

A inteligência artificial e o setor agrícola nos últimos 20 anos: um estudo

O crescimento populacional tem sido ponto crucial para alavancar o desenvolvimento tecnológico no setor agrícola, visto que se tornou necessário produzir alimentos em maior quantidade e em curto período de tempo. Por esse motivo, o presente trabalho buscou analisar e quantificar no período de 20 anos (2002 a 2021) uma das tecnologias que está conseguindo conquistar espaço no desenvolvimento tecnológico do setor agrícola, a Inteligência Artificial (IA). Para tal finalidade, foi utilizada a plataforma de busca Scopus. A plataforma permite que a busca seja filtrada com base no assunto e intervalo de tempo, dessa forma, buscou-se trabalhos que fizeram uso das técnicas de IA, com enfoque ao aprendizado de máquina e o aprendizado profundo. A quantificação do uso do tema em questão no setor agrícola ocorreu com base nas publicações ao decorrer dos 20 anos analisados. Além disso, o software VOSviewer foi utilizado para criar mapas de redes, identificando os países, órgãos de fomento e autores que apresentavam maior interesse no tema em questão. Com as análises realizadas, acredita-se que foi fornecido uma percepção sobre o tema, o quanto a área de estudo já evoluiu e o quanto ainda pode evoluir. Esta evolução também se dará com a expansão dessas tecnologias, compreendendo o uso dessas tecnologias em diversas culturas agrícolas.

Palavras-chave: Desenvolvimento tecnológico; Agricultura; Scopus; VOSviewer.

Artificial intelligence and the agricultural sector in the last 20 years: a study

Population growth has been a crucial point in leveraging technological development in the agricultural sector, as it has become necessary to produce food in greater quantities and in a shorter period of time. For this reason, the present work sought to analyze and quantify over a period of 20 years (2002 to 2021) one of the technologies that is allowing to conquer the technological space of the agricultural sector, Artificial Intelligence (AI). For this purpose, the Scopus search platform was used. The platform allows the search to be filtered based on the subject and time interval, thus, works were sought that made use of AI techniques, with an approach to machine learning and deep learning. The quantification of the use of the theme in question in the agricultural sector was based on publications over the 20 years analyzed. In addition, the VOSviewer software was used to create network maps, identifying the countries, development agencies and authors who were most interested in the topic in question. With the analyzes carried out, it is believed that a perception on the subject was provided, how much the area of study has already evolved and how much it can still evolve. This evolution will also occur with the expansion of these technologies, including the use of these technologies in various agricultural crops.

Keywords: Technological development; Agriculture; Scopus; VOSviewer.

Topic: **Engenharia Agrícola**

Received: **20/06/2022**

Approved: **04/10/2022**

Reviewed anonymously in the process of blind peer.

Poliana Maria da Costa Bandeira 
Universidade Federal de Viçosa, Brasil
<http://lattes.cnpq.br/7229543787567127>
<http://orcid.org/0000-0002-7183-5705>
polianabandeira1@hotmail.com

Priscila Pascali da Costa Bandeira 
Universidade Federal de Viçosa, Brasil
<http://lattes.cnpq.br/7920904010363268>
<http://orcid.org/0000-0003-0966-7488>
priscilabandeira@outlook.com

Ana Beatriz Alves de Araújo 
Universidade Federal Rural do Semi-Árido, Brasil
<http://lattes.cnpq.br/3258937728496364>
<http://orcid.org/0000-0003-0477-0021>
beatrizufersa@gmail.com

Antônio Diego da Silva Teixeira 
Universidade Federal Rural do Semi-Árido, Brasil
<http://lattes.cnpq.br/7602339705056052>
<http://orcid.org/0000-0003-4506-8618>
diego.itap@hotmail.com

Ana Luiza Veras de Souza 
Universidade Federal Rural do Semi-Árido, Brasil
<http://lattes.cnpq.br/3438141481768017>
<http://orcid.org/0000-0002-1977-7907>
ana_luizaveras@hotmail.com

Jonatan Levi Ferreira de Medeiros 
Universidade Federal Rural do Semi-Árido, Brasil
<http://lattes.cnpq.br/5597490752283299>
<http://orcid.org/0000-0002-6869-8180>
jonatan_levi@hotmail.com



DOI: 10.6008/CBPC2237-9290.2022.002.0003

Referencing this:

BANDEIRA, P. M. C.; BANDEIRA, P. P. C.; ARAÚJO, A. B. A.; TEIXEIRA, A. D. S.; SOUZA, A. L. V.; MEDEIROS, J. L. F.. A inteligência artificial e o setor agrícola nos últimos 20 anos: um estudo. **Natural Resources**, v.12, n.2, p.28-38, 2022. DOI: <http://doi.org/10.6008/CBPC2237-9290.2022.002.0003>

INTRODUÇÃO

Atualmente, observa-se crescente desenvolvimento tecnológico no setor agrícola com o intuito de produzir em maior quantidade em um curto período de tempo. Um dos fatores que geram a necessidade de produzir mais em um curto período de tempo, é o aumento na demanda por alimentos (ABDOLLAHI et al., 2021) ocasionado pelo crescimento populacional.

É estimado pela Organização das Nações Unidas (ONU) que até 2050 a população mundial atingirá 9,7 bilhões de pessoas (United Nations Department of Economic and Social Affairs, 2015). Além do aumento na demanda alimentar o crescimento populacional gera a escassez de recursos naturais. Essas duas situações, aumento da demanda alimentar e escassez de recursos naturais, colaboram para o avanço tecnológico do setor agrícola.

Na modernização do setor agrícola, observa-se o crescimento no uso de sensores (proximais ou orbitais), drones, inteligência artificial e outros métodos para produzir em maior quantidade e em um curto período de tempo, sem que haja perda na qualidade dos produtos. Esses equipamentos e técnicas são utilizados para estimar a produtividade (SILVA et al., 2020; OLIVEIRA et al., 2020); identificar e avaliar a severidade de doenças presentes na cultura (KUMAR et al., 2021; NAGASUBRAMANIAN et al., 2019; WALLELIGN et al., 2018); realizar a colheita mecanizada (FENG et al., 2018); entre outros.

Dentre as técnicas e equipamentos mencionados para o desenvolvimento tecnológico no âmbito agrícola, tem-se a Inteligência Artificial (IA). A IA é um conjunto de técnicas que visa o aperfeiçoamento das máquinas, as tornando capazes de reproduzir as ações humanas (locomoção, visão, audição, dentre outras). Como parte da IA, tem-se o aprendizado de máquina (ML), que possui a capacidade de aprender uma nova função a partir de um conjunto de dados (JHA et al., 2019). Há ainda, dentro do ML, outra técnica denominada aprendizado profundo (DL). O DL possui o objetivo alcançar a capacidade de análise de um ser humano, tanto em dados visuais como também em dados sonoros (YANG et al., 2022).

Devido as técnicas de IA estarem apresentando alta funcionalidade no setor agrícola, pode-se avaliar o desenvolvimento dessa área neste setor, visando identificar a progressão do seu uso em trabalhos científicos. Dessa forma, obtêm-se uma visão geral do assunto da IA no setor agrícola. Assim, para realizar análise de um determinado assunto, pode-se recorrer as análises bibliométricas (AB).

As AB são revisões utilizadas tanto para proporcionar uma visão geral de determinado assunto presente em determinada área, como é possível de serem utilizadas na determinação da qualidade da pesquisa, de pesquisadores e de grupos ou organizações que tais pesquisadores façam parte.

Com isso, este trabalho possuiu o objetivo de realizar análise bibliométrica sobre a abrangência da IA no setor agrícola nos últimos 20 anos (2002 - 2021). Para tal, a pesquisa foi dividida em quatro partes, sendo elas: a) analisar os últimos 20 anos (2002 a 2021) de pesquisas sobre o uso da IA, com enfoque ao ML e DL, no setor agrícola; b) identificar as organizações de fomento que apresentam maior quantidade de publicações na área pesquisa de IA no setor agrícola; c) realizar análise de coocorrência e de acoplamento bibliométrico; e, d) apresentar o uso de DL e ML a partir de produções científicas dos últimos 5 anos.

MATERIAIS E MÉTODOS

Os dados para a AB foram coletados do banco de dados da Scopus, que é plataforma frequentemente utilizada como fonte de dados para realizar revisões apresentando alta confiabilidade no banco de dados (AMARASINGAM et al., 2022; DATTA et al., 2022; RAGAZOU et al., 2022). Para realizar a pesquisa na Scopus é necessário determinar as palavras-chave da área que queira analisar. Para tal tarefa, foi realizada a pesquisa entre os anos de 2002 e 2021, com as palavras-chave ‘Agricultural or Agriculture’, ‘Artificial Intelligence’, ‘Machine Learning’ e ‘Deep Learning’. Inicialmente, foi realizada a pesquisa relacionando apenas o termo ‘Agricultural or Agriculture’ com ‘Artificial Intelligence’, em seguida, o termo ‘Agricultural or Agriculture’ foi relacionado a ‘Machine Learning’ e ‘Deep Learning’. Essa divisão ocorreu para que a pesquisa fosse capaz de determinar o crescimento da área de IA e, de forma separada, de ML e DL no setor agrícola. A Figura 1 apresenta as palavras-chave, bem como, em qual parte dos artigos as palavras-chave foram selecionadas.

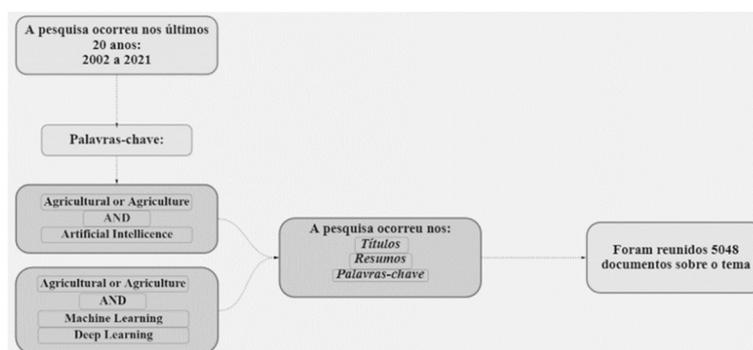


Figura 1: Fluxograma para identificar na base de dados da Scopus publicações entre os anos de 2002 e 2021 que utilizem técnicas de IA na área agrícola.

Ao final da coleta dos dados foram selecionados 5.048 artigos no período entre 2002 a 2021. Para análise dos documentos coletados, foi realizada a distribuição dos documentos a partir do ano de publicação. Dessa forma, pode-se avaliar e quantificar o desenvolvimento da área de IA no setor agrícola. Além disso, para verificar órgãos de fomento, países e autores que apresentam as maiores relevâncias no uso de IA no setor agrícola, foi utilizado a análise de coocorrência e acoplamento bibliométrico por meio do *software* VOSviewer.

RESULTADOS E DISCUSSÃO

Análise descritiva

Ao analisar os documentos coletados no período proposto (2002 a 2021), foi observado que o número de documentos publicados por ano apresentou baixa quantidade na primeira década do século XXI se comparado a segunda década do século XXI (Figura 2). O crescimento das publicações na segunda década do século XXI, provavelmente, ocorreu devido à enorme geração de dados, denominados de *big datas*, além do desenvolvimento dos *hardwares* com computadores de alto desempenho.

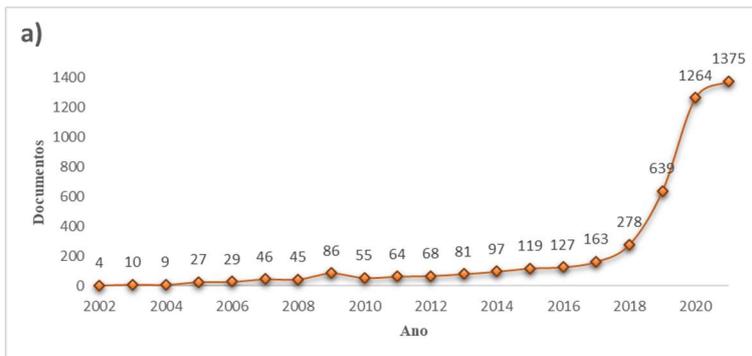


Figura 2: Documentos publicados com tema de IA na área agrícola no período de 2002 a 2021.

Como mencionado, a IA comporta um conjunto de técnicas, dentre elas temos a ML e DL. Ao darmos enfoque a essas duas técnicas, observa-se o pouco uso no início do século XXI (Figura 3). Porém, assim como na Figura 2, verificou-se o aumento no uso de ML e DL após a primeira década do século XXI. Os fatores de crescimento do acesso à informação e geração de dados, bem como, o desenvolvimento no *hardware*, também foram importantes para a evolução e uso dessas duas técnicas, ML e DL. No caso de modelos de DL, que apresentam alta demanda computacional, máquinas como as Unidades de Processamento Gráfico (GPU) e Unidades de Processamento Tensor (TPU), foram fatores extremamente importantes para o aumento no uso de modelos de DL.

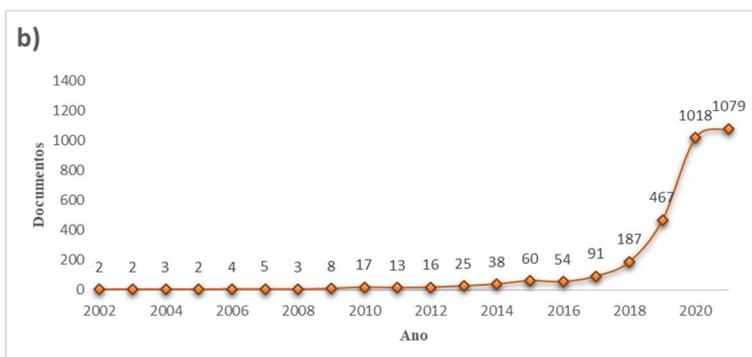


Figura 3: Documentos publicados com tema de ML e DL na área agrícola.

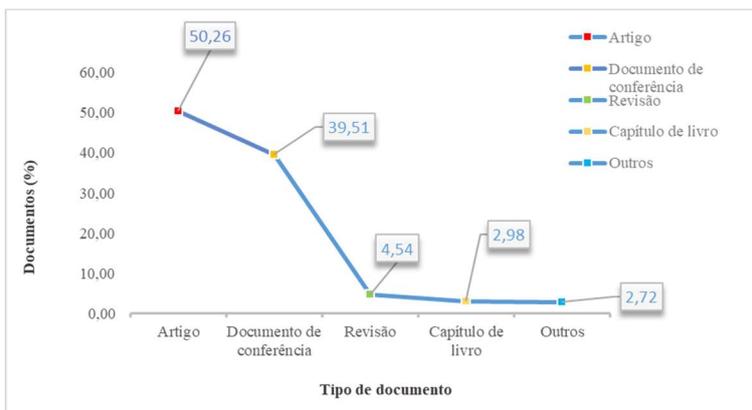


Figura 4: Categorização em porcentagem dos documentos publicados na área de IA no setor agrícola no período de 2002 a 2021.

Além da classificação a partir do ano da publicação, os documentos do banco de dados foram diferenciados de acordo com o tipo de documento (Figura 4). Como observado na Figura 4, as pesquisas que utilizam a IA no setor agrícola são publicadas na maioria das vezes como artigos científicos, correspondendo

a 50,26%. Em sequência, tem-se a categoria documentos de conferência que possui a representatividade de 39,51%. Dessa forma, artigos científicos e documentos de conferência, correspondem a quase 90% das pesquisas publicadas com o tema relacionado a IA na área agrícola no período de 2002 a 2021.

Na Figura 5 é possível visualizar as publicações de acordo com os órgãos de fomento dos autores, que correspondem aos documentos presentes no banco de dados utilizado neste trabalho. Vale destacar a relevância da China, que está na primeira posição, com um total de 261 publicações. O Brasil e EUA apresentam, cada um, dois órgãos de fomento entre as 10 primeiras posições. Além disso, o interesse da União Europeia assume posição importante nesta área de estudo, apresentando três órgãos de fomento entre as 10 primeiras posições.

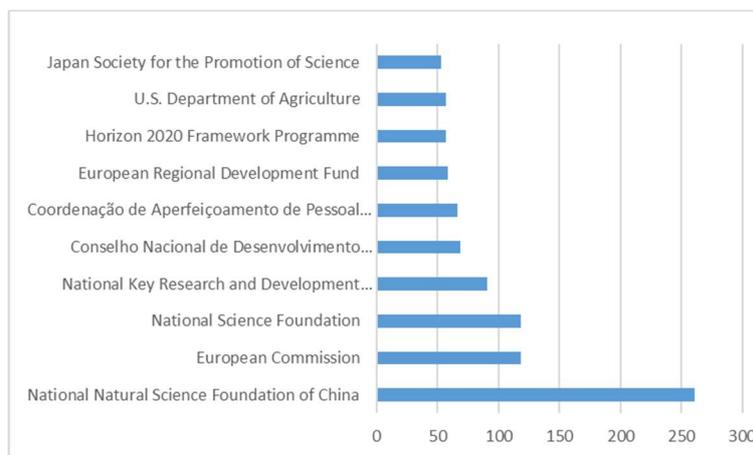


Figura 5: Os 10 órgãos de fomento com maior quantidade de publicações na área de IA no âmbito agrícola entre os anos de 2002 a 2021.

Mapas de rede

Além das análises realizadas anteriormente, foram construídos mapas de redes. Para tal tarefa, foi utilizado o VOSviewer (ECK et al., 2018), que é um *software* para criação de mapas que podem ser visualizados em formatos de redes bibliométricas. A criação das redes pode ocorrer a partir de citação, acoplamento bibliográfico, cocitação, coautoria ou coocorrência. Para o presente trabalho, os gráficos apresentados foram elaborados com base na coocorrência e acoplamento bibliográfico.

Para identificar as palavras-chave que possuem maior evidência nos trabalhos científicos e que são usualmente utilizadas pelos autores, bem como, a relação do uso entre elas, foi criado um mapa de coocorrência de palavras-chave. Foram selecionadas 20 palavras-chave para criação do mapa de análise por agrupamento. A Figura 6 apresenta as palavras-chave e as ligações entre elas. O tamanho de cada círculo representa a frequência de uso, sendo que, quanto maior o círculo mais frequentemente a palavra é utilizada. Como esperado, as palavras 'deep learning' e 'machine learning' apresentam elevada quantidade de uso, com 350 e 284 ocorrências, respectivamente.

Além da representatividade quantitativa das palavras-chave, na Figura 6 é possível identificar a relação entre elas. As cores presentes nos círculos e nas ligações são referentes a grupos e, os itens de mesma cor, possuem semelhança metodológica e/ou teórica. Em função disso, percebe-se a ligação entre os termos 'deep learning', 'convolutional neural networks' e 'classification'. Essa relação, provavelmente, ocorre devido

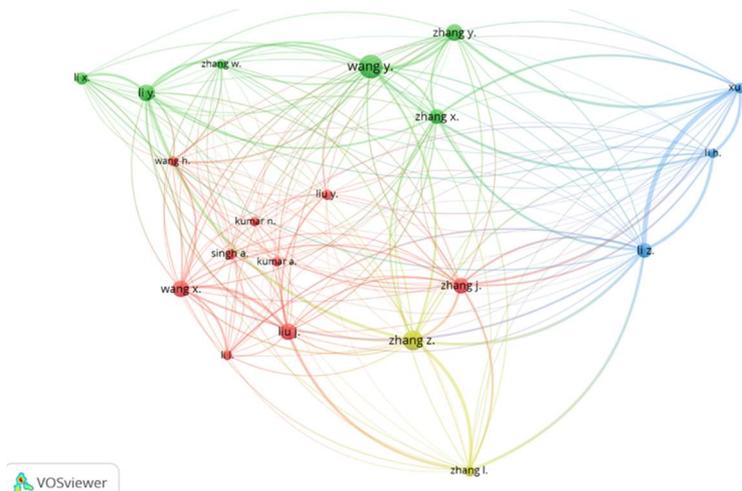


Figura 8: Acoplamento bibliográfico dos 20 autores com maior número de citações.

A análise de cocitação foi realizada para identificar os 20 autores com maior quantidade de citações. Para este caso, o autor Chen et al. (2019) apresentou um total de 539 citações, sendo este o autor que possui o maior número de citações (Figura 9). Apesar de não ser o autor com maior número de publicações, foi considerado o autor com maior número de citações no banco de dados em análise.

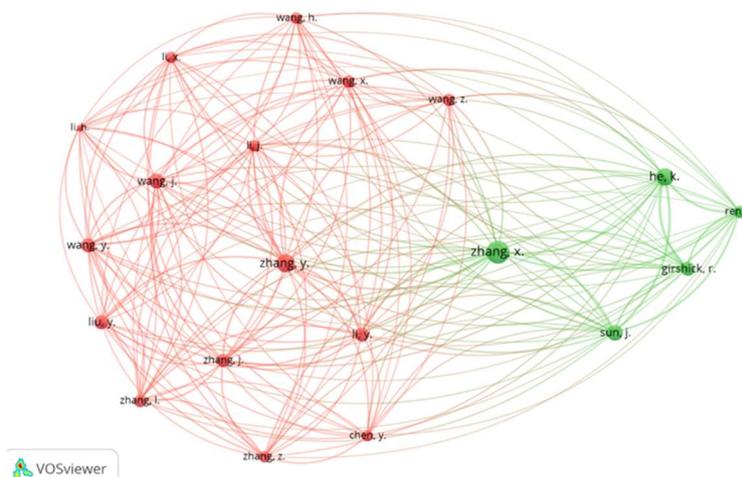


Figura 9: Análise de cocitação de 20 autores que apresentam maiores números de citações.

Técnicas de machine learning na agricultura

No setor agrícola a demanda de mão de obra é elevada e, como mencionado anteriormente, os modelos de ML são formas de gerar a percepção humana à máquina a partir de um conjunto de dados. Portanto, neste item é apresentado, por meio de trabalhos científicos, as aplicações do ML e DL de diferentes setores do âmbito agrícola. Vale ressaltar que o DL é um ramo do ML.

Na agricultura se busca alcançar o melhor rendimento das culturas, porém, alguns fatores podem ocasionar a perda na produção das culturas agrícolas. As doenças e pragas são um exemplo que causam a perda de produtividade. Em função disso, faz-se necessário realizar diagnósticos precoces, para evitar grandes perdas de produtividade. Os diagnósticos, por vezes, podem ser realizados com métodos visuais, em que o especialista identifica a doença e a severidade, informando a dosagem para aplicação do defensivo adequado. Assim, a qualidade do diagnóstico irá depender do conhecimento do especialista humano (LIU et

al., 2017).

Sendo assim, a área de detecção de doenças tem se destacado com trabalhos que apresentam como solução o uso de ML, com intuito de substituir o especialista humano evitando avaliações subjetivas e reduzindo os erros ocasionados por cansaço. O uso de DL, que é um ramo do ML, para aplicação de defensivos agrícola se apresenta como um método não intrusivo, reduzindo impactos negativos a lavoura. Esses métodos, visam não apenas detectar, mas são capazes de localizar por região, indicando em qual parcela da área apresenta indícios de infestação de pragas e doenças. Dessa forma, há redução de gastos de defensivos agrícola, pois, como exposto por Shankar et al. (2020), para o caso de plantas daninhas, observou-se que utilizando métodos em que o defensivo seja pulverizado apenas onde houver a presença da planta invasora, há redução de 61% no uso do defensivo.

Para detecção de doenças em folhas utilizando técnicas que compõe o ML, tem-se, por exemplo, a pesquisa desenvolvida por Bari et al. (2021) que realizou a detecção de doenças em folhas na cultura do arroz. O estudo mencionado utilizou o modelo Faster R-CNN (REN et al., 2015) e o banco de dados foi distribuído com base em folhas saudáveis e doentes. A taxa de identificação de doenças utilizando o modelo proposto ultrapassou 99%. Fuentes et al. (2021) também apresentaram o uso dessas técnicas para detecção de doenças na cultura do tomate, alcançando a taxa de reconhecimento de 93,91% para a métrica mAP (*mean Average Precision*). Com a grande demanda na produção agrícola, ocasionado pelo crescimento populacional, busca-se manter a qualidade e a segurança alimentar. Por isso, as medidas fitossanitárias tendem a ser rigorosas, com modelos alcançando alta precisão como apresentado anteriormente.

Além do uso na aplicação de defensivos, essas técnicas estão sendo aplicadas para detecção e contagem de frutos. Ao utilizar esse tipo de técnica para detecção dos frutos no campo, há a possibilidade de criação de sistemas autônomos para colheita (BIRRELL et al., 2020; FENG et al., 2018). Dessa forma, utilizando técnicas que compõem o ML e a robótica, torna-se possível mesclar ramos que integram a IA gerando sistemas mais completos e capacitados para realizar atividades em campo.

Com o uso dessas técnicas, buscou-se utilizar diferentes tipos de dados associados aos modelos computacionais, para alcançar maior eficiência com dados que fossem facilmente adquiridos. Como exemplo, tem-se o trabalho de Ganesh et al. (2019), que utilizou o modelo Mask R-CNN para detecção de laranjas. Para tal atividade o treinamento foi realizado com as imagens em dois sistemas de cores (RGB e HSV), utilizando três fontes de entrada (RGB, HSV e RGB + HSV), alcançando resultados satisfatórios ao utilizar o RGB + HSV. Com isso, observa-se que podemos alterar as características dos dados de entrada, identificando àquelas que gerem o melhor desempenho no modelo. A alteração pode ocorrer também por meio da fonte de captura das imagens, com uso de smartphones (MURUGAN et al., 2021; OLIVEIRA et al., 2020), drones (CHEN et al., 2019; KILWENGE et al., 2021) ou imagens de satélite (KAVITA et al., 2021; SINGH et al., 2021). Consequentemente, pode-se identificar as fontes que geram o melhor desempenho e o melhor custo benefício para aquisição.

Os modelos de ML podem ser utilizados com dados visuais, como os citados anteriormente, ou por meio de dados numéricos. No estudo realizado por Maldaner et al. (2021), o consumo de combustível,

rotação do motor, potência do motor e consumo específico de combustível foram utilizados como dados de entrada em modelos de ML (*Random Forest*, *Multiple Linear Regression* e *Artificial Neural Network*), buscando estimar a produtividade da cana-de-açúcar por meio de informações do motor da colhedora. Ao utilizar o modelo *Random Forest* o erro percentual absoluto médio foi de 5,7%. Já o trabalho desenvolvido por Vinson et al. (2021), foi utilizado dados que compreendem informações do solo, umidade, informações solares, nutricionais e o manejo de campo, em que esses dados foram aplicados aos modelos SVM (*Support Vector Machine*), GRNN (*Generalized Regression Neural Network*), RBFNN (*Radial Basis Functional Neural Network*) e BPNN (*Back Propagation Neural Network*). Ao final, observou-se que o GRNN apresentou o melhor desempenho para estimar a produtividade do arroz nas métricas analisadas, alcançando um erro percentual absoluto médio de 1,3439%.

Apesar de neste trabalho terem sido citados apenas alguns processos no setor agrícola que fizeram uso de técnicas que compõe o ML, a aplicabilidade desse tema vai muito além dos processos citados (APOLO et al., 2020; MAXWELL et al., 2020; MEKHALFI et al., 2021; XU et al., 2020). O uso intenso do ML em pesquisas científicas, prova que se busca inserir máquinas que irão compreender e realizar as atividades no setor agrícola tão bem quanto os seres humanos. Isso irá tornar o trabalho menos oneroso e irá gerar uma menor susceptibilidade a erros que são causados, por exemplo, pelo cansaço.

CONCLUSÕES

Para o presente estudo foi realizada análise bibliométrica dos últimos vinte anos (2002-2021) das pesquisas realizadas na agricultura que envolvam o tema de IA, com enfoque ao ML e DL. Para tal análise, foram apresentados os pesquisadores, órgãos de fomento e países que possuem maiores contribuições científicas na área em questão. Por isso, observou-se o quão acentuado tem sido a busca de melhorias tecnológicas para o campo agrícola e o quanto as técnicas que compõem o ML têm sido utilizadas para alavancar cada vez mais a agricultura digital.

Com as análises realizadas, acredita-se que foi fornecida uma percepção sobre o tema, o quanto a área de estudo já evoluiu e o quanto ainda pode evoluir. Esta evolução também se dará com a expansão dessas tecnologias, compreendendo o uso dessas tecnologias em diversas culturas agrícolas.

REFERÊNCIAS

ABDOLLAHI, A.; REJEB, K.; REJEB, A.; MOSTAFA, M. M.; ZAILANI, S.. Wireless sensor networks in agriculture: insights from bibliometric analysis. *Sustainability*, v.13, n.21, 2021.

DOI: <http://doi.org/10.3390/su132112011>

AMARASINGAM, N.; SALGADOE, A. S. A.; POWELL, K.; GONZALEZ, L. F.; NATARAJAN, S.. A review of UAV platforms, sensors, and applications for monitoring of sugarcane crops. *Remote Sensing Applications: Society and Environment*, v.26, 2022.

DOI: <http://doi.org/10.1016/J.RSASE.2022.100712>

APOLO, O. E. A.; GUANTER, J. M.; EGEE, G.; RAJA, P.; RUIZ, M. P.. Deep learning techniques for estimation of the yield

and size of citrus fruits using a UAV. *European Journal of Agronomy*, v.115, n.126030, 2020. DOI:

<http://doi.org/10.1016/j.eja.2020.126030>

BARI, B. S.; ISLAM, N.; RASHID, M.; HASAN, J.; AZRAAI, M.; RAZMAN, M.; MUSA, R. M.; AB NASIR, A. F.; MAJEED, P. P. A. A. A real-time approach of diagnosing rice leaf disease using deep learning-based faster R-CNN framework Distributed under Creative Commons CC-BY 4.0. *Peer J. Computer Science*, v.7, n.432, 2021. DOI: <http://doi.org/10.7717/peerj-cs.432>

BIRRELL, S.; HUGHES, J.; CAI, J. Y.; IIDA, F.. A field-tested robotic harvesting system for iceberg lettuce. *Journal of*

Field Robotics, v.37, n.2, p.225-245, 2020. DOI:

<http://doi.org/10.1002/ROB.21888>

CHEN, Y.; LEE, W. S.; GAN, H.; PERES, N.; FRAISSE, C.; ZHANG, Y.; HE, Y.. Strawberry yield prediction based on a deep neural network using high-resolution aerial orthoimages.

Remote Sensing, v.11, n.13, 2019. DOI:

<http://doi.org/10.3390/rs11131584>

DATTA, P.; BEHERA, B.; RAHUT, D. B.. Climate change and Indian agriculture: A systematic review of farmers' perception, adaptation, and transformation. **Environmental Challenges**, v.8, n.100543, 2022. DOI:

<http://doi.org/10.1016/J.ENVC.2022.100543>

ECK, N. J.; VAN, WALTMAN, L.. **VOSviewer Manual**. CWTS, 2018.

FENG, Q.; ZOU, W.; FAN, P.; ZHANG, C.; WANG, X.. Design and test of robotic harvesting system for cherry tomato.

International Journal of Agricultural and Biological Engineering, v.11, n.1, p.96-100, 2018. DOI:

<http://doi.org/10.25165/IJABE.V11I1.2853>

FUENTES, A.; YOON, S.; LEE, M. H.; PARK, D. S.. Improving Accuracy of Tomato Plant Disease Diagnosis Based on Deep Learning With Explicit Control of Hidden Classes. **Frontiers in Plant Science**, v.12, 2021. DOI:

<http://doi.org/10.3389/FPLS.2021.682230>

GANESH, P.; VOLLE, K.; BURKS, T. F.; MEHTA, S. S.. Deep Orange: Mask R-CNN based Orange Detection and Segmentation. **IFAC-PapersOnLine**, v.52, n.30, p.70-75, 2019. DOI: <http://doi.org/10.1016/j.ifacol.2019.12.499>

JHA, K.; DOSHI, A.; PATEL, P.; SHAH, M.. A comprehensive review on automation in agriculture using artificial intelligence. **Artificial Intelligence in Agriculture**, n.2, p.1-12, 2019. DOI: <http://doi.org/10.1016/J.AIIA.2019.05.004>

KAVITA; MATHUR, P.. Satellite-based crop yield prediction using machine-learning algorithm. In: ASIAN CONFERENCE ON INNOVATION IN TECHNOLOGY. **Annals. ASIANCON**, 2021. DOI:

<http://doi.org/10.1109/ASIANCON51346.2021.9544562>

KILWENGE, R.; ADEWOPO, J.; SUN, Z.; SCHUT, M.. UAV-Based Mapping of Banana Land Area for Village-Level Decision-Support in Rwanda. **Remote Sens**, v.13, n.24, 2021. DOI: <http://doi.org/10.3390/rs13244985>

KOIRALA, A.; WALSH, K. B.; WANG, Z.; MCCARTHY, C.. Deep learning - Method overview and review of use for fruit detection and yield estimation. **Computers and Electronics in Agriculture**, v.162, p.219-234, 2019. DOI:

<http://doi.org/10.1016/j.compag.2019.04.017>

KUMAR, M.; KUMAR, A.; PALAPARTHY, V. S.. Soil Sensors-Based Prediction System for Plant Diseases Using Exploratory Data Analysis and Machine Learning. **IEEE Sensors Journal**, v.21, n.16, p.17455-17468, 2021. DOI:

<http://doi.org/10.1109/JSEN.2020.3046295>

LEE, J.; NAZKI, H.; BAEK, J.; HONG, Y.; LEE, M.. Artificial intelligence approach for tomato detection and mass estimation in precision agriculture. **Sustainability**, v.12, n.21, p.1-15, 2020. DOI: <http://doi.org/10.3390/su12219138>

LIU, B.; ZHANG, Y.; HE, D. J.; LI, Y.. Identification of apple leaf diseases based on deep convolutional neural networks.

Symmetry, v.10, p.11, 2017. DOI:

<http://doi.org/10.3390/SYM10010011>

MALDANER, L. F.; CORRÊDO, L. P.; CANATA, T. F.; MOLIN, J. P.. Predicting the sugarcane yield in real-time by harvester engine parameters and machine learning approaches.

Computers and Electronics in Agriculture, v.181, n.105945, 2021. DOI: <http://doi.org/10.1016/J.COMPAG.2020.105945>

MAXWELL, A. E.; POURMOHAMMADI, P.; POYNER, J. D.. Mapping the topographic features of mining-related valley fills using mask R-CNN deep learning and digital elevation data. **Remote Sensing**, v.12, n.3, p.1-23, 2020. DOI:

<http://doi.org/10.3390/rs12030547>

MEKHALFI, M. L.; NICOLÒ, C.; BAZI, Y.; RAHHAL, M. M. A.; MAGHAYREH, E. A.. Detecting crop circles in google earth images with mask R-CNN and YOLOv3. **Applied Sciences**, v.11, n.5, p.1-12, 2021. DOI:

<http://doi.org/10.3390/app11052238>

MURUGAN, M. S. B.; RAJAGOPAL, M. K.; ROY, D.. IoT based smart agriculture and plant disease prediction. **Journal of Physics: Conference Series**, v.2115, n.1, 2021. DOI:

<http://doi.org/10.1088/1742-6596/2115/1/012017>

NAGASUBRAMANIAN, K.; JONES, S.; SINGH, A. K.; SARKAR, S.; SINGH, A.; GANAPATHYSUBRAMANIAN, B.. Plant disease identification using explainable 3D deep learning on hyperspectral images. **Plant Methods**, v.15, n.1, p.1-10, 2019. DOI: <http://doi.org/10.1186/s13007-019-0479-8>

OLIVEIRA, D. T.; PEREIRA, R.; JUNIOR, W. M.; ZERBATO, C.. Convolutional neural networks in predicting cotton yield from images of commercial fields. **Computers and Electronics in Agriculture**, v.171, n.105307, 2020. DOI: <http://doi.org/10.1016/j.compag.2020.105307>

RAGAZOU, K.; GAREFALAKIS, A.; ZAFEIRIOU, E.; PASSAS, I.. Agriculture 5.0: A New Strategic Management Mode for a Cut Cost and an Energy Efficient Agriculture Sector. **Energies**, v.15, n.9, p.3113, 2022. DOI:

<http://doi.org/10.3390/EN15093113>

REN, S.; HE, K.; GIRSHICK, R.; SUN, J.. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. **Computer Vision and Pattern Recognition**, p.1-14, 2015. DOI: <http://doi.org/10.48550/arXiv.1506.01497>

SHANKAR, P.; WERNER, N.; SELINGER, S.; JANSSEN, O.. Artificial intelligence driven crop protection optimization for sustainable agriculture; artificial intelligence driven crop protection optimization for sustainable agriculture. In: ITU INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE FOR GOOD (AI4G). **Annals**. 2020. DOI:

<http://doi.org/10.1109/AI4G50087.2020.9311082>

SILVA, S.; OLIVEIRA NETO, S. N.; LEITE, H. G.; ALCÂNTARA, A. E. M.; OLIVEIRA NETO, R. R.; SOUZA, G. S. A.. Productivity estimate using regression and artificial neural networks in small familiar areas with agrosilvopastoral systems.

Agroforestry Systems, v.94, n.6, p.2081-2097, 2020. DOI: <http://doi.org/10.1007/S10457-020-00526-1/TABLES/4>

SINGH, R. K.; SINGH, P.; DREWS, M.; KUMAR, P.; SINGH, H.; GUPTA, A. K.. A machine learning-based classification of LANDSAT images to map land use and land cover of India.

Remote Sensing Applications: Society and Environment, v.24, 2021. DOI: <http://doi.org/10.1016/j.rsase.2021.100624>

VINSON, J.; PRIYADHARSON, S. M.; KANNADASAN, R.. Exploration of machine learning approaches for paddy yield prediction in eastern part of tamilnadu. **Agronomy**, v.11, n.10, 2021. DOI: <http://doi.org/10.3390/agronomy11102068>

WALLELIGN, S.; POLCEANU, M.; BUCHE, C.. Soybean plant disease identification using convolutional neural network. In: INTERNATIONAL FLORIDA ARTIFICIAL INTELLIGENCE

RESEARCH SOCIETY CONFERENCE, 31. **Annals. FLAIRS**, 2018. p.146-151.

XU, B.; WANG, W.; FALZON, G.; KWAN, P.; GUO, L.; CHEN, G.. Automated cattle counting using Mask R-CNN in quadcopter vision system. **Computers and Electronics in Agriculture**, v.171, n.105300, 2020. DOI: <http://doi.org/10.1016/j.compag.2020.105300>

YANG, J.; GUO, X.; LI, Y.; MARINELLO, F.; ERCISLI, S.; ZHANG, Z.. A survey of few-shot learning in smart agriculture: developments, applications, and challenges. **Plant Methods**, v.18, n.1, 2022. DOI: <http://doi.org/10.1186/S13007-022-00866-2>

Os autores detêm os direitos autorais de sua obra publicada. A CBPC – Companhia Brasileira de Produção Científica (CNPJ: 11.221.422/0001-03) detêm os direitos materiais dos trabalhos publicados (obras, artigos etc.). Os direitos referem-se à publicação do trabalho em qualquer parte do mundo, incluindo os direitos às renovações, expansões e disseminações da contribuição, bem como outros direitos subsidiários. Todos os trabalhos publicados eletronicamente poderão posteriormente ser publicados em coletâneas impressas ou digitais sob coordenação da Companhia Brasileira de Produção Científica e seus parceiros autorizados. Os (as) autores (as) preservam os direitos autorais, mas não têm permissão para a publicação da contribuição em outro meio, impresso ou digital, em português ou em tradução.