



Gestão no meio agrícola com o apoio da Inteligência Artificial: uma análise da digitalização da agricultura

Agricultural management through Artificial Intelligence: an analysis of digitization of agriculture

Marcelo da Costa Borba¹, Josefa Edileide Santos Ramos², Bibiana Melo Ramborger²,
Eduardo Oliveira Marques², João Armando Dessimon Machado³

RESUMO: A aplicação da inteligência artificial aos dados dos sensores e os sistemas de gerenciamento de fazendas estão 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, através do gerenciamento e tomada de decisão mais precisos, assim como otimizando a lucratividade, a produtividade e a sustentabilidade, 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: Aprendizado de máquina. Árvore de decisão. *E-agriculture*. Robótica.

ABSTRACT: The application of artificial intelligence to sensor data and management systems in farms are developing to follow-up programs in real time, furnishing recommendations and insights in activities and support to farmers' decisions. A review on the application of artificial intelligence in agricultural production is provided. Types of research were listed (a) neural networks; (b) supervised learning and (c) dynamic methods. Categorization of articles showed the manner agriculture may benefit by technologies through artificial intelligence by management, more precise decision-taking, optimization of profits, productivity and sustainability. This results in methods with great efficiency when integrated to a robust information system constructed on functions that may be managed by users.

Keywords: Machine learning. Decision tree. *E-agriculture*. Robotics.

Autor correspondente:

Marcelo da Costa Borba: marcelodcborba@gmail.com

Recebido em: 21/09/2020

Aceito em: 14/05/2021

INTRODUÇÃO

As constantes mudanças no ambiente agrícola têm exigido cada vez mais soluções equilibradas e contínuas, em face da diminuição na disponibilidade de mão de obra, da maior demanda por recursos naturais, da escassez média de recursos agrícolas, da alta idade média

¹ Doutor em Agronegócios na linha de Pesquisa de Gestão, Inovação, Tecnologia e Qualidade no Agronegócio no Programa de Pós-Graduação em Agronegócios da Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre (RS), Brasil.

² Doutorandos em Agronegócios pela Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre (RS), Brasil.

³ Doutor em Economia Agroalimentar pela Universidade de Córdoba, UCO, Espanha. Professor titular junto ao Departamento de Economia e Relações Internacionais/FCE da UFRGS na graduação e pós-graduação. Porto Alegre (RS), Brasil.

dos agricultores e da baixa renovação da população agrícola (FENG, 2019; LI; YANG, 2018). 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 (ROOPAEL; 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; LEZOCHÉ *et al.*, 2020).

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

Devido à relevância do assunto, algumas revisões foram produzidas nos últimos anos com o intuito de analisar a influência da inteligência artificial no meio agrícola. Alguns desses trabalhos, como o de Rooh, Li e Ali (2015), apresentam 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 (assimiladas) 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) apresentam implicações do estilo do agricultor para a condução situacional da decisão frente à incorporação da IA, assim como tratam 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. 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 como uma revisão que integra os conceitos e a aplicabilidade dos campos da IA, baseados na atividade

agrícola. Também serão analisados os métodos e ramificações da inteligência artificial como suporte para a melhor tomada de decisão, em que os métodos podem ser bem eficazes ao serem integrados a um sistema de informação geral, constituído por funções que podem ser geridas pelo proprietário agrícola. A estrutura deste trabalho segue: 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 - são abordadas conclusões do estudo e as expectativas futuras.

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 de caracteres em inglês para formar a *string* de busca ("*artificial intelligence*" AND *Agric** OR *Agribusiness* OR *Farm** OR *e-agriculture*). As bases de dados foram escolhidas em decorrência de sua ampla cobertura da literatura relevante ao tema proposto, e ainda por recursos bibliométricos avançados, como sugerir literatura relacionada ou citações. O idioma escolhido foi o inglês, por representar a língua com a maior quantidade de publicações nessas bases. Teve o período de 2000 a 2019 como tempo de análise, esse tempo representa um recorte de vinte anos dentro da pesquisa sobre a temática, assim como por corresponder ao período com maior regularidade 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 cinco etapas: (i) busca nas bases com a seleção e extração dos dados a serem importados para a identificação e eliminação dos trabalhos duplicados; (ii) leitura do título, resumo e palavras-chave - sendo necessário que esses elementos apresentassem alguma ligação à pergunta de pesquisa; (iii) leitura da introdução e conclusão - foi considerado o fato de haver na introdução ou na conclusão indícios que respondessem à questão da revisão; (iv) 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 (v) análise e síntese das evidências - localização e separação das cotas que efetivamente respondiam à questão proposta pela revisão (Figura 1)

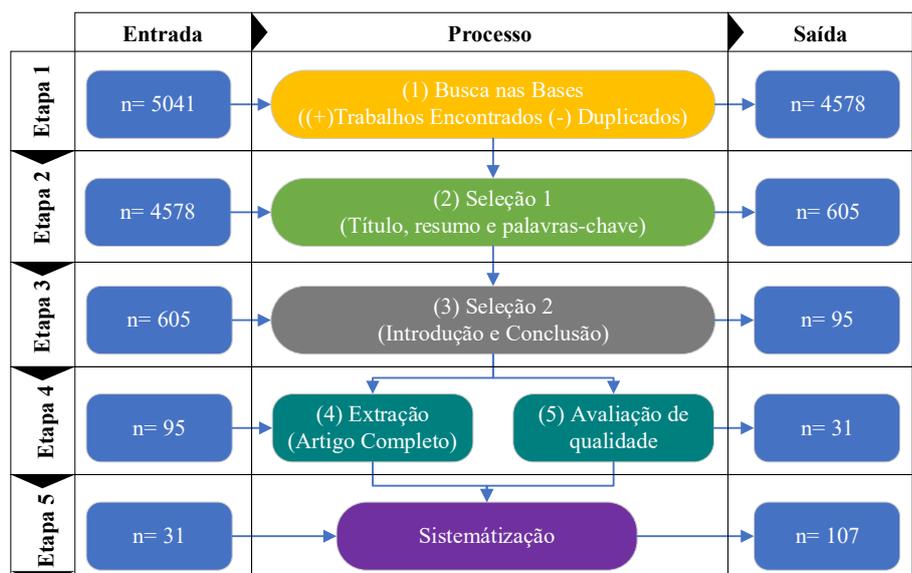


Figura 1. Etapas da pesquisa e revisão.
Fonte: Dados da Pesquisa (2020).

A revisão sistemática seguiu o protocolo de Principais Itens para Relatar Revisões Sistemáticas e Meta-análises - PRISMA (2009), por considerá-lo uma estrutura metodológica de fácil aplicação. A pesquisa foi desenvolvida no período de janeiro a junho de 2020, sendo conduzida por quatro pesquisadores (três executores e um supervisor), apoiada pelos *softwares*: StArt (3.3 Beta 03) para a organização dos dados e Mendeley (1.19.4) para a gestão bibliográfica.

3 RESULTADOS E DISCUSSÃO

A atividade agrícola na maioria dos países desempenha papel crítico, tanto em fatores econômicos quanto ocupacionais (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 eficiente 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).

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 o monitoramento em tempo real das atividades de forma autônoma, visando analisar dados operacionais combinados com informações de terceiros, como os serviços meteorológicos e conselhos de especialistas, para fornecer ideias e melhorar a tomada de decisão (HUTSON, 2017; KARGAR; SHIRZADIFAR, 2013) (Figura 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) (Figura 2).

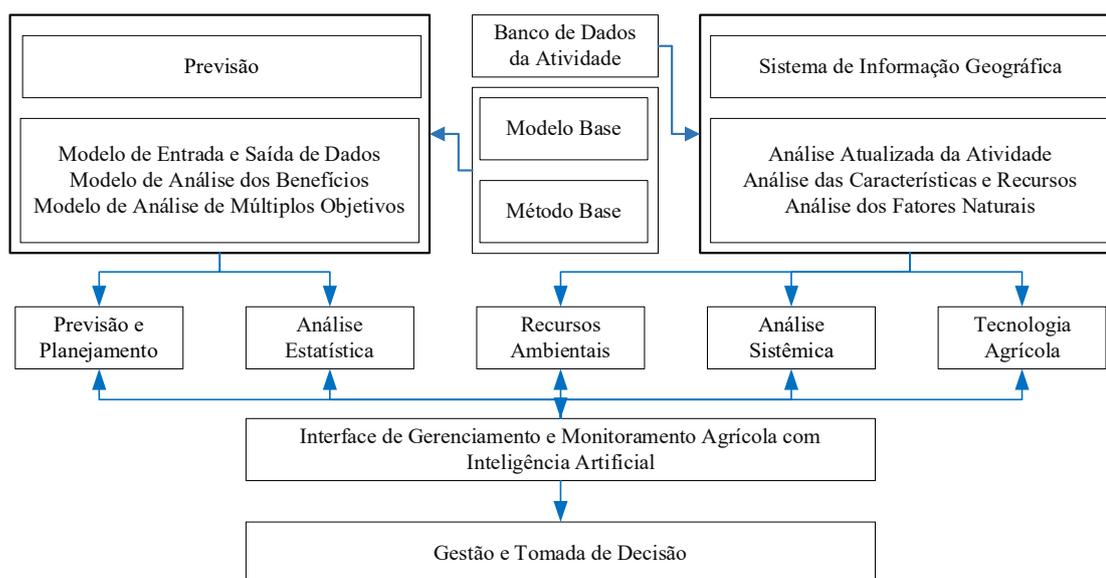


Figura 2. Estrutura de fatores para a gestão e tomada de decisão com interface de IA na Atividade Agrícola.

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

A gestão e a 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 nas tomadas de decisões, bem como ampliar a consistência e a qualidade delas, expressa em características e

recursos (MAHMOUD; M RAFAE; A RAFAE, 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).

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 para a classificação da imagem (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 (Figura 3).

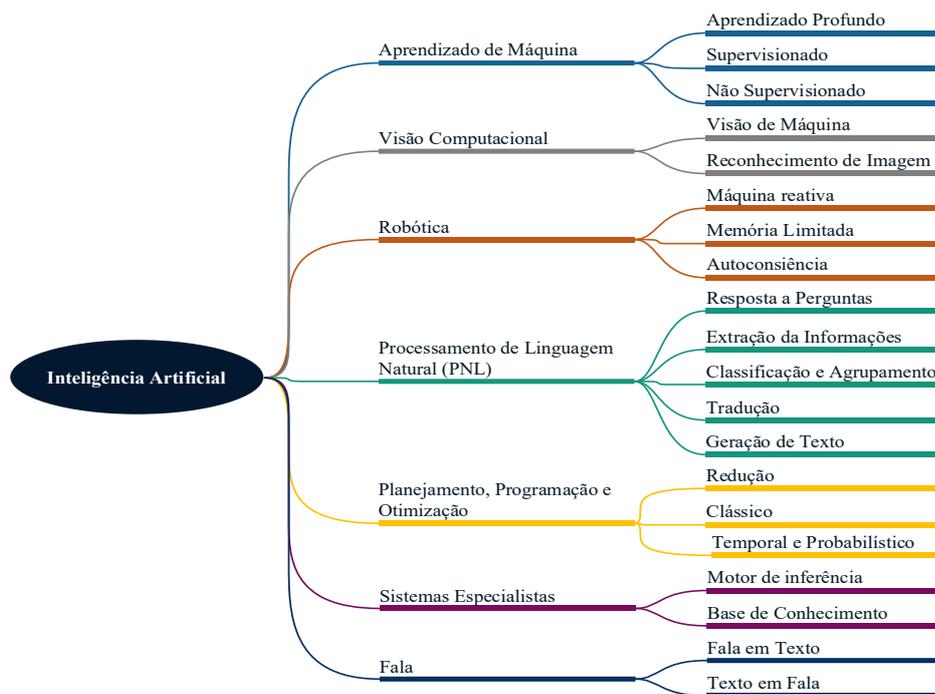


Figura 3. Campos de Inteligência Artificial.
Fonte: Adaptado de Villaneuva e Salenga (2018).

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 informações 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 a 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 para uma 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 estejam 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*) são o campo da integração do conhecimento a relatórios e projetos de extensão tradicionais, objetivando fornecer conselhos gerais que auxiliem na gestão da propriedade agrícola (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 de texto ou de fala (VIJAYALAKSHMI; PANDIMEENA, 2019). A saída textual gerada é passada pelas 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, obtendo a resposta em texto e fala de modo que o aprimoramento futuro possa ser feito e a saída seja constituída na linguagem local (VIJAYALAKSHMI; PANDIMEENA, 2019).

Como visto na Figura 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, e seus respectivos métodos. A seguir, eles serão apresentados por meio da organização em três tópicos: redes neurais artificiais, aprendizagem supervisionada e métodos dinâmicos.

3.2 REDES NEURAIAS ARTIFICIAIS

Nas revisões, a ANN foi o método mais citado, tanto pela facilidade de programação, como por ser 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), ao abordar, principalmente, a previsão de produtividade, a modelagem espacial (manejo de irrigação e índices de vegetação espectral) e a previsão espaço-temporal (séries temporais do rendimento em um tempo específico) (Quadro 1).

Quadro 1. Quadro das propostas de aplicações 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 minimizar 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 aveia, 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 autônomos de baixo custo, fácil 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 os 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 análise descritiva, geoestatística, 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.
Mehdzadeh (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.	Sistema de Inferência Fuzzy (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, conhecidas como Rede Neural com Retardo de Tempo (TDNN - *Time Delay Neural Network*) (RATHOD *et al.*, 2018). Pode ocorrer ainda 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 avaliar as terras agrícolas adequadas e inadequadas para cultivo de determinado produto.

No modelo *Perceptron* Neural de Múltiplas Camadas (MLP - *Multi-Layer Neural Perceptron*) é usada 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 de domínio por meio do agrupamento multiclasses: 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 baseado no método de suspensão/ativação por um período de tempo predefinido.

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). O aprendizado supervisionado pode ser aplicado para configurar um procedimento de execução de previsões, por exemplo, de classificação, regressão, regressão linear e regressão logística (RATHOD *et al.*, 2018). Essa

modalidade representa a entrada da informação já preparada e sujeita ao algoritmo (VENKATESH; THANGARAJ, 2008). No Quadro 2, são apresentados alguns desses algoritmos, predominantemente encontrados ao longo dos trabalhos analisados. Cabe destacar que as ANNs também são partes da aprendizagem supervisionada, mas foram colocadas no quadro anterior pela relevância e quantidade de citações nos trabalhos selecionados.

Quadro 2. Quadro das propostas de aplicações 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.	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 à 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 <i>stakeholders</i> 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 <i>design</i> 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 à 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.	Algoritmo Genético (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 <i>software</i> , através do acoplamento magnético dos atuadores conectados ao dispositivo.

Fonte: Dados da Pesquisa (2020).

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, mostrando 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 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 como operadores principais a competição e a 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, o que pode favorecer a proteção ambiental (ALZOUBI; ALMALIKI; MIRZAEI, 2019).

Já o algoritmo de Vizinhos Mais Próximos (*Nearest Neighbors*) 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 tráfego de dados (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). Esse é 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.

3.4 MÉTODOS DINÂMICOS

Os métodos dinâmicos são classificados por reunir métodos com características próximas em relação à 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) (Quadro 3).

Quadro 3. Quadro das propostas de aplicações 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 de 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 <i>et al.</i> (2016)	Suécia	Analisar o treinamento e o teste de máquinas de vetores de suporte para uma detecção e alerta precoce de problemas relacionados à 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 Bhrmaramba (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 de 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). 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 possuem funções similares a uma Rede de Sensores Sem Fio (WSN - *Wireless Sensor Network*), que realizam o monitoramento distribuído por meio de um grande número de nós de microssores 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 enviar *feedbacks* 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 muito atraente, criando a possibilidade de desempenho superior em comparação aos modelos convencionais validados. A Figura 4 apresenta as abordagens concentradas em torno dos métodos de aprendizado de máquinas encontrados na extração dos dados e seus métodos e suas ramificações.

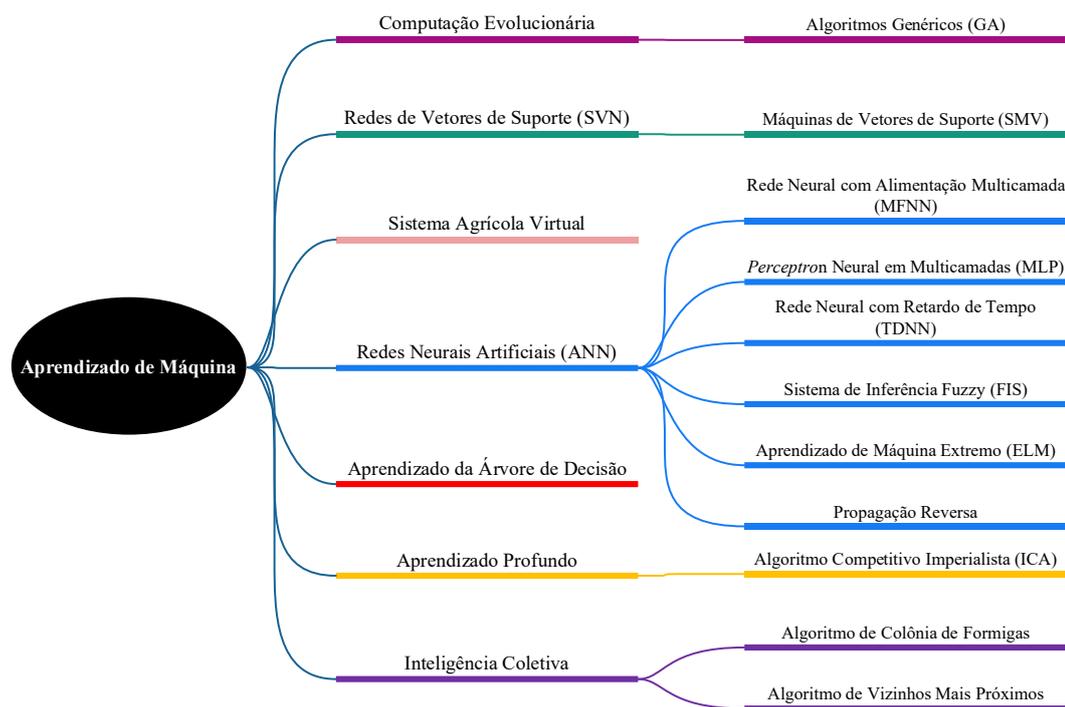


Figura 4. Métodos de Aprendizado de Máquina encontrados nesta pesquisa.
Fonte: Adaptado de Aristodemou e Tietze (2018).

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.

4 CONSIDERAÇÕES FINAIS

Esta revisão teve por objetivo analisar como a inteligência artificial está sendo utilizada no meio agrícola: campos, métodos e aplicações no período de 2000 a 2019. Ao apresentar os campos ou ramificações da IA esta revisão traz alternativas já desenvolvidas na atividade agrícola que se tornaram suporte aos sistemas das fazendas, pois oferecerem recomendações e *insights* mais ricos para a tomada de decisão e melhoria das etapas da cadeia de suprimentos agrícolas. Essa relação forma um registro automatizado de dados, análise, implementação e gestão agrícola baseada na gestão do conhecimento.

Para isso, espera-se que o uso dos métodos de IA seja ainda mais difundido, permitindo a integração com seus campos. 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 e mais eficientes no meio rural para melhor atender à crescente demanda por alimentos - fator vital para a prosperidade econômica do setor agrícola e segurança alimentar.

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 micro-organismos em alimentos (LATORRE-BIEL *et al.*, 2013). Ou até mesmo monitorar o desenvolvimento animal como cria, recria, engorda, abate, comercialização. A 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 o foco em campos específicos da IA, como forma de expandir os conhecimentos em cada ramificação como o uso da visão computacional ou Algoritmo Genético no meio agrícola.

5 AGRADECIMENTOS

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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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, v. 21, n. 5, p. 71-85, 2001. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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**, Jakarta, v. 7, n. 6, p. 3492-3499, 2017. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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>.
- ROOPAEL, 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. DOI: <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. DOI: <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: [s. n.], 2017. p. 12-23. DOI: 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. DOI: <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. 7, p. 356-361, 2011. DOI: <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. DOI: <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. DOI: <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, v. 4, n. 6, p. 494-502, 2008. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <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. DOI: <https://doi.org/10.1007/bf02830149>.