

Diagnóstico Precoce de Doenças em Folhas de Milho: Uma Comparação entre CNNs e XGBoost para Classificação de Imagens Agrícolas¹

Leandro Sanches Launé²
Lucas Gabriel Sousa da Fonseca³
Luis Eduardo José de Carvalho⁴
Thomas Airan Coutinho Gomes⁵
Luis Impieri Oliveira⁶
Carlos Antonio Cantanhede de Araújo⁷
Giovanni Lucca França da Silva⁸

ABSTRACT

Plant leaf diseases in corn crops pose a significant threat to agricultural production, leading to substantial economic losses. Given the importance of corn for global food security and the economy, the development of accurate machine learning-based tools for the early diagnosis of these diseases is essential. This study aimed to compare the effectiveness of Convolutional Neural Networks (CNNs) and XGBoost in classifying images of corn leaves, aiming to assist in disease identification and agricultural management.

Keywords: Machine learning; Image classification; Leaf diseases; Corn; Convolutional neural networks; XGBoost.

RESUMO

Doenças foliares em plantações de milho representam uma ameaça significativa à produção agrícola, podendo causar perdas econômicas consideráveis. Dada a importância do milho para a segurança alimentar e a economia global, o desenvolvimento de ferramentas precisas, baseadas em aprendizagem de máquina, para o diagnóstico precoce dessas doenças é fundamental. Este trabalho teve como objetivo comparar a eficácia de Redes Neurais Convolucionais (CNNs) e XGBoost na classificação de imagens de folhas de milho, visando auxiliar na identificação de doenças e no manejo agrícola.

Palavras-chave: Aprendizado de máquina; Classificação de imagens; Doenças foliares; Milho; Redes neurais convolucionais; XGBoost.

¹Artigo proveniente de desafio.

²Graduando em Engenharia de Software, UNDB e leandroabc1401@gmail.com.

³Graduando em Engenharia de Software, UNDB e lucasfonseca.software@gmail.com.

⁴Graduando em Engenharia de Software, UNDB e eduardocarvdev@gmail.com.

⁵Graduando em Engenharia de Software, UNDB e thomasairancoutinhogomes@gmail.com.

⁶Graduando em Engenharia de Software, UNDB e luis.impieri.oliveira@gmail.com.

⁷Graduando em Engenharia de Software, UNDB e carlos-antonio21@live.com.

⁸Professor orientador. Ph.D. em ciência da computação pela UFMA, giovanni.silva@undb.edu.br



XVII ENCONTRO CIENTÍFICO DA UNDB
COMUNIDADES TRADICIONAIS: DESAFIOS E PERSPECTIVAS
(XVII EC 2024)

1. INTRODUÇÃO

A cultura do milho é de grande importância para a segurança alimentar global, sendo um alimento básico para consumo humano e animal. No entanto, a produtividade do milho é frequentemente afetada por diversas doenças foliares, causando prejuízos econômicos significativos aos agricultores [1]. O diagnóstico precoce e preciso dessas doenças é crucial para a adoção de medidas de controle adequadas, minimizando perdas na produção.

Tradicionalmente, o diagnóstico de doenças foliares em milho é realizado por agrônomos especialistas, por meio de observação visual das plantas. Entretanto, esse método pode ser subjetivo, impreciso e demorado, especialmente para grandes lavouras.

Neste contexto, a Inteligência Artificial (IA) surge como uma ferramenta promissora para o desenvolvimento de sistemas automatizados de diagnóstico de doenças foliares. O Aprendizado de máquina, um subcampo da IA, possibilita o treinamento de modelos computacionais para reconhecimento de padrões a partir de imagens de folhas de milho. Esses modelos podem auxiliar os produtores na identificação precoce de doenças, permitindo a aplicação de medidas de controle mais assertivas e oportunas.

O presente trabalho tem como objetivo principal comparar o desempenho de Redes Neurais Convolucionais (CNNs) e XGBoost na classificação de doenças foliares em plantas de milho. A escolha dessas técnicas se justifica pela sua ampla utilização em problemas de classificação de imagens e pela sua capacidade de extrair características relevantes dos dados.

1.1 ESPECIFICAMENTE, ESTE ESTUDO BUSCA:

- **Avaliar a precisão de cada modelo:** Comparar a capacidade dos modelos de classificar corretamente as diferentes doenças foliares.
- **Analisar as matrizes de confusão:** Identificar as classes que apresentam maior dificuldade de classificação e as principais fontes de erro.
- **Comparar métricas de desempenho:** Utilizar métricas como precisão, recall e F1-score para avaliar o desempenho de cada modelo de forma mais detalhada.
- **Identificar a técnica mais adequada:** Determinar qual das duas técnicas, CNN ou XGBoost, é mais adequada para a classificação de doenças foliares em milho, considerando os resultados obtidos e as características de cada modelo.
- **Contribuir para o desenvolvimento de ferramentas de auxílio ao diagnóstico:** Desenvolver um sistema de apoio à decisão que possa auxiliar os agricultores na identificação precoce de doenças e na tomada de decisões mais assertivas para o manejo fitossanitário da cultura do milho.

Através da realização deste estudo, espera-se demonstrar o potencial da Inteligência Artificial e do Aprendizado de Máquina para a agricultura de precisão, permitindo a detecção precoce de doenças e a tomada de decisões mais assertivas pelos produtores rurais.

Ao comparar as duas técnicas de aprendizado de máquina, este trabalho visa contribuir para o avanço da pesquisa em agricultura de precisão e para o desenvolvimento de ferramentas que auxiliem os agricultores na tomada de decisões mais eficientes e sustentáveis.

2. MATERIAIS E MÉTODOS

2.1 BASE DE DADOS

Para a realização deste estudo, foi utilizado um conjunto de dados de imagens de folhas de milho obtido da plataforma Plant Village [2]. Esse repositório disponibiliza um vasto banco de imagens rotuladas com diferentes tipos de doenças de plantas. Para

este trabalho, foram selecionadas imagens de milho saudáveis e com três doenças foliares comuns: Cercospora, Ferrugem Comum e Murcha da Folha do Norte.

2.2 PRÉ-PROCESSAMENTO DAS IMAGENS

As imagens do dataset foram submetidas a um processo de pré-processamento para garantir a qualidade dos dados e melhorar o desempenho dos modelos. As etapas envolvidas nesse processo foram:

- **Redimensionamento:** Todas as imagens foram redimensionadas para um tamanho padrão, garantindo que todas as imagens tivessem a mesma dimensão e facilitando o processamento pelos modelos.
- **Conversão para escala de cinza:** As imagens coloridas foram convertidas para escala de cinza, reduzindo a dimensionalidade dos dados e simplificando o processamento.
- **Normalização:** Os valores dos pixels foram normalizados para o intervalo entre 0 e 1, o que contribui para melhorar a convergência dos modelos de aprendizado de máquina.

2.3 MODELOS DE CLASSIFICAÇÃO

2.3.1 REDES NEURAIAS CONVOLUCIONAIS (CNNS)

Uma Rede Neural Convolutiva (CNN) foi implementada utilizando a biblioteca TensorFlow [3]. A arquitetura da CNN consistiu de camadas convolucionais para extração de características das imagens, seguidas de camadas de pooling para redução da dimensionalidade e camadas densamente conectadas para classificação final. A função de ativação ReLU (Rectified Linear Unit) foi utilizada nas camadas convolucionais, enquanto a função softmax foi utilizada na camada de saída para gerar as probabilidades de pertinência a cada classe. O otimizador Adam foi utilizado para o processo de treinamento, e a função de custo categorical cross-entropy foi empregada para avaliar o erro do modelo.

2.3.2 XGBOOST

O algoritmo XGBoost, um modelo de aprendizado de máquina baseado em árvores de decisão potenciadas por gradiente, foi utilizado para a classificação das doenças foliares. As características das imagens foram extraídas utilizando o descritor Haralick, uma técnica de análise de textura baseada em matrizes de co-ocorrência [4]. O XGBoost foi treinado com parâmetros otimizados para o problema de classificação multiclasse.

2.4 AVALIAÇÃO DOS MODELOS

O desempenho dos modelos foi avaliado por meio de métricas padrão de classificação, incluindo acurácia, precisão, recall e F1-score. A matriz de confusão também foi utilizada para visualizar a distribuição das predições do modelo e identificar potenciais erros de classificação.

$$\text{Acurácia} = \frac{PV+NV}{PV+NV+PF+NF} \quad (1)$$

$$\text{Recall} = \frac{PV}{PV+NF} \quad (2)$$

$$\text{Precisão} = \frac{PV}{PV+PF} \quad (3)$$

$$\text{Especificidade} = \frac{NV}{NV+NF} \quad (4)$$

3. RESULTADOS E DISCUSSÃO

3.1 DIVISÃO DA BASE DE DADOS

A base de dados foi dividida em três subconjuntos: treino, validação e teste. O conjunto de treino foi utilizado para treinar os modelos de classificação, o conjunto de validação serviu para monitorar o processo de treinamento e evitar o overfitting, e o conjunto de teste foi utilizado para avaliar o desempenho final dos modelos em dados nunca vistos anteriormente.

3.2 HIPERPARÂMETROS

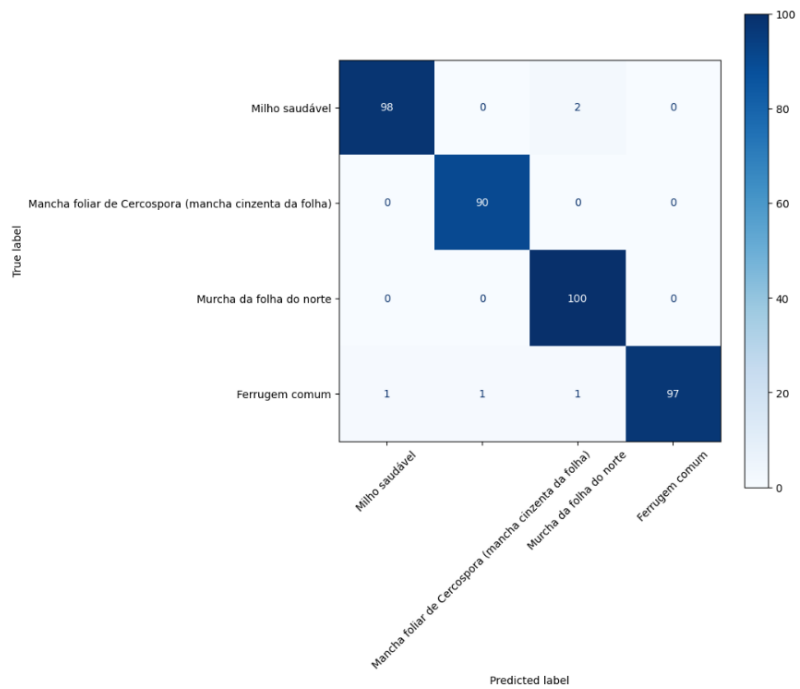
Na CNN utilizou-se 20 épocas, a função de custo: `sparse_categorical_crossentropy` e a função de otimização: Adam. O tamanho do lote foi 32 (valor padrão do TensorFlow). O tamanho do kernel foi: (3, 3) para todas as camadas convolucionais. Acerca do tipo de amostragem usando máxima ativação, foi utilizado: Camadas de MaxPooling: (2, 2) em todas as camadas de pooling.

No XGBoost foram utilizado os parâmetros: `objective: 'multi:softmax'` para multiclasse, `eval_metric: 'mlogloss'` para medir a performance do modelo, `num_class: 4` indicando o número de classes, `max_depth: 4` profundidade máxima das árvores, `eta: 0.1` parametro para a taxa de aprendizagem e `subsample: 0.8` proporção dos dados utilizados para treinar cada árvore.

Após o treinamento e avaliação dos modelos CNN e XGBoost, obtivemos os seguintes resultados. A rede neural convolucional (CNN) apresentou um desempenho excepcional, alcançando uma **acurácia de 98,46%** no conjunto de validação. Essa alta taxa de acerto demonstra a eficácia da CNN em classificar as doenças foliares em milho. A análise da matriz de confusão e do relatório de classificação detalhado revela:

- **Alta precisão e recall** para todas as classes, indicando que o modelo consegue tanto identificar corretamente as amostras de cada classe quanto minimizar o número de falsos positivos e falsos negativos.
- **Desempenho superior** para as classes "Milho Saudável" e "Mancha Foliar de Cercospora", com precisão e recall próximos a 100%.
- **Levemente menor precisão** para as classes "Murcha da Folha do Norte" e "Ferrugem Comum", embora os resultados ainda sejam muito bons.

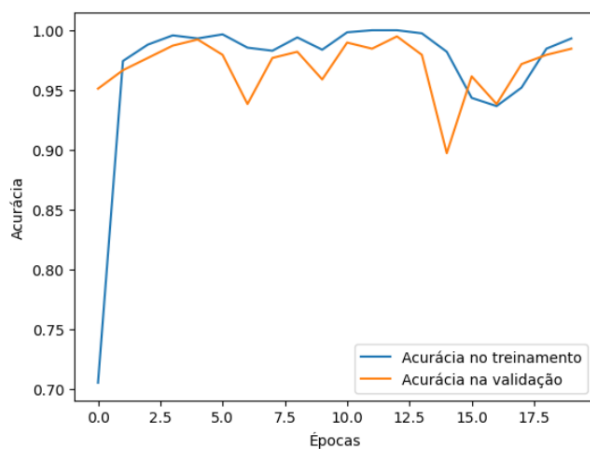
Matriz de confusão:



Acurácia no conjunto de Validação:

13/13 - 0s - 25ms/step - accuracy: 0.9846 - loss: 0.1006
Acurácia no conjunto de validação: 98.46%

Plotagem do desempenho:



Relatório de Classificação por Classe:

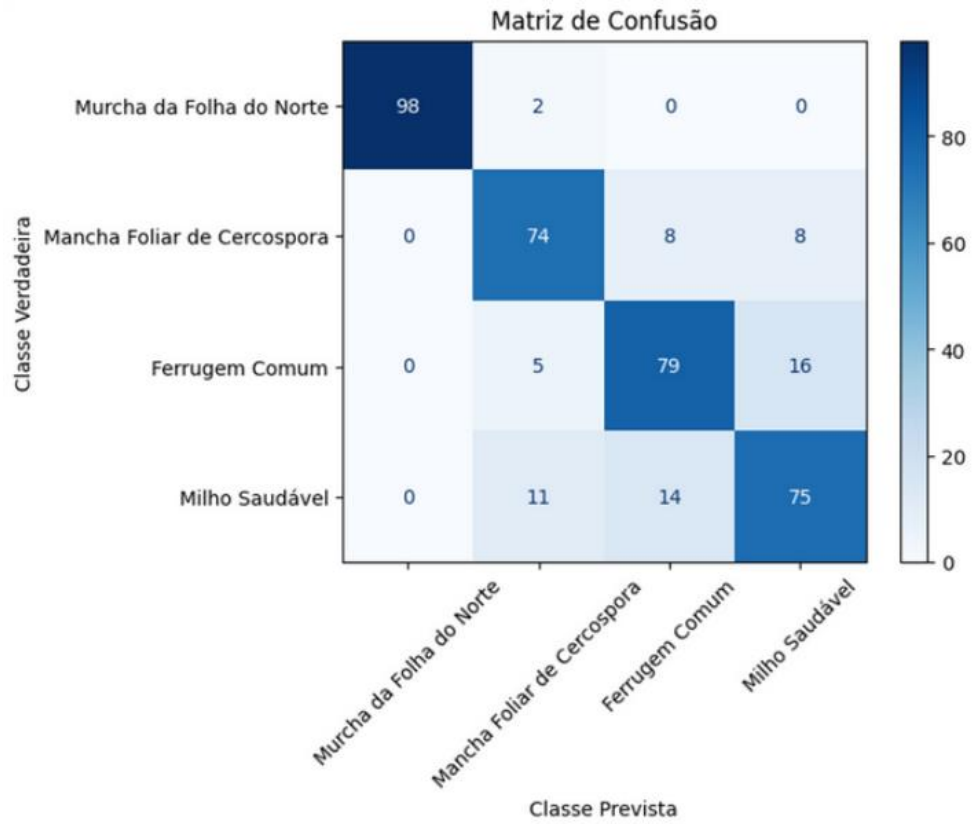
CLASSES	PRECISION	RECALL
Milho Saudável	0.99	0.98
Mancha Foliar de Cercospora(mancha cinzenta da folha)	0.99	1.00
Murcha da Folha do Norte	0.97	1.00
Ferrugem Comum	1.00	0.97
accuracy	/	/
macro avg	0.99	0.99
weighted avg	0.99	0.99

Ao aplicar o **XGBoost** com características de Haralick, o modelo mostrou-se eficiente na classificação das folhas de milho. Aqui estão os principais resultados:

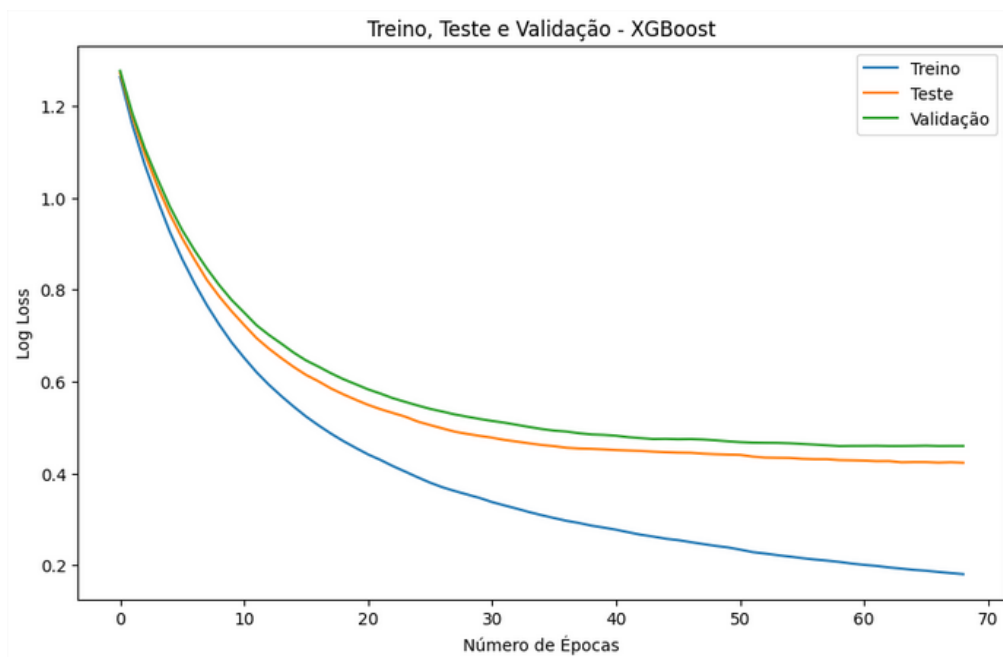
- Murcha da Folha do Norte: Precisão 1.00, recall 0.98, f1-score 0.99 (98 acertos, 2 erros).
- Mancha Foliar de Cercospora: Precisão 0.80, recall 0.82, f1-score 0.81 (74 acertos, 16 erros).
- Ferrugem Comum: Precisão 0.78, recall 0.79, f1-score 0.79 (79 acertos, 21 erros).
- Milho Saudável: Precisão 0.76, recall 0.75, f1-score 0.75 (75 acertos, 25 erros).

A precisão geral do modelo é de 83,59%, com uma média macro de 0.84 para precisão, recall e f1-score.

Matriz de confusão:



Plotagem do desempenho:



Relatório de Classificação por Classe:

CLASSES	PRECISION	RECALL
Murcha da Folha do Norte	1.00	0.98
Mancha Foliar de Cercospora	0.80	0.82
Ferrugem Comum	0.78	0.79
Milho Saudável	0.76	0.75
accuracy	/	/
macro avg	0.84	0.84
weighted avg	0.84	0.84

3.3 IMPACTO NO AGRONEGÓCIO

Apesar da alta acurácia do CNN, o XGBoost não fica para trás, podendo ser uma potencial alternativa para ser usado no Agronegócio. A aplicação de XGBoost com características de Haralick para a classificação de folhas de milho tem um impacto significativo no agronegócio. A identificação rápida e precisa de doenças nas folhas permite intervenções mais eficazes, reduzindo perdas de colheita e melhorando a produtividade. O uso de técnicas de aprendizado de máquina automatiza o diagnóstico, economizando tempo e recursos.

3.4 DISCUSSÃO

Os resultados obtidos demonstram que a CNN superou o XGBoost na tarefa de classificação de doenças foliares em milho. A alta acurácia da CNN pode ser atribuída a diversas razões, incluindo:

- **Capacidade de extrair características hierárquicas:** As CNNs são capazes de aprender automaticamente as características mais relevantes das imagens, como texturas, formas e padrões, o que as torna mais eficientes na identificação de nuances visuais.

- **Adaptabilidade a grandes volumes de dados:** As CNNs podem lidar com grandes quantidades de dados e aprender representações complexas, o que as torna ideais para problemas de classificação de imagens com alta variabilidade.
- **Capacidade de generalização:** As CNNs treinadas com um grande número de imagens tendem a generalizar bem para novos dados, o que é fundamental para aplicações em ambientes reais.

3.5 COMPARAÇÃO COM XGBOOST

- **Extração Manual de Características:** no XGBoost, as características de Haralick foram extraídas manualmente antes do treinamento do modelo. Enquanto essas características são poderosas, elas podem não capturar toda a complexidade dos padrões visuais presentes nas imagens.
- **Modelo Linear vs. Não Linear:** XGBoost, mesmo sendo um modelo robusto, pode não capturar tão bem os padrões complexos e não lineares que as CNNs conseguem identificar.

3.6 CONSIDERAÇÕES ADICIONAIS:

- **Influência da arquitetura da CNN:** a escolha da arquitetura da CNN, incluindo o número de camadas, o tamanho dos filtros e a função de ativação, pode impactar significativamente o desempenho do modelo.
- **Otimização dos hiperparâmetros:** a otimização dos hiperparâmetros tanto da CNN quanto do XGBoost é crucial para obter os melhores resultados.
- **Aumento do conjunto de dados:** um conjunto de dados maior e mais diversificado pode melhorar ainda mais o desempenho dos modelos, especialmente para classes com poucas amostras.

4. CONCLUSÃO

Os resultados obtidos neste estudo demonstram o grande potencial das Redes Neurais Convolucionais (CNNs) para a classificação precisa e eficiente de doenças foliares em milho. A CNN utilizada neste trabalho alcançou uma acurácia de 98,46%,

superando significativamente o modelo XGBoost. Essa alta performance indica que a CNN é uma ferramenta poderosa para o desenvolvimento de sistemas automatizados de diagnóstico de doenças em plantas, com aplicações diretas na agricultura de precisão.

A capacidade da CNN em extrair características hierárquicas das imagens e aprender representações complexas a torna ideal para lidar com a variabilidade visual presente em imagens de folhas de milho afetadas por diferentes doenças. Além disso, a alta taxa de acerto da CNN demonstra sua robustez em relação a ruídos e variações nas condições de captura das imagens.

Os resultados deste trabalho contribuem para o avanço da pesquisa em agricultura de precisão, abrindo novas perspectivas para o desenvolvimento de ferramentas de diagnóstico de doenças em plantas mais precisas e eficientes. A detecção precoce de doenças permite a adoção de medidas de controle mais eficazes, reduzindo perdas na produção e otimizando o uso de recursos.

4.1 IMPLICAÇÕES PARA A AGRICULTURA DE PRECISÃO.

A implementação de sistemas de diagnóstico de doenças em plantas baseados em aprendizado de máquina pode trazer diversos benefícios para a agricultura, como:

- **Aumento da eficiência na produção:** a detecção precoce de doenças permite a aplicação de medidas de controle mais precisas e oportunas, reduzindo perdas na produção e otimizando o uso de insumos agrícolas.
- **Redução do uso de agrotóxicos:** a utilização de modelos de aprendizado de máquina pode contribuir para a redução do uso de agrotóxicos, promovendo uma agricultura mais sustentável e com menor impacto ambiental.
- **Melhoria da qualidade dos produtos agrícolas:** a identificação precoce e o controle de doenças contribuem para a produção de alimentos de melhor qualidade, com menor incidência de resíduos de agrotóxicos.
- **Redução de custos de produção:** A otimização do manejo fitossanitário, com base em informações precisas sobre o estado de saúde das plantas, pode gerar economia de custos para os agricultores.

4.2 TRABALHOS FUTUROS

Embora os resultados obtidos neste estudo sejam promissores, ainda há diversas oportunidades para futuras pesquisas. Algumas sugestões incluem:

- **Integração com sistemas de agricultura de precisão:** A integração dos modelos de classificação de doenças em sistemas de agricultura de precisão pode permitir a criação de ferramentas mais completas para o manejo de lavouras.
- **Desenvolvimento de aplicativos móveis:** O desenvolvimento de aplicativos móveis que permitam aos agricultores capturar imagens de suas plantas e obter diagnósticos em tempo real pode facilitar a adoção dessas tecnologias.

REFERÊNCIAS

CASTRO NETO, Jarbas Caiado de; ODA, Yuri Sarreta. Desenvolvimento de sistema aplicado à Agricultura de Precisão para classificação de plantas de soja e plantas daninhas utilizando Visão Computacional e imagens multiespectrais. **Livro de Resumos**, 2023.

SILVA, Elizângela Maria Gonçalves; GERMANO, Renato. UTILIZAÇÃO DE VISÃO COMPUTACIONAL E DEEP LEARNING PARA SEPARAÇÃO DE GRÃOS: UM PROTÓTIPO DE BAIXO CUSTO BASEADO NO ARDUINO. In: **TECNOLOGIAS EDUCACIONAIS: FERRAMENTAS DISRUPTIVAS EM FAVOR DO ENSINO**. Editora Científica Digital, 2024. p. 85-106.

SANTOS, Thiago Teixeira et al. Visão computacional aplicada na agricultura. 2020.

SILVA, Moisés J.; SCHIMIGUEL, Juliano. Identificação de doenças em plantas por meio de processamento de imagens: redes neurais convolucionais como auxílio à agricultura. **Revista de Ubiquidade**, v. 3, n. 1, p. 91-111, 2020.

HEMALATHA, S.; SANGEETHA, M. Identificação de pragas na agricultura de precisão usando aquisição de dados de imagem de baixo custo. **Brazilian Journal of Biology**, v. 84, p. e281671, 2024.

MENESES, Kamila Cunha De. Rumo à agricultura inteligente: previsão de produtividade agrícola com dados agrometeorológicos usando machine learning. 2021.

ADJITCHE, I. C. D.; BALICO, L.; BENDAHAN, A. B. Classificação automática em pastagem usando machine learning. 2020.

ROUT, Ranjita; PARIDA, Priyadarsan. A review on leaf disease detection using computer vision approach. In: **Intelligent Techniques and Applications in Science and Technology: Proceedings of the First International Conference on Innovations in**



XVII ENCONTRO CIENTÍFICO DA UNDB
COMUNIDADES TRADICIONAIS: DESAFIOS E PERSPECTIVAS
(XVII EC 2024)

Modern Science and Technology 1. Springer International Publishing, 2020. p. 863-871.

LU, Jinzhu; TAN, Lijuan; JIANG, Huanyu. Review on convolutional neural network (CNN) applied to plant leaf disease classification. **Agriculture**, v. 11, n. 8, p. 707, 2021.

UPADHYAY, Santosh Kumar; KUMAR, Avadhesh. A novel approach for rice plant diseases classification with deep convolutional neural network. **International Journal of Information Technology**, v. 14, n. 1, p. 185-199, 2022.

DUBEY, Ratnesh Kumar; CHOUBEY, Dilip Kumar. Feature selection with Optimized XGBoost model-based paddy plant leaf disease classification. **Multimedia Tools and Applications**, p. 1-16, 2024.

TANAKA, Sergio Kenji Sawasaki; PEREIRA, Eron Ponce; COLETO, Bruno Henrique; TANAKA, Sergio Akio. Aplicação da inteligência artificial no agronegócio utilizando Deep Learning para identificação de doenças em culturas. **Revista Terra & Cultura: Cadernos de Ensino e Pesquisa**, v. 40, n. especial, p. 23-31, 2024.