

TECNOLOGIAS DE DEEP LEARNING PARA DIAGNOSE DO ESTADO NUTRICIONAL DE PLANTAS: UMA REVISÃO SISTEMÁTICA

JULIA LUNA COUTO¹, MARCOS SILVA TAVARES², JAMILE RAQUEL REGAZZO³, THIAGO LIMA DA SILVA⁴, MURILO MESQUITA BAESSO⁵

¹ Graduanda de Eng. de Biosistemas, Depto. Eng. de Biosistemas, FZEA/USP, Pirassununga - SP, julialuna@usp.br.

² Doutorando em Eng. de Sistemas Agrícolas, Depto. Eng. de Biosistemas, ESALQ/USP, Piracicaba – SP.

³ Mestranda em Eng. de Sistemas Agrícolas, Depto. Eng. de Biosistemas, ESALQ/USP, Piracicaba – SP.

⁴ Doutorando em Eng. de Sistemas Agrícolas, Depto. Eng. de Biosistemas, ESALQ/USP, Piracicaba – SP.

⁵ Prof. Doutor Associado, Depto. Eng. de Biosistemas, FZEA/USP, Pirassununga – SP.

Apresentado no
LII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2023
18 a 21 de outubro de 2023 – Ribeirão Preto - SP, Brasil

RESUMO: Agricultura de precisão avança com o deep learning para diagnosticar o estado nutricional das plantas por meio de padrões de sintomas, melhorando a produtividade e qualidade. Este ramo é o enfoque deste trabalho, que utilizou a plataforma Scopus (Elsevier), onde nos últimos 10 anos foi amplamente difundida esta linha de pesquisa, encontrando 162 documentos a partir do método PRISMA-P, o qual orientou a seleção dos artigos, fornecendo uma compreensão abrangente das pesquisas relacionadas ao tema. Destacou-se o uso frequente de métodos como redes neurais convolucionais, K-vizinhos mais próximos (KNN) e drones para aquisição de imagens e classificação automatizada. As pesquisas, lideradas por China e Índia, alcançaram alta precisão no enfrentamento de problemas agrícolas e na tomada de decisões.

PALAVRAS-CHAVE: processamento de imagens; qualificação de doenças; agroinformática.

DEEP LEARNING TECHNOLOGIES FOR DIAGNOSING THE NUTRITIONAL STATUS OF PLANTS: A REVIEW

ABSTRACT: Precision agriculture benefits from the advancement of deep learning to diagnose the nutritional status of plants based on symptom patterns, improving productivity and quality. This branch is the focus of this work, which used the Scopus platform (Elsevier), where in the last 10 years this line of research has been widely disseminated, finding 162 documents from the PRISMA-P method. Deep learning methods such as convolutional neural networks, K-Nearest Neighbors (KNN) and use of drones for image acquisition and automated classification are the most frequent. High accuracy is achieved by solving problems that affect agricultural production and decision-making, such as disease and illness, with China and India leading the world in research.

KEYWORDS: image processing; qualification of diseases; agroinformatics;

INTRODUÇÃO: O diagnóstico nutricional convencional de plantas envolve análise laboratorial de tecidos vegetais para determinar os teores de nutrientes. O uso de *deep learning* na nutrição de plantas envolve análise de imagens e espectroscopia. A análise de imagens extrai informações relevantes, como eficiência fotossintética e teores de nutrientes,

enquanto a espectroscopia mede a absorção e reflexão da luz pelos tecidos vegetais. Essas tecnologias requerem conjuntos de dados representativos para treinar modelos de *deep learning* capazes de identificar padrões de deficiência ou excesso. Isso permite uma aplicação eficaz de fertilizantes, melhorando a produtividade e qualidade, reduzindo custos e impacto ambiental (TRIVELIN E LAVRES JUNIOR, 2010). Esta revisão objetiva investigar artigos de alto impacto sobre o uso de *deep learning* no diagnóstico nutricional de plantas, destacando tendências globais e características dessas tecnologias.

MATERIAL E MÉTODOS: Foi realizada uma revisão sistemática dos últimos 10 anos de artigos na plataforma *Scopus*, utilizando as palavras-chave "*Technologies*", "*Diagnoses*", "*Diseases*", "*Plants*" e "*Images*". A seleção do material de literatura foi feita com o objetivo de reduzir o número de trabalhos e focar no conteúdo relevante. O estudo seguiu os protocolos de revisão sistemática e metanálise (PRISMA-P), com base nesses critérios: I) Idade; II) Categorias do assunto – Agricultura e Ciências Biológicas, Bioquímica Genética e Biologia Molecular, Informática, Engenharia; III) Idioma – Inglês; IV) Tipo de acesso - acesso livre. A análise bibliométrica foi conduzida na plataforma *Scopus*, aplicando filtros aos 162 documentos, resultando em 29 artigos. Os 10 mais citados foram selecionados e discutidos com base em tópicos como país de origem, palavras-chave, problema analisado, algoritmo de *deep learning* e outros. O mapeamento dos dados foi realizado usando o Software VOSviewer, versão 1.6.19.

RESULTADOS E DISCUSSÃO: O mapeamento bibliométrico revelou 102 palavras-chave relevantes nos 29 documentos selecionados, incluindo "*deep learning*", "*machine learning*", "*classification*" e "*image processing*", associando desenvolvimento tecnológico a diagnose nutricional.

Nº Artigo	Nº Citações	Ano	Espécie	Problema (s) analisado (s)	Deep Learning	Resultado
1	111	2016	Alfafa (Medicago sativa)	Mancha foliar comum, ferrugem, Leptosphaerulina briosiana e Cercospora medicaginis	129 características; floresta aleatória; SVM; K-NN;	97,64% conj. treino; 94,74% conj. treino
2	96	2019	Maçã	Antracnose	Deteção automática de lesões; CycleGAN;	Análise em tempo real e efetiva
3	93	2020	Uva	Podridão negra, sarampo preto, ferrugem da folha e os ácaros da uva	Processamento de imagens; algoritmo R-CNN;	81,1% precisão; vel. 15,01 FPS; viável outras doenças;
4	81	2019	Camellia sinensis	Automatizar a identificação de diferentes doenças	Classificação automatizada; CNN; LeafNet;	90,16% de precisão;
5	61	2017	Tomate	Limite de tempo e	Super-resolução de	Rapidez na

				alta resolução de imagens a partir de drones e verificar eficiência na classificação	imagens; processamento; SRCNN;	fenotipagem ; precisão garantida
6	57	2019	*células-tronco	Inibir inflamação Lipopolissacarídeo; doenças inflamatórias.	Biocompatibilidade;	Permitiu a identificação das ações das células
7	47	2019	Milho	Identificação precoce, mancha das folhas do norte, perdas na produtividade; drones;	Imagens UVA; CNN com imagens de baixa resolução;	95%; mapas de calor para localização;
8	43	2019	Soja	Doenças foliares mais recorrentes	CNN's; 1200 conjunto de dados	Precisões >92%
9	32	2020	Trigo	Powdery mildew (PM, Blumeria graminis f. sp. tritici)	Imagens hiperspectrais; técnicas de segmentação;	PCA precisão 93,33%
10	30	2016	* síntese de nanopart. de ouro	Classificação da qualidade de colônias de células-tronco induzidas (iPSC)	Support Vector Machines; Scaled Invariant Feature Transf.	62,4% com K-NN

QUADRO 1- Análise geral dos 10 artigos mais citados selecionados da base de dados Scopus Elsevier);

A análise dos artigos, apresentada no Quadro 1, sinalizou discrepâncias nas citações, com uma diminuição linear entre o mais citado e o décimo (270%). A relevância do autor, instituição e reconhecimento da planta estudada influenciam o número de citações, que não está claramente associado ao ano de publicação. 8 dos 10 artigos enfocam espécies de alta importância global no ramo agrícola, evidenciando a busca pela evolução tecnológica nesse setor. Problemas relacionados à qualidade da produção agrícola, como doenças e proliferação de bactérias e fungos, foram abordados, além da utilização de drones para aquisição de imagens e classificação automatizada com métodos de deep learning, como redes neurais convolucionais e K-vizinhos mais próximos (KNN), obtendo alta precisão. A revisão sistemática PRISMA-P orientou a seleção dos artigos, fornecendo uma compreensão abrangente das pesquisas relacionadas ao tema. A China (38%) e a Índia (17%) foram os principais países envolvidos na pesquisa, indicando um foco significativo de estudos a nível global. A alta precisão alcançada destaca a importância do tema e a necessidade de investimentos em diversos setores, além da agricultura.

CONCLUSÕES: Métodos de deep learning, como redes neurais convolucionais, K-vizinhos mais próximos (KNN) e uso de drones para aquisição de imagens e a classificação automatizada são os mais frequentes resultando em alta precisão, solucionando problemas que afetam a produção agrícola e a tomada de decisões, como doenças e enfermidades.

REFERÊNCIAS:

CHEN, JING; LIU, QI; GAO, LINGWANG. Visual tea leaf disease recognition using a convolutional neural network model. **Symmetry**, v. 11, n. 3, p. 343, 2019. [4]

JADHAV, SACHIN B.; UDUPI, VISHWANATH R.; PATIL, SANJAY B. Convolutional neural networks for leaf image-based plant disease classification. **IAES International Journal of Artificial Intelligence**, v. 8, n. 4, p. 328, 2019. [8]

JOUTSIJOKI, HENRY et al. Machine learning approach to automated quality identification of human induced pluripotent stem cell colony images. **Computational and mathematical methods in medicine**, v. 2016, 2016. [10]

LIU, YING et al. Green synthesis of gold nanoparticles using *Euphrasia officinalis* leaf extract to inhibit lipopolysaccharide-induced inflammation through NF- κ B and JAK/STAT pathways in RAW 264.7 macrophages. **International journal of nanomedicine**, v. 14, p. 2945, 2019. [6]

MOHER, D., SHAMSEER, L., CLARKE, M. et al. Itens de relatório preferidos para revisão sistemática e protocolos de meta-análise (PRISMA-P) 2015 declaração. **Syst Rev** 4, 1 (2015).

PAGE, MATTHEW J. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **International journal of surgery**, v. 88, p. 105906, 2021.

QIN, FENG et al. Identification of alfalfa leaf diseases using image recognition technology. **PLoS One**, v. 11, n. 12, p. e0168274, 2016. [1]

TIAN, YUNONG et al. Detection of apple lesions in orchards based on deep learning methods of cyclegan and yolov3-dense. **Journal of Sensors**, v. 2019, 2019. [2]

TRIVELIN, P. C. O., & LAVRES JUNIOR, J. (2010). **Nutrição mineral de plantas**. Editora Agronômica Ceres.

WU, HARVEY et al. Autonomous detection of plant disease symptoms directly from aerial imagery. **The plant phenome journal**, v. 2, n. 1, p. 1-9, 2019. [7]

XIE, XIAOYUE et al. A deep-learning-based real-time detector for grape leaf diseases using improved convolutional neural networks. **Frontiers in plant science**, v. 11, p. 751, 2020. [3]

YAMAMOTO, KYISUKE; TOGAMI, TAKASHI; YAMAGUCHI, NORIO. Super-resolution of plant disease images for the acceleration of image-based phenotyping and vigor diagnosis in agriculture. **Sensors**, v. 17, n. 11, p. 2557, 2017. [5]

ZHAO, JINLING et al. Identification of leaf-scale wheat powdery mildew (*Blumeria graminis* f. sp. *Tritici*) combining hyperspectral imaging and an SVM classifier. **Plants**, v. 9, n. 8, p. 936, 2020. [9]