

---

**APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL NO AGRONEGÓCIO UTILIZANDO  
DEEP LEARNING PARA IDENTIFICAÇÃO DE DOENÇAS EM CULTURAS**

**APPLICATION OF ARTIFICIAL INTELLIGENCE IN AGRIBUSINESS USING DEEP  
LEARNING TO IDENTIFY DISEASES IN CROPS**

Sergio Kenji Sawasaki Tanaka<sup>1</sup>

Eron Ponce Pereira<sup>2</sup>

Bruno Henrique Coletto<sup>3</sup>

Sergio Akio Tanaka<sup>4</sup>

**RESUMO**

A Inteligência Artificial (IA) é uma ferramenta poderosa para monitorar culturas e prever rendimentos com precisão. A aprendizagem profunda (*Deep Learning*) e suas variantes, como redes neurais artificiais, profundas e recorrentes, fornecem *insights* sobre como a IA pode melhorar a produção agrícola. A análise cuidadosa dos resultados oferece orientações para alcançar a excelência na agricultura. A Inteligência Artificial oferece uma abordagem promissora para monitorar culturas e prever rendimentos com precisão. Através de uma imersão profunda nas complexidades da aprendizagem profunda e suas variantes híbridas, como Redes Neurais Artificiais, Profundas e Recorrentes, adquire-se uma compreensão específica de como a IA pode impulsionar a produção agrícola. Esta pesquisa destaca a necessidade e a relevância das redes neurais recorrentes e redes híbridas no contexto agrícola, demonstrando sua capacidade de superar outras abordagens, como redes neurais artificiais e redes neurais convencionais. Em resumo, com base na análise dos dados, fornecemos orientações claras para orientar futuros empreendimentos em busca da excelência na agricultura.

23

**Palavras-chave:** aprendizado profundo; agricultura; previsão de rendimento; doenças de plantas; mapeamento de clima e solo; redes neurais convolucionais.

---

<sup>1</sup> Graduando do Curso de Ciência da Computação do Centro Universitário Filadélfia - UniFil. serginho.k.s.tanaka@edu.unifil.br

<sup>2</sup> Graduando do Curso de Ciência da Computação do Centro Universitário Filadélfia - UniFil. eronponcepereira@edu.unifil.br

<sup>3</sup> Co-orientador: Professor do Centro Universitário Filadélfia - UniFil. bruno.coletto@unifil.br

<sup>4</sup> Orientador: Professor e Orientador do Projeto do Centro Universitário Filadélfia - UniFil. sergio.tanaka@unifil.br

## ABSTRACT

Artificial Intelligence (AI) is a powerful tool for monitoring crops and accurately predicting yields. Deep learning and its variants, such as artificial neural networks, deep neural networks, and recurrent neural networks, provide insights into how AI can enhance agricultural production. Careful analysis of the results offers guidance to achieve excellence in farming. Artificial Intelligence offers a promising approach to monitor crops and predict yields accurately. Through a deep dive into the complexities of deep learning and its hybrid variants, such as Artificial Neural Networks, Deep Neural Networks, and Recurrent Neural Networks, a specific understanding of how AI can drive agricultural production is acquired. This research highlights the need and relevance of recurrent neural networks and hybrid networks in the agricultural context, demonstrating their ability to outperform other approaches like artificial neural networks and conventional neural networks. In summary, based on data analysis, we provide clear guidance to steer future endeavors towards excellence in agriculture.


**Keywords:** deep learning; agriculture; yield prediction; plant diseases; climate and soil mapping; convolutional neural networks.

## 1 INTRODUÇÃO

A agricultura é indiscutivelmente um dos pilares fundamentais da civilização humana, fornecendo alimentos, fibras e materiais essenciais para a nossa sobrevivência e prosperidade. No entanto, à medida que enfrentamos desafios globais crescentes, como mudanças climáticas, escassez de recursos e crescente demanda por alimentos, a agricultura moderna se encontra em uma encruzilhada, como afirma Suchithra (2020). “A principal causa da perda significativa na qualidade do solo está relacionada às estratégias inadequadas de manejo do solo e cultivo. Além disso, o uso excessivo de fertilizantes químicos proporcionou desequilíbrios na disponibilidade de nutrientes no solo”.

A revolução da agricultura está se desdobrando, e uma das ferramentas mais promissoras nesse cenário é as redes neurais uma vertente da Inteligência Artificial que replica a estrutura e os processos do cérebro humano podendo ser ampliado a Redes Neurais Profundas, com o objetivo de replicar o funcionamento do cérebro humano. Sendo possível treinar uma máquina para ela se auto-treinar, exemplificado pela Figura 1.

**Figura 1** - Exemplo de rede neural



Fonte - Aprendizado Profundo (Chen, 2019)

Este artigo explora de forma abrangente o papel transformador que o Aprendizado Profundo desempenha na agricultura contemporânea, onde a tecnologia se torna uma aliada vital dos agricultores, ajudando-os a tomar decisões informadas em relação ao plantio, previsão de rendimento e identificação de doenças (Saleem, 2019). Ao capacitar a agricultura com IA, a produção agrícola está se tornando mais eficiente, sustentável e capaz de enfrentar os desafios do século XXI. Ao longo deste artigo será analisado como o Aprendizado Profundo é aplicado em áreas-chave da agricultura, desde a identificação de doenças nas plantas até o mapeamento de clima e solo para sugestão de cultivos, culminando na previsão precisa do rendimento das culturas. Em um mundo onde a segurança alimentar global é uma preocupação crescente.

25

## 2 DESENVOLVIMENTO

A produção agrícola desempenha um papel fundamental na alimentação global e na economia de muitos países. No entanto, a agricultura enfrenta uma série de desafios, incluindo a necessidade de aumentar a produtividade para atender a uma população em crescimento, lidar com as mudanças climáticas e garantir a sustentabilidade ambiental. Nesse contexto, a aplicação do Aprendizado Profundo na

agricultura representa uma resposta inovadora a esses desafios, oferecendo soluções avançadas e eficazes para melhorar a produção, a qualidade dos alimentos assim como na eficiência dos processos agrícolas.

Além disso, vale ressaltar que as técnicas de Aprendizado Profundo mencionadas, como Redes Neurais Convolucionais (CNN), Redes Neurais Profundas (DNN), Redes Neurais Memória de Longo Prazo (LSTM) e outras, são aplicadas de forma adaptável de acordo com as necessidades específicas de cada situação agrícola, demonstrando a versatilidade e a capacidade de personalização dessa tecnologia.

## **2.1 O papel do Aprendizado Profundo na Agricultura**

O Aprendizado Profundo desempenha um papel importante na Revolução da Agricultura, com a Inteligência Artificial liderando o caminho. A IA busca replicar a estrutura e os processos do cérebro humano, sendo sua base a rede neural, um componente essencial do Aprendizado Profundo. A rede neural profunda é aprimorada com camadas ocultas que enriquecem o processo de aprendizado. Pode surgir a pergunta: por que precisamos de IA na agricultura.

O Aprendizado Profundo também encontra aplicação na colheita, onde máquinas colaborativas com IA, monitoradas por sistemas de drones controlados pela Internet das Coisas (IoT), foram introduzidas. Essas soluções automatizadas identificam automaticamente a extensão do campo, enquanto a colheita ocorre com a combinação de técnicas de aprendizado de máquina e IoT.

## **2.2 Identificação de Doenças em Plantas**

Na produção de culturas, a identificação de doenças é extremamente necessária, pois a redução das enfermidades resulta em maiores rendimentos. Tradicionalmente, a detecção de doenças, em muitos casos, é realizada por meio de verificações manuais. A aprendizagem profunda desempenha um papel fundamental na identificação de plantas e de suas enfermidades. Essas doenças podem ser

identificadas com o auxílio de Redes Neurais Convolucionais (CNNs), que capturam e analisam imagens de folhas infectadas. Essas imagens são treinadas com milhares de dados para garantir resultados precisos. O diagnóstico de doenças é validado por especialistas, e medidas corretivas adequadas são sugeridas. A CNN também ajuda a identificar a localização precisa da parte afetada, melhorando o diagnóstico (Shrestha, 2020).

Além disso, o Aprendizado Profundo também contribui para a identificação de fatores desencadeadores de doenças, como mudanças climáticas e agentes externos, incluindo insetos. Essa capacidade permite que os agricultores identifiquem doenças antes de sua manifestação, possibilitando a adoção de medidas preventivas.

### **2.3 Previsão de Rendimento de Culturas**

Ed-Daoudi (2023) e Paudel (2021) detalham em sua obra que ao longo do tempo, o conhecimento agrícola tradicional tem diminuído, e os agricultores passaram a depender cada vez mais de máquinas e sistemas automatizados. O Aprendizado Profundo desempenha um papel essencial na previsão dos rendimentos das culturas, levando em consideração variáveis ambientais como clima, temperatura, precipitação, índice vegetativo, tipo de solo, textura e nutrientes.

Os métodos de previsão podem ser de dois tipos: classificação ou regressão. Uma das funcionalidades da classificação é para categorizar o crescimento das culturas em classes, como bem desenvolvidas, medianamente desenvolvidas e subdesenvolvidas. A regressão fornece valores estimados numericamente. O Aprendizado Profundo utiliza vários tipos de redes neurais e suas combinações para implementar técnicas de classificação e regressão para a previsão de rendimento de culturas.

As Redes Neurais Artificiais (ANN) podem ser empregadas para estimar o rendimento das culturas com base na análise de imagens capturadas periodicamente das plantações, levando em consideração o seu progresso de crescimento, as características do solo e os fatores climáticos. Essa análise é conduzida utilizando imagens das culturas registradas ao longo de seu ciclo de crescimento, a fim de avaliar

sua saúde, desenvolvimento e crescimento. A previsão do rendimento também é realizada com base em variáveis ambientais como temperatura, precipitação e irrigação. As ANNs são treinadas utilizando dados que incluem tanto os fatores ambientais quanto as imagens das culturas, e têm demonstrado alcançar resultados com uma precisão média de 60-70%.

Aprimorar a previsão de rendimento de culturas é possível por meio da análise múltipla dos fatores ambientais. Os dados relacionados a esses fatores, como temperatura e umidade do solo, são coletados e avaliados periodicamente, levando em consideração o ciclo das safras.

A combinação de dados de fatores ambientais e a aplicação do algoritmo *K-means Nearest Neighbor (KNN)* para agrupar propriedades de solo semelhantes proporcionou uma previsão de rendimento estimada de 67%. Dharani (2021), sendo que antes tinha um rendimento de 28%.

Redes Neurais Convolucionais (CNN) são usadas para processar imagens de culturas em diferentes estágios de crescimento. A previsão de rendimento é baseada em imagens de folhas e frutos das culturas. A CNN foi treinada com imagens de várias culturas, incluindo cevada, trigo, abobrinha e frutas cítricas. A precisão da previsão varia de 80% a 90%, dependendo da cultura (Dharani, 2021).

Redes Neurais Profundas (DNN) são uma forma de ANN que usa várias camadas ocultas. O DNN é usado para vincular as características complexas do genótipo da planta e as propriedades de crescimento da planta com fatores climáticos para prever o rendimento das culturas. Foi usado em culturas de milho e arroz, obtendo uma precisão de previsão de cerca de 64% (Dharani, 2021).

A previsão do rendimento das culturas também pode ser realizada com base em fatores atmosféricos como temperatura, comprimento da estação de crescimento e imagens de sensores e drones. Essa abordagem de regressão multivariada resultou em uma precisão média de cerca de 64,5% (Dharani, 2021).

Redes Neurais Memória de Longo Prazo (LSTM) são usadas para prever o rendimento de culturas com base em dados de séries temporais. Os fatores incluem índices vegetativos, dados climáticos e ambientais. A precisão da previsão varia de 85% a 89%, dependendo da cultura e dos fatores ambientais.

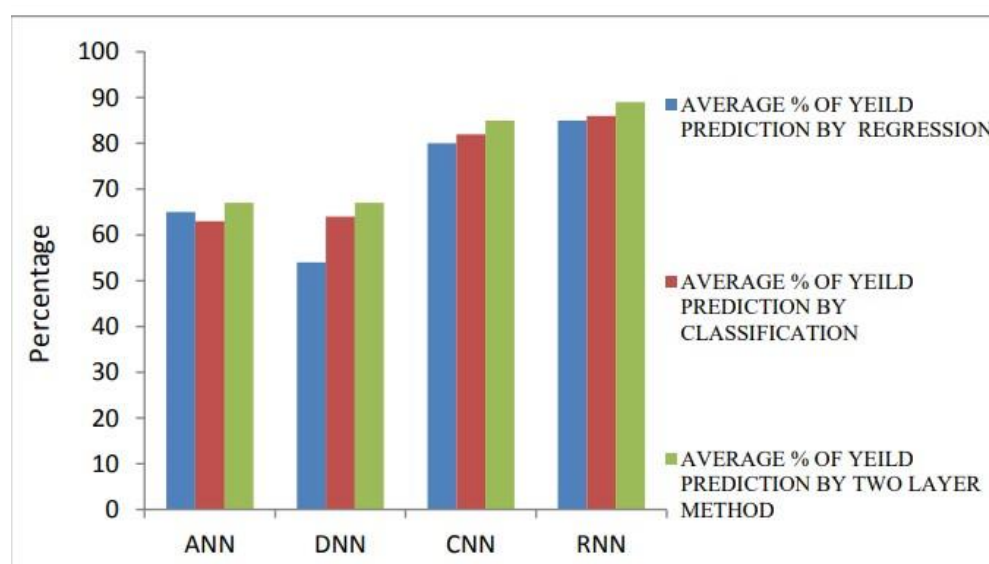
Redes Neurais Híbridas (*HNN*) combinam (*ANN*) com técnicas de aprendizado de máquina. Elas são usadas para monitorar a temperatura, umidade e chuvas para prever as condições climáticas e de irrigação, melhorando assim o rendimento das culturas.

A previsão de rendimento também é melhorada com a análise de dados multitemporais e imagens de satélite. O uso de algoritmos como o *Bayesian Classifier* resulta em previsões precisas de até 87,7%. Além disso, o uso de algoritmos metaheurísticos e modelos de cultivo permite prever o rendimento das culturas com uma precisão de cerca de 85%. A aplicação de algoritmos de aprendizado por reforço, como *Q-learning*, em conjunto com parâmetros ambientais, eleva a precisão da previsão para até 90% (Dharani,2021).

É importante ressaltar que os resultados destas abordagens podem ser visualizados de forma impactante na figura 2, um gráfico de colunas que destaca a precisão de cada método em relação à previsão de rendimento das culturas. Esta representação visual permite uma compreensão imediata da eficácia de cada técnica, demonstrando como as inovações tecnológicas estão impulsionando a agricultura para um futuro mais promissor e produtivo.

29

**Figura 2 - Média dos treinamentos**



Fonte - Resultado de treinamento (Dharani,2021).

O Aprendizado Profundo revoluciona a agricultura, informando decisões de plantio, prevendo rendimentos e detectando doenças. Otimiza a produção e fortalece a segurança alimentar global. Futuramente, sua aplicação continuará a impulsionar a agricultura para enfrentar os desafios atuais (Liakos,2018).

### **3 CONCLUSÃO**

Com isso, conclui-se que o Aprendizado Profundo tem demonstrado ser uma ferramenta poderosa e versátil na agricultura, desempenhando um papel essencial na otimização da produção agrícola e na mitigação de desafios crescentes. Neste artigo, exploramos diversas aplicações do Aprendizado Profundo na agricultura, destacando seu impacto em áreas-chave: identificação de doenças nas plantas com o uso de CNN e outras técnicas de treinamento, mapeamento de clima e solo, previsão de rendimento de culturas e redes neurais híbridas.

No entanto, é crucial ressaltar que o Aprendizado Profundo não é uma solução isolada. A colaboração entre cientistas, agricultores, especialistas em IA e decisores políticos é fundamental para garantir a eficácia e a ética na implementação dessas tecnologias. Além disso, é essencial considerar questões relacionadas à privacidade dos dados, ao acesso à tecnologia e ao treinamento dos agricultores.

À medida que enfrentamos desafios globais, como a mudança climática e o aumento da demanda por alimentos, o Aprendizado Profundo oferece uma ferramenta para melhorar a produtividade agrícola e a segurança alimentar. Com o contínuo avanço da tecnologia e a colaboração contínua entre diversas partes interessadas, é possível colher os benefícios do Aprendizado Profundo na agricultura e garantir um futuro mais sustentável para a produção de alimentos.

No futuro, planejo explorar a combinação de diferentes tipos de dados, como imagens de satélite, dados climáticos, informações do solo e dados genômicos das plantas, para criar modelos de Aprendizado Profundo mais robustos e precisos para previsão de rendimento de culturas e tomada de decisões agrícolas.



## REFERÊNCIAS

DHARANI, M K; THAMILSELVAN, R; NATESAN, P; KALAIVAANI, Pcd; SANTHOSHKUMAR, S. Review on Crop Prediction Using Deep Learning Techniques. **Journal Of Physics: Conference Series**, [S.l.], v. 1767, n. 1, p. 012026, fev. 2021. DOI: <http://dx.doi.org/10.1088/1742-6596/1767/1/012026>

PAUDEL, Dilli; BOOGAARD, Hendrik; WIT, Allard de; JANSSEN, Sander; OSINGA, Sjoukje; PYLIANIDIS, Christos; ATHANASIADIS, Ioannis N.. Machine learning for large-scale crop yield forecasting. **Agricultural Systems**, [S.l.], v. 187, p. 103016, fev. 2021. DOI: <http://dx.doi.org/10.1016/j.agsy.2020.103016>.

CHEN, Jiasi; RAN, Xukan. DeepLearning With Edge Computing: a review. **Proceedings Of The Ieee**, v. 107, n. 8, p. 1655-1674, ago. 2019. DOI: <http://dx.doi.org/10.1109/jproc.2019.2921977>.

ED-DAOUDI, Rachid; ALAOUI, Altaf; ETTAKI, Badia; ZEROUAOUI, Jamal. Improving Crop Yield Predictions in Morocco Using Machine Learning Algorithms. **Journal Of Ecological Engineering**, [S.l.], v. 24, n. 6, p. 392-400, jun. 2023. DOI: <http://dx.doi.org/10.12911/22998993/162769>.

SALEEM; POTGIETER; ARIF, Mahmood. Plant Disease Detection and Classification by Deep Learning. **Plants**, [S.l.], v. 8, n. 11, p. 468, out. 2019. DOI: <http://dx.doi.org/10.3390/plants8110468>.

SHRESTHA, Garima; DEEPSIKHA; DAS, Majolica; DEY, Naiwrita. Plant Disease Detection Using CNN. In: IEEE APPLIED SIGNAL PROCESSING CONFERENCE (ASPCON), 2020, Índia. **Proceeding** [...]. Índia: IEEE, 2020. DOI: <http://dx.doi.org/10.1109/aspcn49795.2020.9276722>.

SUCHITHRA, M.S.; PAI, Maya L. Improving the prediction accuracy of soil nutrient classification by optimizing extreme learning machine parameters. **Information Processing In Agriculture**, [S.l.], v. 7, n. 1, p. 72-82, mar. 2020. DOI: <http://dx.doi.org/10.1016/j.inpa.2019.05.003>.