

COMO O USO DA INTELIGÊNCIA ARTIFICIAL TEM CONTRIBUÍDO COM A CULTURA DO AMENDOIM?

HOW HAS THE USE OF ARTIFICIAL INTELLIGENCE CONTRIBUTED TO THE PEANUT CULTURE?

Diego Cezar Dalpian – diegodalpian@hotmail.com
 Faculdade de Tecnologia de Taquaritinga (Fatec) – Taquaritinga – SP – Brasil

Oswaldo Lázaro Mendes – oswaldo.lazaro@fatectq.edu.br
 Faculdade de Tecnologia de Taquaritinga (Fatec) – Taquaritinga – SP – Brasil

DOI: 10.31510/infa.v19i2.1478

Data de submissão: 01/09/2022

Data do aceite: 28/11/2022

Data da publicação: 20/12/2022

RESUMO

O amendoim é um importante alimento que contribui para a segurança alimentar mundial. Esse estudo bibliométrico exploratório usou a base *SCOPUS* como consulta e buscou mostrar quais estudos, com o uso da inteligência artificial, foram feitos nos últimos dez anos na cultura do amendoim. O resultado mostrou que são poucos os estudos com esse tema e que a aplicação da inteligência artificial aos dados dos sensores de gerenciamento e de tomada de decisão, podem contribuir com os produtores e gestores na assertividade da sua administração, podendo assim, agregar valor aos produtos, aumentar a lucratividade, a produtividade, e a sustentabilidade dos negócios agrícolas, por meio da compreensão do conjunto de dados.

Palavras-chave: Aprendizado de máquina. *E-agriculture*. Sensoriamento remoto. Gestão estratégica

ABSTRACT

Peanut is an important food that contributes to world food security. This exploratory bibliometric study used the SCOPUS database as a query and sought to show which studies, with the use of artificial intelligence, were carried out in the last ten years in the peanut crop. The result showed that there are few studies on this topic and that the application of artificial intelligence to data from management and decision-making sensors can contribute to producers and managers in the assertiveness of their administration, thus being able to add value to products, increase the profitability, productivity, and sustainability of agricultural businesses by understanding the data set.

Keywords: Machine learning. *E-agriculture*. Remote sensing. Strategic management

1 INTRODUÇÃO

A segurança alimentar tornou-se uma preocupação cada vez mais global, o que deve ficar ainda mais evidente após a crise do COVID-19, (PETETIN, 2020). O crescimento populacional tem levado a um aumento da demanda por alimentos, que pode ser atendido aumentando a área plantada, distribuição e produtividade, reduzindo desperdícios e alterando os padrões de consumo de alimentos.

O amendoim é uma cultura que tem grande importância socioeconômica no Brasil. Esse grão é uma oleaginosa originária da América do Sul, pertencente à família Fabaceae. Atualmente, ocupa área plantada de aproximadamente 200 mil hectares, com produção de mais de 800 mil toneladas, resultando em produtividade média de 3,9 t ha⁻¹, sendo o estado de São Paulo responsável por 90% da produção nacional. A cultura segue em expansão pelo país, com previsão de crescimento em termos de área plantada, produção e produtividade (CONAB, 2022).

Além disso, o amendoim após o processo de secagem na indústria poderá ser utilizado tanto *in natura*, como também para a extração do óleo que será empregado nas indústrias, por ser rico em proteínas e lipídios, ressalta-se que o mesmo é definido como um alimento que possui um grande valor nutricional (CUNHA *et al.*, 2013). O estudo de Tucunduva (2013) mostra que a cada 100g de amendoim, é possível obter cerca de 4 mcg de selênio, 0,66mg de vitamina E e 16,5g de gordura poli-insaturada, sendo o amendoim considerado um alimento funcional. Por essas razões o amendoim contribui positivamente com a segurança alimentar mundial.

Assim como em todas as áreas do conhecimento, pesquisas com uso da Inteligência Artificial IA tem recebido atenção. O presente estudo tem como objetivo, apresentar de forma bibliométrica e exploratória os estudos dos últimos dez anos que abordam o uso da IA na cadeia produtiva do amendoim e, destacar de que forma a IA tem contribuído para o desenvolvimento de melhorias dessa cultura.

2 FUNDAMENTAÇÃO TEÓRICA

A inteligência artificial IA é a técnica do sistema para traduzir corretamente dados externos, aprender e usar dessa aprendizagem para atingir objetivos e tarefas específicas por meio de adaptação flexível (KAPLAN; HAENLEIN, 2019). Propor a modernização do

agrícola, com a adesão da inteligência artificial, tem sido uma alternativa para agricultores vencerem as dificuldades como a redução da disponibilidade de mão de obra, da maior demanda de recursos naturais, da escassez média de recursos agrícolas, da reduzida renovação da população agrícola (FENG, 2019; LI; YANG, 2018).

Segundo Perini (2004) a promoção da inteligência artificial no campo pode estimular 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. Já Li (2018) alerta que considerando a grande variedade de métodos dentro da IA, é fundamental conhecer as características individuais e dos métodos e os possíveis cenários para seu uso.

No setor agrícola a Agricultura Inteligente (*Smart Farm*) ou *Agriculture 4.0* foi fortemente impulsionada pela IA, devido o desenvolvimento de tecnologias inteligentes como a Internet das Coisas - IoT (LI; YANG, 2018; PIVOTO et al., 2018) Computação na Nuvem (ROOPAEI; 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).

É possível monitorar de forma autônoma as atividades no campo agrícola e em tempo real com a utilização da IA. Essa prática possibilita estudar dados operacionais combinados com informações de terceiros, como os serviços meteorológicos e conselhos de especialistas, para entregar propostas e melhorar a tomada de decisão (HUTSON, 2017; KARGAR; SHIRZADIFAR, 2013). A IA apresenta como importância a simulação de simulação dos dados bom objetivo de gerar conhecimento importante e facilitar decisões estratégicas aos produtores (HASHIMOTO et al., 2001), sendo assim, a IA ordena que uma máquina (computador) reconheça elementos em seu ambiente (recursos ambientais, tecnologias existentes) e devolva ao usuário - um ser humano ou outra máquina - algumas orientações ou informações (análises estatísticas, sistêmicas) que apoie o receptor a atingir objetivos como, planejamento, previsão e tomada de decisão (KUMAR; BHARAMARAMBA, 2017).

A IA tem apresentado um papel importante no desenvolvimento de cultivares leguminosas. O estudo de Harfouche *et. al* (2019) mostrou que a seleção de cultivares com as melhores características, principalmente sob condições de estresse, requer a modelagem de dados genômicos e fenônicos de forma a proporcionar o melhor rendimento com o mínimo de custo e esforço. Os dados MOI são dados multidimensionais, heterogêneos e complexos

que requerem soluções avançadas para sua aplicação em tecnologias de melhoramento de plantas. Ainda segundo Harfouche *et al.*, (2019) com o avanço das tecnologias de IA, o desenvolvimento de variedades de culturas climáticas inteligentes com maior rendimento pode aumentar a tolerância/resistência a vários estresses abióticos e pode produzir maiores ganhos genéticos em menos tempo (HARFOUCHE, *et al.*, 2019).

Um estudo realizado por Borba *et al.*, (2021) mostrou que a aplicação de métodos de IA circula pela captação de diferentes atores como o sistema agrícola virtual, detecção precoce do patógeno de pragas e doenças que é a visão de máquina, exploração de culturas, monitoramento dos limites da fazenda (propagação reversa), estruturas de irrigação e até a vigilância do rebanho com os dispositivos integrados no sistema de produção agrícola, como a árvore de decisão. O estudo concluiu que os métodos tem potencial de eficácia corroborando com um sistema de informação geral, integrado por funções que podem ser geridas pelo proprietário agrícola.

3 PROCEDIMENTOS METODOLÓGICOS

A metodologia usada foi uma pesquisa bibliométrica exploratória de abordagem qualitativa e quantitativa com a busca de estudos publicados na base científica *Scopus*, sobre o tema o uso da inteligência artificial na produção do amendoim. A pesquisa cumpriu uma sequência de três fases que envolveram os critérios de seleção dos periódicos, o acesso aos artigos, análise dos artigos com a leitura e a seleção daqueles que tratavam do uso da IA no campo agrícola com ênfase na produção do amendoim e por fim, a apresentação dos resultados. No quadro 1 é apresentado as fases realizadas para selecionar os artigos que foram discutidos.

Quadro 1:Fases da pesquisa

Fases	Procedimentos/critérios
Fase 01	Foi escolhida a base de dados <i>Scopus</i> para realizar as pesquisas desse estudo, em virtude da sua alta representatividade da academia internacional.
Fase 02	A pesquisa nas bases de dados <i>Scopus</i> sobre o tema a inteligência artificial na produção do amendoim, foi acessada pelo site da Capes através do <i>link</i> de periódicos da <i>Scopus</i> . O intervalo de tempo selecionado foi de 2012-2022.

Fase 03	Foram usadas as palavras-chave: <i>peanut; artificial intelligence</i> ; como critério de seleção dos artigos constituintes da amostra.
----------------	---

Fonte: adaptado de (SCHNEIDERS; ALBUQUERQUE) 2019

4 RESULTADOS E DISCUSSÃO

Para discussão foram escolhidos doze trabalhos achados na base *SCOPUS* que mostram resultados com uso da inteligência artificial na cultura do amendoim. O Quadro 2 mostra o ano, o título, os autores e o objetivo de cada estudo, e na sequência serão discutidos os resultados de cada achado.

Quadro 2. Estudos escolhidos para discussão

ANO	TÍTULO	AUTORES	OBJETIVO
2022	We got nuts! use deep neural networks to classify images of common edible nuts	An, R., Perez-Cruet, J., Wang, J.	Classificação com uso de imagens
2022	Peanut leaf spot disease identification using pre-trained deep convolutional neural network	Patayon, U.B., Crisostomo, R.V.	Criação de um modelo que pode identificar a doença da mancha foliar por imagem
2022	Using UAV and Multispectral Images to Estimate Peanut Maturity Variability on Irrigated and Rainfed Fields Applying Linear Models and Artificial Neural Networks	Santos, A.F., Lacerda, L.N., Rossi, C., (...), Silva, R.P., Vellidis, G.	Comparação e validação a regressão linear e múltipla linear com modelos utilizando artificial redes neurais (ANN).
2021	Fab advances in fabaceae for abiotic stress resilience: from ‘omics’ to artificial intelligence	Singh, D., Chaudhary, P., Taunk, J., (...), Yadav, R.K., Pal, M.	Algoritmos baseados em (AI) podem ser utilizados para simulação o rendimento das culturas em ambientes em mudança.
2021	Use of artificial intelligence for optimizing biosorption of textile wastewater using agricultural waste	Aghilesh. K, Agarwal, S., Garg, M.C., Joshi, H.	Metodologia de Superfície de Resposta (RSM) Artificial A Rede Neural (RNA) e o Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS) foram utilizados para obter condições ótimas para a remoção do Azul de Metileno.
2020	Based on the Network and Information Technology, the Actual Performance Evaluation System of Heavy Metal Removal Biomass Materials in Water Was Developed	Liu, M.	Combinado com a tecnologia da informação com uso de outras tecnologias para construção do sistema de avaliação que combine tecnologia da informação e desenvolvimento de química biológica.
2020	Efficient Catalytic Conversion of Waste Peanut Shells into Liquid Biofuel: An Artificial Intelligence Approach	Li, P., Du, Z., Chang, C., (...), Xu, G., Xu, C.C.	Uso de uma metodologia híbrida compreendendo artificial rede neural (RNA) e algoritmos genéticos (GA) foram utilizados para modelação e otimização do processo de metanólise de resíduos amendoim.
2017	Portable spectroscopy	Yang, M., Chen,	Monitoramento eficiente e em tempo real do

	system determination of acid value in peanut oil based on variables selection algorithms	Q., Kutsanedzie, F.Y.H., (...), Guo, Z., Ouyang, Q.	valor ácido (AV) em amendoim óleo.
2015	An integrated crop model and GIS decision support system for assisting agronomic decision making under climate change	Kadiyala, M.D.M., Nedumaran, S., Singh, P., (...), Irshad, M.A., Bantilan, M.C.S.	Analise da variabilidade espacial dos impactos das mudanças climáticas na produção de amendoim de Anantapur.
2015	Applying machine learning algorithms and WorldView-2 satellite imagery to classify crop types	Li, W.-L., Lee, R.-Y., Lei, T.-C., Shiu, Y.-S.	Estudo do uso de algoritmos de aprendizado de máquina e o classificador tradicional de máxima verossimilhança para classificar milho, amendoim, adubação verde e outras categorias
2013	Development, uncertainty and sensitivity analysis of the simple SALUS crop model in DSSAT	Dzotsi, K.A., Basso, B., Jones, J.W.	Integração a versão simples do modelo de cultura SALUS (System Approach to Land Use Sustainability) no amplamente utilizado Sistema de Apoio à Decisão para Transferência de Agrotecnologia (DSSAT) para aumentar a capacidade do DSSAT.
2012	Quality control and rancidity tendency of nut mix using an electronic nose	Yoshida, K., Ishikawa, E., Joshi, M., (...), Ayouni, F., Bonnefille, M.	Uso de um nariz eletrônico para identificar as causas do ranço em misturas de nozes e monitorar a qualidade sensorial global.

Fonte: elaborado pelo autor (2022).

Os autores An *et.al.*, (2022) construíram um conjunto de dados de imagens de nozes e o usou para treinar um modelo de rede neural para classificar imagens por tipo de noz. O modelo de rede neural treinado previu corretamente 338 de 440 imagens (40 por tipo de noz) no conjunto de validação, alcançando 99,55% de precisão. Além disso, o modelo classificou as 440 imagens do conjunto de teste com 100% de precisão. O modelo alcançou precisão quase perfeita nos conjuntos de validação e teste, demonstrando a viabilidade de automatizar a classificação de tipos de castanhas usando fotos de smartphones. Sendo de código aberto, o conjunto de dados e o modelo podem auxiliar no desenvolvimento de aplicativos de rastreamento de dieta que facilitam a adoção e adesão dos usuários a uma dieta saudável.

Já Patayon *et al.*, (2022) mostrou que o DenseNet-169 treinou usando estocástico gradiente descendente SGD com momentum, Adam, e o propagação quadrática média RMSProp atingiu a mais alta precisão de 98%, enquanto o DenseNet-169 treinado usando RMSProp alcançou a mais alta precisão de 98% entre as arquiteturas de rede neural convolucionais profundas pré-treinadas. Além disso, este resultado pode ser benéfico em sistemas de automação agrícola e identificação de doenças para amendoim ou plantas de amendoim.

O estudo de Santos *et al.*, (2022) mostrou que independentemente da arquitetura da RNA usada para prever variáveis complexas e não lineares, maturidade do amendoim pode

ser estimada com precisão por meio de modelos com múltiplas entradas usando índices de vegetação (VIs) e graus-dia de crescimento ajustados (Agdd). Embora a precisão dos modelos Multilayer Perceptron (MLP) ou Multilayer Perceptron (RBF) para áreas irrigadas e de sequeiro separadamente tenha sido alta, os modelos gerais de RNA usando áreas irrigadas e de sequeiro podem ser usados para prever maturidade do amendoim com a mesma precisão.

A integração de pan-iônicas com novas abordagens de ômicas acelerará os programas de melhoramento de leguminosas. Além disso, a inteligência artificial Algoritmos baseados em (AI) podem ser utilizados para simular o rendimento das culturas em ambientes em mudança, o que pode ajudar a prever o ganho genético de antemão. A aplicação de aprendizado de máquina (ML) na mineração de loci de características quantitativas (QTL) ajudará ainda mais na determinação dos determinantes genéticos da tolerância ao estresse abiótico em pulsos (SINGH *et al.*, 2021).

Em um estudo com o uso da inteligência artificial os autores Aghilesh *et al.*, (2021) mostraram que a Metodologia de Superfície de Resposta RSM pode ser usada para determinar a condição ideal para remoção adsorptiva de Azul de Metileno MB e técnicas de modelagem para bioassorção em resíduos agrícolas como bagaço de cana e casca de amendoim.

Já o autor Liu (2020), mostrou que combinado com a tecnologia da informação, o uso de microscopia eletrônica de varredura (sem) análise, área de superfície específica e adsorvente para a caracterização do espectro infravermelho análise e estudo, tempo de adsorção, pH, quantidade de aditivo adsorvente, temperatura, força iônica, competição do efeito de adsorção de Cd sobre o efeito de adsorção, construiu o sistema de avaliação, no final, e avaliou a eficiência de remoção de material da eficiência do experimento. O autor identificou que a eficiência de todos são mais de 92%, o que é benéfico para a combinação de tecnologia da informação e desenvolvimento de química biológica do amendoim entre outros tipos de biomassa.

O autor Li *et al.*, (2018) sugeriu que com o uso de uma metodologia híbrida compreendendo artificial rede neural (RNA) e algoritmos genéticos (GA) para modelar e otimizar o processo de metanolise de resíduos amendoim, foi possível mostra que as cascas de amendoim podem ser usadas como potenciais matérias-primas para a produção de biocombustível líquido levulinato de metila ML e o algoritmos genéticos ANN-GA pode servir como uma ferramenta poderosa para a tecnologia de processamento de biocombustíveis.

Com o uso de monitoramento eficiente e em tempo real do valor ácido (AV) em óleo de amendoim, mostrou que os métodos de seleção de variáveis puderam selecionar variáveis mais significativas e melhorar o desempenho do modelo, principalmente para o modelo GA-Si-PLS que apresentou melhor resultado (YANG et al., 2017).

Os autores Kadiyala *et al.*, (2015) com uso do modelo da variabilidade espacial e sistemas de informações geográficas SIG revela que os rendimentos de amendoim podem ser aumentados em média em 1,0%, 5,0%, 14,4% e 20,2%, adotando opções de adaptação de tolerância ao calor, cultivares tolerantes à seca, irrigação suplementar e uma combinação de cultivar tolerância à seca e irrigação suplementar, respectivamente. Os autores mostram que os padrões espaciais dos benefícios relativos das opções de adaptação foram geograficamente diferentes e os maiores benefícios podem ser alcançados com a adoção de novas cultivares tolerantes à seca e com a aplicação de uma irrigação suplementar aos 60 dias após a semeadura.

Os autores Li *et al.*, (2015) mostram que o classificador de probabilidade máxima (ML) convencional ainda é o mais eficaz classificador para classificar e interpretar imagens de satélite.

Dzotsi *et al.*, (2013) mostraram que a incerteza dos parâmetros em seu estudo resultou em uma alta variabilidade nas saídas modeladas. A biomassa potencial simulada acima do solo variou de 1,2tha-1 a 38tha-1 para milho e 4tha-1 a 26,5tha-1 para amendoim e algodão, todos os locais e anos considerados. O grau de variabilidade dependia do nível de produção, da localização, do ano e da cultura. A classificação dos parâmetros da cultura não foi significativamente afetada pelo ano de estudo, mas foi fortemente relacionada ao nível de produção, localização e cultura. O modelo não foi sensível aos parâmetros relacionados à predição do momento de germinação e emergência. Os parâmetros mais influentes foram relacionados ao crescimento do índice de área foliar, duração da safra e acúmulo de tempo térmico. Os resultados deste estudo contribuíram para a compreensão dos efeitos da incerteza dos parâmetros da cultura nos resultados do modelo sob diferentes condições ambientais (DZOTSI *et al.*, 2013).

Com o uso de um nariz eletrônico baseado em Flash GC que foi usado para identificar as causas do ranço em misturas de nozes e monitorar a qualidade sensorial global apresentou que o amendoim foi o ingrediente mais crítico no desenvolvimento de sabores desagradáveis de ranço (YOSHIDA *et al.*, 2012).

5 CONCLUSÃO

Em se tratando do uso de tecnologias na cadeia de produção do amendoim as possibilidades e contribuições encontradas são múltiplas, e puderam ser apresentadas nos estudos escolhidos para essa discussão, sendo esses: a classificação com uso de imagens, criação de um modelo que pode identificar a doença da mancha foliar por imagem, comparação e validação a regressão linear e múltipla linear com modelos utilizando redes neurais artificial (ANN), a artificial inteligência algoritmos baseados em (AI) podem ser utilizados para simulação do rendimento das culturas em ambientes em mudanças climáticas, Metodologia de Superfície de Resposta (RSM), Artificial A Rede Neural (RNA) e o Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS) utilizados para obter condições ótimas para a remoção do Azul de Metileno, e o combinado com a tecnologia da informação com uso de outras tecnologias para construir o sistema de avaliação.

Ao apresentar os estudos da IA na cultura do amendoim, foi mostrado possibilidades já desenvolvidas nas práticas agrícolas que se tornaram, e algumas podem se tornar suporte aos sistemas de gestão para tomada de decisão nas fazendas, pois oferecem instruções e visão mais assertiva com melhorias das etapas da cadeia de suprimentos agrícolas. Importante evidenciar que essa relação proporciona um registro automatizado de dados, análise, implementação e gestão agrícola baseada na gestão do conhecimento.

Sendo assim, com a contribuição da IA na cultura do amendoim é oportuna, visto que o gerenciamento e a tomada de decisão podem tornar-se mais precisos, podendo agregar valor aos produtos, aumentar a lucratividade, a produtividade, e a sustentabilidade dos negócios agrícolas, por meio da compreensão do conjunto de dados, contribuindo assim com a segurança alimentar e a saúde do planeta que é uma preocupação mundial.

REFERÊNCIAS

AGHILESH K, AJAY KUMAR, SMRITI AGARWAL, MANOJ CHANDRA GARG & HIMANSHU JOSHI (2021) Use of artificial intelligence to optimize textile wastewater biosorption using agricultural waste. Environmental Technology, DOI: [10.1080/09593330.2021.1961874](https://doi.org/10.1080/09593330.2021.1961874)

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>.

AN R, PEREZ-CRUET J, WANG J. **We got nuts! use deep neural networks to classify images of common edible nuts.** Nutrition and Health, 2022, DOI: [10.1177/02601060221113928](https://doi.org/10.1177/02601060221113928).

BORBA, M. DA C.; RAMOS, J. S.; RAMBORGER, B. M.; MACHADO, J.A. **Gestão no meio agrícola com o apoio da Inteligência Artificial: uma análise da digitalização da agricultura.** Rev Agro Amb, v. 15, n. 3, e9337, 2022 - e-ISSN 2176-9168

BRONSON, K.; KNEZEVIC, I. **Big Data in food and agriculture.** Big Data & Society, v. 3, n. 1, p. 2053951716648174, 2016.

CONAB - Companhia Nacional de Abastecimento (2022). **Acompanhamento da safra brasileira de grãos – Safra 2021/2022.** 8º levantamento.101 Disponível em: <https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>. Acesso em: 25/09/2022.

CUNHA, J. B. DE A.; NUNES, I. A; GAVA, C. A. T.; SANTOS, R. C. DOS; MARTINS, L. M. V; FERNANDES JUNIOR, P. **Diversidade cultural de bactérias isoladas de nódulos de amendoim (*Arachis hypogaea* L.) cultivados em solos do Nordeste do Brasil.** I.In: CONGRESSO BRASILEIRO DE CIÊNCIAS DO SOLO, 34., 2013. Florianópolis. Anais... Viçosa, MG: Sociedade Brasileira de Ciência do Solo, 2013.

DZOTSI, K. A.; BASSO B.; JONES, J.W. **Development, uncertainty and sensitivity analysis of the simple SALUS crop model in DSSAT, Ecological Modelling,** Volume 260, 2013, Pages 62-76, ISSN 0304-3800, <https://doi.org/10.1016/j.ecolmodel.2013.03.017>.

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>

HARFOUCHE AL, JACOBSON DA, KAINER D, ROMERO JC, HARFOUCHE AH, SCARASCIA MUGNOZZA G, MOSHELION M, TUSKAN GA, KEURENTJES JJB, ALTMAN A. **Accelerating Climate Resilient Plant Breeding by Applying Next-Generation Artificial Intelligence.** Trends Biotechnol. 2019 Nov;37(11):1217-1235. doi: 10.1016/j.tibtech.2019.05.007. Epub 2019 Jun 21. PMID: 31235329.

HARFOUCHE, AL; JACOBSON, DA; KAINER, D.; ROMERO, JC; HARFOUCHE, AH; MUGNOZZA, GS; MOSHELION, M.; TUSKAN, GA; KEURENTJES, JJ; ALTMAN, A. **Accelerating the improvement of climate-resilient plants by applying state-of-the-art artificial intelligence.** Biotechnology Trends. 2019, 37, 1217-1235

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>. 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.

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>.

KADIYALA, M.D.M.; NEDUMARAN, S.; CHUKKA S. PIARA SINGH, MOHAMMAD A. IRSYAD, BANTILAN, M.C.S. **An integrated crop model and GIS decision support system for assisting agronomic decision making under climate change**. Science of The Total Environment, Volumes 521–522, 2015, Pages 123-134, ISSN 0048-9697, <https://doi.org/10.1016/j.scitotenv.2015.03.097>.

KAPLAN, A.; HAENLEIN, M. Siri. **Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence**. Business Horizons, Amsterdam, v. 62, n. 1, p. 1525, 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 KUMAR, A. V. S. P.; BHARAMARAMBA, R. **Adapting mining into agriculture sector with machine learning techniques**. International Journal of Control and Automation, Seul, v. 10, n. 7, p. 13-22, 2017. DOI: <https://doi.org/10.14257/ijca.2017.10.7.02>.

LEE, R.-Y. , HSU, C.-H. , SHIU, Y.-S. **Applying machine learning algorithms and WorldView-2 satellite imagery to classify crop types**. Asian Conference on Remote Sensing: Fostering Resilient Growth in Asia, Proceedings (2015).

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.10001298.2018.01.001>.

LI, P. , DU, Z. , CHANG, C. , XU, G. , XU, CC. **Efficient Catalytic Conversion of Waste Peanut Shells into Liquid Biofuel: An Artificial Intelligence Approach**. Energia e Combustíveis, 2020 34 (2), 1791-1801 DOI: 10.1021/acs.energyfuels.9b03433

LIU, M. 2020. **Based on the Network and Information Technology, the Actual Performance Evaluation System of Heavy Metal Removal Biomass Materials in Water Was Developed**. Journal of Physics: Conference Series 1574 (2020) 012096 IOP Publishing DOI:10.1088/1742-6596/1574/1/012096.

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

PETETIN, L. **The COVID-19 crisis: an opportunity to integrate food democracy into post-pandemic food systems** Eur. J. Risk Regul. (2020), pp. 1-11, [10.1017/err.2020.40](https://doi.org/10.1017/err.2020.40)

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>

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

SANTOS, A.F.; LACERDA, L.N.; ROSSI, C.; MORENO, L.D.A.; OLIVEIRA, M.F.; PILON, C.; SILVA, R.P.; VELLIDIS, G. **Using UAV and Multispectral Images to Estimate Peanut Maturity Variability on Irrigated and Rainfed Fields Applying Linear**

Models and Artificial Neural Networks. *Remote Sens.* **2022**, *14*, 93. DOI: <https://doi.org/10.3390/rs14010093>

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.

SINGH, D.; CHAUDHARY, P.; TAUNK, J.; SINGH, C.K.; SINGH, D.; TOMAR, R.S.S.; ASKI, M.; KONJENGBAM, N.S.; RAJE, R.S.; SINGH, S.; SENGAR, R.S.; YADAV, R.K.; PAL, M. **Fab Advances in Fabaceae for Abiotic Stress Resilience: From ‘Omics’ to Artificial Intelligence**. *Int. J. Mol. Sci.* **2021**, *22*, 10535. DOI: <https://doi.org/10.3390/ijms221910535>

TUCUNDUVA, S. **Tabela de composição de alimentos**. 4. Ed. São Paulo: Manole, 2013.

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.

WOLFERT, S. et al. **Big Data in Smart Farming: a review**. Agricultural Systems, London, v. 153, p. 6980, 2017. DOI: <https://doi.org/https://doi.org/10.1016/j.agsy.2017.01.023>.

YANG, M., CHEN, Q., KUTSANEDZIE, FYH, (...), GUO, Z., OUYANG, Q. **Portable spectroscopy system determination of acid value in peanut oil based on variables selection algorithms**. Measurement, Volume 103, 2017, Pages 179-185, ISSN 0263 2241, DOI: <https://doi.org/10.1016/j.measurement.2017.02.037>

YOSHIDA, K., ISHIKAWA, E., JOSHI, M., LECHAT, H., AYOUNI, F., BONNEFILLE, M. (2012). **Quality Control and Rancidity Tendency of Nut Mix Using an Electronic Nose**. In: Kundu, M.K., Mitra, S., Mazumdar, D., Pal, S.K. (eds) **Perception and Machine Intelligence**. PerMIn 2012. Lecture Notes in Computer Science, vol 7143. Springer, Berlin, Heidelberg. DOI: https://doi.org/10.1007/978-3-642-27387-2_21