p. 157–176, 2015. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84926505137&partnerID=40&md5=aa4383f83e91ffdc18ae2b3e5ac4e79>. Acesso em: 14 nov. 2021.

ROOPAELI, M.; RAD, P.; CHOO, K.-K. R. Cloud of things in smart agriculture: intelligent irrigation monitoring by thermal imaging. **IEEE Cloud Computing**, Piscataway, v. 4, n. 1, p. 10–15, 2017.

ROSE, D. C.; CHILVERS, J. Agriculture 4.0: broadening responsible innovation in an era of smart farming. **Frontiers in Sustainable Food Systems**, Lausanne, v. 2, [art.] 87, [p. 1–7], 2018.

ROSEGRANT, M. W.; CAI, X. Global water demand and supply projections. **Water International**, Philadelphia, v. 27, n. 2, p. 170–182, 2009. Disponível em: <http://www.tandfonline.com/doi/abs/10.1080/02508060208686990>. Acesso em: 15 jun. 2021.

RUPNIK, R. *et al.* AgroDSS: a decision support system for agriculture and farming. **Computers and Electronics in Agriculture**, Amsterdam, v. 161, p. 260–271, 2019. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169917314205>. Acesso em: 6 nov. 2021.

SABRI, N. *et al.* Smart prolong fuzzy wireless sensor-actor network for agricultural

application. **Journal of Information Science and Engineering**, Taipei, v. 28, n. 2, p. 295–316, 2012.

SALEHNIA, N. *et al.* Climate data clustering effects on arid and semi-arid rainfed wheat yield: a comparison of artificial intelligence and K-means approaches. **International Journal of Biometeorology**, New York, v. 63, p. 861–872, 2019. Disponível em: <http://link.springer.com/10.1007/s00484-019-01699-w>. Acesso em: 7 set. 2021.

SANTOS, A. A. R. *et al.* Innovation dynamics: Analysis of mango innovation strategies by ride. **Revista em Agronegócios e Meio Ambiente**, Maringá, v. 10, p. 91–114, 2017.

SANTOS, P. M. *et al.* Mudanças climáticas globais e a pecuária: cenários futuros para o semiárido brasileiro. **Revista Brasileira de Geografia Física**, Recife, v. 4, n. 6, p. 1176–1196, 2012. Disponível em: <https://periodicos.ufpe.br/revistas/rbgfe/article/view/232765>. Acesso em: 12 nov. 2021.

SANTOS, A. P. S. *et al.* **O semiárido brasileiro: roquezas, diversidades e saberes**. Campina Grande: INSA/MCTI, 2013.

SANTOS, D. L. *et al.* Partial root-zone drying in field-grown papaya: gas exchange, yield, and water use efficiency. **Agricultural Water Management**, Amsterdam, v. 243, [art.] 106421, 2020a. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0378377420313627>. Acesso em: 7 nov. 2021.

SANTOS, C. A. *et al.* Spatio-temporal patterns of energy exchange and evapotranspiration during an intense drought for drylands in Brazil. **International Journal of Applied Earth Observation and Geoinformation**, Washington, DC, v. 85, [art.] 101982, 2020b. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0303243419302338>. Acesso em: 12 jan. 2022.

SANTOS, C. M. G.; MOREIRA, M. M.; RODRIGUES, J. D. Metabolismo da videira “syrah” no semiárido nordestino sob três estratégias hídricas. **Semina: Ciências Agrárias**, Londrina, v. 34, n. 6, p. 3611–3624, 2013. Supl.1. Disponível em: <http://www.uel.br/revistas/uel/index.php/semagrarias/article/view/13007>. Acesso em: 17 nov. 2021.

SARAIVA, M. *et al.* Automatic mapping of center pivot irrigation systems from satellite images using deep learning. **Remote Sensing**, Basel, v. 12, [art.] 558, 2020. Disponível em: <https://www.mdpi.com/2072-4292/12/3/558>. Acesso em: 4 set. 2021.

SARANYA, C. P.; NAGARAJAN, N. Efficient agricultural yield prediction using metaheuristic optimized artificial neural network using Hadoop framework. **Soft Computing**, Berlin, v. 24, n. 16, p. 12659–12669, 2020. Disponível em: <https://doi.org/10.1007/s00500-020-04707-z>. Acesso em: 22 nov. 2021.

SARWAR, A.; PETERS, R. T.; MOHAMED, A. Z. Linear mixed modeling and artificial neural network techniques for predicting wind drift and evaporation losses under moving sprinkler irrigation systems. **Irrigation Science**, Berlin, v. 38, n. 2, p. 177–188, 2020. Disponível em: <https://doi.org/10.1007/s00271-019-00659-x>. Acesso em: 27 nov. 2021.

SEEBACHER, S.; SCHÜRITZ, R. Blockchain technology as an enabler of service systems: a structured literature review. *In: INTERNATIONAL CONFERENCE ON EXPLORING SERVICES SCIENCE - IESS*, 8., 2017, Rome. [**Proceedings ...**]. Cham: Springer, 2017. p. 12–23. Disponível em: http://link.springer.com/10.1007/978-3-319-56925-3_2. Acesso em: 8 set. 2021.

SEYAM, M.; OTHMAN, F.; EL-SHAFIE, A. RBFNN versus empirical models for lag time prediction in tropical humid rivers. **Water Resources Management**, Amsterdam, v. 31, n. 1, p. 187–204, 2017. Disponível em: <http://dx.doi.org/10.1007/s11269-016-1518-0>. Acesso em: 22 nov. 2021.

SHAKIBAI, A. R.; KOOCHEKZADEH, S. Modeling and predicting agricultural energy consumption in Iran. **American-Eurasian Journal of Agricultural and Environmental Science**, Faisalabad, v. 5, n. 3, p. 308–312, 2009.

SHARMA, G.; SINGH, A.; JAIN, S. A hybrid deep neural network approach to estimate reference evapotranspiration using limited climate data. **Neural Computing and Applications**, London, v. 34, p. 4013–4032, 2022. Disponível em: <https://link.springer.com/10.1007/s00521-021-06661-9>. Acesso em: 22 fev. 2022.

SHIRI, J. *et al.* Comparison of heuristic and empirical approaches for estimating reference evapotranspiration from limited inputs in Iran. **Computers and Electronics in Agriculture**, Amsterdam, v. 108, p. 230–241, 2014. Disponível em: <http://dx.doi.org/10.1016/j.compag.2014.08.007>. Acesso em: 4 mar. 2022.

SHU, L. H. *et al.* Design for reduced resource consumption during the use phase of products. **CIRP Annals**, Paris, v. 66, n. 2, p. 635–658, 2017. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0007850617301518>. Acesso em: 24 dez. 2021.

SILVA, S. S. *et al.* Application strategies of saline water and nitrogen doses in mini watermelon cultivation. **Comunicata Scientiae**, Bom Jesus, PI, v. 11, p. e3233–e3233, 2020a.

SILVA, J. L. B. *et al.* Changes in the water resources, soil use and spatial dynamics of Caatinga vegetation cover over semiarid region of the Brazilian Northeast. **Remote Sensing Applications: Society and Environment**, Amsterdam, v. 20, [art.]100372, 2020b. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2352938520300872>. Acesso em: 21 dez. 2021.

SILVA, F. P. *et al.* Eficiência técnica e heterogeneidade tecnológica na agropecuária das regiões semiárida e não semiárida do Nordeste brasileiro. **Revista de Economia e Sociologia Rural**, Brasília, DF, v. 57, n. 3, p. 379–395, 2019. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-20032019000300379&tlng=pt. Acesso em: 21 dez. 2021.

SILVA, Y. L. *et al.* Estratégias de manejo pecuário na Caatinga: o caso de agricultores assistidos pelo projeto Sustentare na comunidade Sítio Areias, Sobral, CE. **Cadernos de**

Ciência & Tecnologia, Brasília, DF, v. 37, [art.] 26661, 2020c.

SILVA, L. P. *et al.* Modeling land cover change based on an artificial neural network for a semiarid river basin in northeastern Brazil. **Global Ecology and Conservation**, Amsterdam, v. 21, [art.] e00811, 2020d. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S2351989419300265>. Acesso em: 07 out. 2021.

SILVA, M. V *et al.* Pilot monitoring of caatinga spatial-temporal dynamics through the action of agriculture and livestock in the Brazilian semiarid. **Remote Sensing Applications: Society and Environment**, Amsterdam, v. 19, [art.] 100353, 2020e.

SILVA, V. P. R. *et al.* Risco climático da cana-de-açúcar cultivada na região nordeste do Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 17, n. 2, p. 180–189, 2013.

SILVA, K. A. *et al.* Soil sampling optimization using spatial analysis in irrigated mango fields under Brazilian semi-arid conditions. **Revista Brasileira de Fruticultura**, Jaboticabal, v. 42, n. 5, p. 1–18, 2020f. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-29452020000503003&tlng=en. Acesso em: 21 dez. 2021.

SILVA, J. M. C. *et al.* The caatinga: understanding the challenges. In: SILVA, J. M. C.; LEAL, I. R.; TABARELLI, M. (ed.). **Caatinga**. Cham: Springer International, 2017. p. 3–19. *E-book*. Disponível em: http://link.springer.com/10.1007/978-3-319-68339-3_1. Acesso em: 21 dez. 2021.

SILVA, G. D. P.; SHARQAWY, M. H. Techno-economic analysis of low impact solar brackish water desalination system in the Brazilian Semiarid region. **Journal of Cleaner Production**, Amsterdam, v. 248, [art.] 119255, 2020. Disponível em: <https://doi.org/10.1016/j.jclepro.2019.119255>. Acesso em: 29 nov. 2021.

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**, Amsterdam, v. 189, [art.] 106405, 2021. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169921004221>. Acesso em: 21 dez. 2021.

SIMÕES, J. A. Generations, changes and continuities in the social experience of male homosexuality and the HIV-AIDS epidemic. **Sexualidad, Salud y Sociedad**, Rio de Janeiro, n. 29, p. 313–339, 2018.

SIMONE, M. C.; RIVERA, Z. B.; GUIDA, D. Obstacle avoidance system for unmanned ground vehicles by using ultrasonic sensors. **Machines**, Basel, v. 6, n. 2, [art.] 18, 2018.

SOUSA, B. F. S. *et al.* Avaliação de classificadores baseados em aprendizado de máquina para a classificação do uso e cobertura da terra no bioma Caatinga. **Revista Brasileira de Cartografia**, Rio de Janeiro, v. 62, p. 385–399, 2013. Disponível em: <https://seer.ufu.br/index.php/revistabrasileiracartografia/article/view/43717>. Acesso em: 11

jun. 2021.

SRINIVASAN, P. S. Empowering agribusiness with digital innovation for emerging market. *In: ADHIKARI, A. (org.). Strategic marketing issues in emerging markets.* Singapore: Springer Singapore, 2018. p. 257–273. *E-book*. Disponível em: https://doi.org/10.1007/978-981-10-6505-7_24. Acesso em: 23 nov. 2021.

STASTNY, J.; KONECNY, V.; TRENZ, O. Agricultural data prediction by means of neural network. **Agricultural Economics**, Prague, v. 57, n. 7, p. 356–361, 2011. Disponível em: <http://www.agriculturejournals.cz/web/agricecon.htm?volume=57&firstPage=356&type=publishedArticle>. Acesso em: 25 out. 2021.

STONE, P. J.; SORENSEN, I. B.; JAMIESON, P. D. Effect of soil temperature on phenology, canopy development, biomass and yield of maize in a cool-temperate climate. **Field Crops Research**, Amsterdam, v. 63, n. 2, p. 169–178, 1999.

SUNDMAEKER, H. *et al.* Internet of food and farm 2020. *In: VERMESAN, O.; SINTEF, N. (ed.). Digitising the industry - internet of things connecting physical, digital and virtual worlds.* Belgium: River Publishers, 2016. p. 129–151.

TABARI, H.; TALAEI, P. H. Temporal variability of precipitation over Iran: 1966–2005. **Journal of Hydrology**, Amsterdam, v. 396, n. 3/4, p. 313–320, 2011. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0022169410007304>. Acesso em: 24 jan. 2022.

TABARI, H.; TALAEI, P. H.; WILLEMS, P. Short-term forecasting of soil temperature using artificial neural network. **Meteorological Applications**, Cambridge, v. 22, n. 3, p. 576–585, 2015. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1002/met.1489>. Acesso em: 27 jan. 2022.

TAN, Y.; ZHENG, Z. Research advance in swarm robotics. **Defence Technology**, Amsterdam, v. 9, n. 1, p. 18–39, 2013. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S221491471300024X>. Acesso em: 14 fev. 2022.

TEIXEIRA, A. H. C.; BASTIAANSEN, W. G. M. Five methods to interpret field measurements of energy fluxes over a micro-sprinkler-irrigated mango orchard. **Irrigation Science**, Berlin, v. 30, n. 1, p. 13–28, 2012. Disponível em: <http://link.springer.com/10.1007/s00271-010-0256-y>. Acesso em: 12 jun. 2021.

TEIXEIRA, A. H. C.; BASTIAANSEN, W. G. M.; BASSOI, L. H. Crop water parameters of irrigated wine and table grapes to support water productivity analysis in the São Francisco river basin, Brazil. **Agricultural Water Management**, Amsterdam, v. 94, n. 1/3, p. 31–42, 2007. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0378377407001953>. Acesso em: 27 jul. 2021.

TIEN, J. M. Internet of things, real-time decision making, and artificial intelligence. **Annals of Data Science**, Paris, v. 4, n. 2, p. 149–178, 2017. Disponível em: <http://link.springer.com/10.1007/s40745-017-0112-5>. Acesso em: 30 mar. 2022.

TOPUZ, A. Predicting moisture content of agricultural products using artificial neural networks. **Advances in Engineering Software**, London, v. 41, n. 3, p. 464–470, 2010. Disponível em: <http://dx.doi.org/10.1016/j.advengsoft.2009.10.003>. Acesso em: 19 fev. 2022.

ULLAH, A. *et al.* Prediction of effective climate change indicators using statistical downscaling approach and impact assessment on pearl millet (*Pennisetum glaucum* L.) yield through Genetic Algorithm in Punjab, Pakistan. **Ecological Indicators**, New York, v. 90, n. April, p. 569–576, 2018. Disponível em: <https://doi.org/10.1016/j.ecolind.2018.03.053>. Acesso em: 24 set. 2021.

UNRUH, G. C. Understanding carbon lock-in. **Energy Policy**, Guildford, v. 28, n. 12, p. 817–830, 2000. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0301421500000707>. Acesso em: 6 nov. 2021.

UNTARU, M.; ROTARESCU, V.; DORNEANU, L. Artificial neural networks for sustainable agribusiness: a case study of five energetic crops. **Agrociencia**, Cidade do México, v. 46, n. 5, p. 507–518, 2012. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84869426625&partnerID=40&md5=af10af49e1e3bec1b9356a2f8e717543>. Acesso em: 1 dez. 2021.

VAN DE GEVEL, A. J. W.; NOUSSAIR, C. N. **The nexus between artificial intelligence and economics**. Berlin: Springer, 2013. *E-book*. Disponível em: https://doi.org/10.1007/978-3-642-33648-5_1. Acesso em: 10 jul. 2021.

VASCONCELOS, Â. M. *et al.* Characterize of production systems and milk quality of production units in the semiarid region of Ceará. **Ciência Animal Brasileira**, Goiânia, v. 19, [art.] e-52844, [p. 1–13], 2018. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1809-68912018000100219&lng=en&tlng=en. Acesso em: 17 abr. 2021.

VASILOGLOU, M. *et al.* A comparative study on carbohydrate estimation: GoCARB vs. dietitians. **Nutrients**, Basel, v. 10, n. 6, [art.] 741, 2018. Disponível em: <http://www.mdpi.com/2072-6643/10/6/741>. Acesso em: 31 out. 2021.

VELLOSO, A. L.; SAMPAIO, E.; PAREYN, F. G. C. (ed.). **Ecorregiões: propostas para o bioma caatinga: resultados do Seminário de Planejamento Ecorregional da Caatinga/Aldeia-PE 28 a 30 novembro de 2001**. Recife: Aldeia-PE, 2001.

VENANCIO, L. P. *et al.* Evapotranspiration mapping of commercial corn fields in Brazil using SAFER algorithm. **Scientia Agricola**, Piracicaba, v. 78, n. 4, p. 1–12, 2020. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-90162021000400102&tlng=en. Acesso em: 10 jul. 2021.

VENKATESH, E. T.; THANGARAJ, P. Self-organizing map and multi-layer perceptron neural network based data mining to envisage agriculture cultivation. **Journal of Computer Science**, Washington DC, v. 4, n. 6, p. 494–502, 2008.

VERGARA, S. C. **Projetos e relatórios de pesquisa em administração**. São Paulo: Editora Atlas, 2013.

VIJAYALAKSHMI, J.; PANDIMEENA, K. Agriculture talkbot using AI. **International Journal of Recent Technology and Engineering**, Bhopal, v. 8, n. 2S5, p. 186–190, 2019.

VILELA, E. F.; CALLEGARO, G. M.; FERNANDES, G. W. (org.). **Biomass e agricultura: oportunidades e desafios**. Rio de Janeiro: Vertente Edições, 2019.

VILLANUEVA, M. B.; SALENGA, M. L. M. Bitter melon crop yield prediction using Machine Learning Algorithm. **International Journal of Advanced Computer Science and Applications**, New York, v. 9, n. 3, p. 1–6, 2018.

VINCENT, D. R. *et al.* Sensors driven ai-based agriculture recommendation model for assessing land suitability. **Sensors**, Basel, v. 19, n. 17, [art.] 3667, 2019.

VISSES, F. A.; SENTELHAS, P. C.; PEREIRA, A. B. Yield gap of cassava crop as a measure of food security - an example for the main Brazilian producing regions. **Food Security**, Dordrecht, v. 10, n. 5, p. 1191–1202, 2018. Disponível em: <http://link.springer.com/10.1007/s12571-018-0831-2>. Acesso em: 10 dez. 2021.

VROCHIDOU, E. *et al.* Computer vision in self-steering tractors. **Machines**, Basel, v. 10, n. 2, [art.] 129, 2022. Disponível em: <https://www.mdpi.com/2075-1702/10/2/129>. Acesso em: 2 set. 2021.

WALDHEIM, P. V. *et al.* Zoneamento climático da cana-de-açúcar, da laranja e do algodão herbáceo para a região Nordeste do Brasil. **Anuário do Instituto de Geociências UFRJ**, Rio de Janeiro, v. 29, n. 2, p. 30–43, 2006. Disponível em: http://ppegeo.igc.usp.br/scielo.php?script=sci_arttext&pid=S0101-97592006000200002&lng=pt&nrm=isoPraia. Acesso em: 19 jun. 2021.

WANG, T. *et al.* A bayesian framework for learning rule sets for interpretable classification. **The Journal of Machine Learning Research**, Brookline, v. 18, n. 1, p. 2357–2393, 2017.

WOLFERT, S. *et al.* Big data in smart farming – A review. **Agricultural Systems**, Barking, v. 153, p. 69–80, 2017. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0308521X16303754>. Acesso em: 10 jul. 2021.

XIMENES, L. J. F. **BNB setorial**. Fortaleza: Banco do Nordeste do Brasil, 2018.

XIN, J. *et al.* Development of vegetable intelligent farming device based on mobile APP. **Cluster Computing**, Amsterdam, v. 22, p. 8847–8857, 2019. Disponível em: <https://doi.org/10.1007/s10586-018-1979-4>. Acesso em: 21 jun. 2021.

XUE-LEI, W.; GONG-HU, L. Study on decision support system of agricultural sustainable development of Jianli county in Jiangnan plain. **Wuhan University Journal of Natural**

Sciences, Wuhan, v. 5, n. 3, p. 334–338, 2000.

YASEEN, Z. M. *et al.* Artificial intelligence based models for stream-flow forecasting: 2000–2015. **Journal of Hydrology**, Amsterdam, v. 530, p. 829–844, 2015. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0022169415008069>. Acesso em: 2 abr. 2021.

YASEEN, Z. M. *et al.* Stream-flow forecasting using extreme learning machines: a case study in a semi-arid region in Iraq. **Journal of Hydrology**, Amsterdam, v. 542, p. 603–614, 2016. Disponível em: <http://dx.doi.org/10.1016/j.jhydrol.2016.09.035>. Acesso em: 27 nov. 2021.

YIN, R. K. **Estudo de caso: planejamento e métodos**. Rio de Janeiro: Bookman, 2015.

YU, Y. *et al.* Spatiotemporal changes in water, land use, and ecosystem services in Central Asia considering climate changes and human activities. **Journal of Arid Land**, Beijing, v. 13, n. 9, p. 881–890, 2021. Disponível em: <https://doi.org/10.1007/s40333-021-0084-3>. Acesso em: 30 nov. 2021.

YU, H. *et al.* Uncertainty analysis of artificial intelligence modeling daily reference evapotranspiration in the northwest end of China. **Computers and Electronics in Agriculture**, Amsterdam, v. 176, [art.] 105653, 2020. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/S0168169920304889>. Acesso em: 10 jul. 2021.

ZARE, M.; KOCH, M. Hybrid signal processing/machine learning and PSO optimization model for conjunctive management of surface–groundwater resources. **Neural Computing and Applications**, London, v. 33, n. 13, p. 8067–8088, 2021. Disponível em: <https://doi.org/10.1007/s00521-020-05553-8>. Acesso em: 22 nov. 2021.