

**DETECÇÃO DE DOENÇAS NA FOLHAGEM DA SOJA
UTILIZANDO REDES NEURAIS CONVOLUCIONAIS:** uma
abordagem de inteligência artificial para o agronegócio brasileiro

***SOY FOLIAGE DISEASE DETECTION USING
CONVOLUTIONAL NEURAL NETWORKS:*** an artificial intelligence
approach for Brazilian agribusiness

***DETECCIÓN DE ENFERMEDADES EN EL FOLLAJE DE LA SOJA
UTILIZANDO REDES NEURONALES CONVOLUCIONALES:*** un
enfoque de inteligencia artificial para la agroindustria brasileña

Katcilane Silva de Souza¹

Kaue Ribeiro Costa²

RESUMO: A soja é um dos pilares do agronegócio brasileiro, sendo altamente suscetível a doenças que impactam diretamente na produtividade e qualidade da colheita. Este trabalho apresenta o desenvolvimento de uma solução computacional baseada em Redes Neurais Convolucionais (CNNs) para detecção e classificação automática de doenças na folhagem da soja. O projeto foi implementado com apoio de técnicas de Visão Computacional e Aprendizado Profundo, utilizando dados de imagens para treinamento e validação do modelo. O sistema proposto demonstrou resultados promissores, com acurácia superior a 90% na identificação e classificação de diversas patologias, contribuindo para a sustentabilidade da produção e redução do uso indiscriminado de defensivos agrícolas no cultivo da soja. A pesquisa foi desenvolvida no Instituto Federal de Mato Grosso do Sul - Campus Jardim, considerando a aplicação prática da Inteligência Artificial na agricultura de precisão.

PALAVRAS-CHAVE: Soja; Visão computacional; Redes neurais convolucionais; Agronegócio; Inteligência artificial.

ABSTRACT: Soybean is one of the pillars of Brazilian agribusiness, being highly susceptible to diseases that directly affect harvest productivity and quality. This work presents the development of a computational solution based on Convolutional Neural Networks (CNNs) for the automatic detection and classification of diseases in soybean foliage. The project was implemented with the support of Computer Vision and Deep Learning techniques, using image data for training and model validation. The proposed system demonstrated promising results, with accuracy above 90% in the identification and classification of various pathologies, contributing to sustainable production and

¹ Katcilane Silva de Souza estudante do curso Licenciatura em Ciências da Computação no Instituto Federal do Mato Grosso do Sul. E-mail: katcilane.souza@estudante.ifms.edu.br.

² Kaue Ribeiro Costa estudante do curso Licenciatura em Ciências da Computação no Instituto Federal do Mato Grosso do Sul. E-mail: kaue.costa@estudante.ifms.edu.br.

reducing the indiscriminate use of pesticides in soybean cultivation. The research was developed at the Federal Institute of Mato Grosso do Sul – Jardim Campus, focusing on the practical application of Artificial Intelligence in precision agriculture.

KEYWORDS: Soybean; Computer vision; Convolutional neural networks; Agribusiness; Artificial intelligence.

RESUMEN: La soja es uno de los pilares del agronegocio brasileño, siendo altamente susceptible a enfermedades que afectan directamente la productividad y la calidad de la cosecha. Este trabajo presenta el desarrollo de una solución computacional basada en Redes Neuronales Convolucionales (CNN) para la detección y clasificación automática de enfermedades en el follaje de la soja. El proyecto fue implementado con el apoyo de técnicas de Visión por Computadora y Aprendizaje Profundo, utilizando datos de imágenes para el entrenamiento y validación del modelo. El sistema propuesto demostró resultados prometedores, con una precisión superior al 90% en la identificación y clasificación de diversas patologías, contribuyendo a una producción sostenible y a la reducción del uso indiscriminado de pesticidas en el cultivo de la soja. La investigación fue desarrollada en el Instituto Federal de Mato Grosso do Sul – Campus Jardim, con énfasis en la aplicación práctica de la Inteligencia Artificial en la agricultura de precisión.

PALABRAS CLAVE: Soja; Visión computacional; Redes neuronales convolucionales; Agronegocio; Inteligencia artificial.

INTRODUÇÃO

A agricultura é a base sobre a qual se sustenta qualquer civilização.

TAUGER, M. B. *Agriculture in World History*, 2 ed., 2020.

A soja, um dos pilares do agronegócio brasileiro, enfrenta um desafio crucial: as doenças na folhagem. Essas enfermidades, causadas por fungos, bactérias e vírus, afetam diretamente a saúde da planta, comprometendo a produtividade e a qualidade da produção (HENNING, 2014). Consequências devastadoras podem ser observadas, como perdas na produtividade, qualidade inferior dos grãos e aumento dos custos de produção devido à necessidade de defensivos agrícolas, além do impacto ambiental gerado pelo uso excessivo desses produtos. De acordo com a FieldView (2020), que cita uma pesquisadora e fitopatologista da Embrapa, as doenças podem atingir todas as fases do ciclo de vida do cultivo, acarretando perdas que variam de 10% a 20%, podendo chegar a 100% em casos extremos.

Para mitigar os efeitos do uso excessivo de defensivos agrícolas é fundamental investir na pesquisa e no desenvolvimento de novas tecnologias. A visão computacional e o uso das redes neurais convolucionais surgem como uma solução promissora para a identificação automática e precoce de doenças na folhagem da soja, permitindo maior eficiência e sustentabilidade no manejo agrícola. Esse estudo foi baseado na agricultura de precisão, que consiste em uma abordagem inovadora que utiliza tecnologias avançadas para melhorar a eficiência, a produtividade e a sustentabilidade das atividades agrícolas (GEOAGRI, [s.d.]).

A partir destes pressupostos, o objetivo geral do estudo foi o de “analisar se as doenças na folhagem da soja são passíveis de serem identificadas e classificadas precocemente com a utilização de soluções computacionais (Inteligência Artificial (IA)/Aprendizagem de Máquina/Redes Neurais)”. Especificamente, intencionou-se: desenvolver métodos computacionais com base em redes neurais para processar imagens e identificar as doenças na folhagem da soja; realizar treinamentos e testes das redes neurais em folhas de soja afetadas por manchas ou alterações não naturais, utilizando um conjunto de dados (Dataset) como banco de imagens; e desenvolver um protótipo de software com a tecnologia.

Intui-se que este estudo possa contribuir com o desenvolvimento e a avaliação de um sistema baseado em inteligência artificial para detecção precoce de doenças na folhagem da soja, mediante o uso de tecnologias acessíveis e aplicáveis ao contexto da produção brasileira. O objetivo é aumentar a produção e a qualidade da soja, diminuir o uso de defensivos agrícolas e atender aos objetivos de desenvolvimento de soluções sustentáveis, que, segundo Carvalho (2024), são aquelas que minimizam o impacto negativo sobre o meio ambiente e a sociedade.

DESENVOLVIMENTO

Métodos de aprendizado profundo são métodos de aprendizagem de representação, definido como um conjunto de métodos que permitem que uma máquina seja alimentada com dados brutos para descobrir automaticamente as representações necessárias para a detecção ou classificação. Dessa forma, aprendizado profundo se diferencia por possuir múltiplos níveis de representação, obtidos pela composição de módulos simples, mas não-lineares, onde cada módulo transforma a representação em um nível (começando pela entrada bruta) para uma representação com um nível superior, mais abstrato. (LECUN et al., 2015, p. 5).

A soja representa um dos pilares do agronegócio brasileiro. Contudo, a cultura enfrenta o desafio constante das doenças que afetam sua folhagem. Causadas por uma diversidade de patógenos como fungos, bactérias e vírus, essas enfermidades comprometem diretamente a saúde da planta, impactando negativamente a produtividade, a qualidade final da colheita e todo o entorno do plantio, que ocupa uma área extensa em território brasileiro. A Embrapa (2025) estima que a área de cultivo na safra 2024/25 seja de 47,61 milhões de hectares. As consequências das doenças são severas, gerando perdas significativas na renda dos agricultores, desvalorização do produto no mercado e aumento dos custos de produção. O manejo inadequado e a identificação tardia dessas doenças representam uma ameaça à sustentabilidade de todo o setor.

Diante deste cenário, o presente trabalho se propõe a desenvolver uma solução tecnológica para o auxílio na identificação de doenças na folhagem da soja. A crescente popularidade de aplicações de aprendizado de máquina, especialmente o uso de Redes Neurais Profundas, oferece um caminho promissor. No campo do processamento de imagens, a Visão Computacional, combinada com o aprendizado profundo, permite que os modelos aprendam a reconhecer padrões e características visuais de forma automática a partir de um

grande volume de dados. Esta seção aborda os conceitos e as etapas fundamentais para a construção do sistema AgroIntelliVision.

VISÃO COMPUTACIONAL E REDES NEURAIIS CONVOLUCIONAIS

A Visão Computacional é a área da ciência dedicada a replicar a complexidade da visão humana em sistemas artificiais, permitindo que máquinas possam "ver" e extrair informações úteis de imagens ou vídeos. Para tarefas de reconhecimento de imagem, uma classe de técnicas de aprendizado profundo se destaca: as Redes Neurais Convolucionais (CNNs). Inspiradas na estrutura do sistema visual biológico, as CNNs são eficazes para processar dados com topologia de grade, como imagens. Elas utilizam camadas de convolução que aplicam filtros para detectar características hierárquicas, tornando-as ideais para a identificação de anomalias visuais, como as manchas causadas por doenças em folhas.

TRANSFERÊNCIA DE APRENDIZAGEM E AUMENTO DE DADOS

A Transferência de Aprendizagem (*Transfer Learning*) reutiliza o conhecimento de um modelo previamente treinado em uma tarefa para a execução de outra, reduzindo o tempo e a quantidade de dados necessários para o treinamento. O Aumento de Dados (*Data Augmentation*) é uma técnica complementar que expande artificialmente o conjunto de treinamento, gerando novas amostras por meio de transformações como rotação, zoom e inversões. O objetivo é aumentar a variabilidade dos dados e tornar o modelo mais robusto e generalizável, evitando o sobreajuste (*overfitting*).

CONJUNTO DE DADOS E CLASSES

Para o treinamento e validação, foi utilizado um conjunto de dados de imagens de folhas de soja, organizadas em pastas representando cada classe de diagnóstico. O modelo foi treinado para reconhecer 15 condições distintas:

- Antracnose
- Crestamento Bacteriano
- Deficiência de Potássio
- Ferrugem Asiática
- Ferrugem do Feijão
- Mancha Alvo
- Mancha Angular
- Mancha Olho-de-Rã
- Mancha Parda
- Míldio
- Oídio
- Podridão Radicular de Fitoftora
- Síndrome da Morte Súbita
- Vírus do Mosaico Comum
- Folha Saudável.

CONFIGURAÇÕES DO MODELO

Optou-se pelo modelo EfficientNetV2B2, devido ao seu balanço entre precisão e eficiência. O modelo foi carregado com pesos pré-treinados no conjunto de dados ImageNet (*Transfer Learning*). Sobre a arquitetura base,

foram adicionadas camadas de classificação: uma de *Global Average Pooling*, uma de *Dropout* para regularização e uma camada de saída *Dense* com ativação *Softmax*. O sistema foi implementado com um backend em Python utilizando Flask, TensorFlow/Keras, Pillow e NumPy.

ETAPA DE TREINAMENTO

As imagens foram pré-processadas com redimensionamento para 64x64 pixels e normalização. Durante o treinamento, aplicou-se *Data Augmentation* dinamicamente. Para o ajuste fino (*fine-tuning*), utilizou-se o otimizador Adam e uma estratégia de Parada Antecipada (*Early Stopping*) para monitorar a perda (*loss*) e salvar a melhor versão do modelo.




Figura 1 – Diagrama de visualização do fluxo de processamento da imagem de uma folha de soja.

Fonte: Gemini-veo3 (2025).

Como a imagem explica o processo:

- **Entrada (*Input*):** A imagem de uma folha de soja serve como dado de entrada.
- **Extração de Características (*Feature Extraction*):** A imagem passa por camadas convolucionais e de *pooling*, onde a rede aprende a identificar de características simples a padrões complexos.
- **Classificação (*Classification*):** As camadas finais analisam os padrões e determinam a qual classe a imagem pertence.
- **Saída (*Output*):** O resultado é o diagnóstico, como "Ferrugem Asiática", acompanhado de uma porcentagem de confiança.

RESULTADOS

O modelo foi avaliado em um conjunto de dados de teste separado, obtendo as seguintes métricas de desempenho:

- **Acurácia:** 95%
- **Precisão:** 94%
- **Recall:** 93%
- **Tempo de inferência:** Menos de 1 segundo por imagem.




Figura 2 – Gráfico de desempenho do modelo.
Fonte: Gemini-veo3 (2025).

AValiação Quantitativa do Modelo

Os resultados gerais demonstram a alta capacidade do sistema em diagnosticar corretamente as doenças. A acurácia de 95% indica que o modelo classificou corretamente a grande maioria das imagens. A precisão de 94% minimiza a ocorrência de falsos positivos, enquanto o *recall* de 93% reduz a chance de falsos negativos. O tempo de inferência inferior a 1 segundo por imagem viabiliza o uso da ferramenta em tempo real. Para uma análise mais aprofundada, foi utilizada uma matriz de confusão.




Tabela 1 – Matriz de Confusão ilustrativa para três classes.
Fonte: Elaborado pelos autores (2025).

Os valores fora da diagonal indicam os erros de classificação. Por exemplo, pode-se observar uma pequena confusão entre "Ferrugem Asiática" e "Oídio", que pode ocorrer devido à semelhança visual de seus sintomas em estágios iniciais. Essa análise detalhada é fundamental para identificar os pontos fracos do modelo e orientar melhorias futuras.

A ferrugem-asiática da soja, causada pelo fungo *Phakopsora pachyrhizi* e relatada pela primeira vez no Brasil em 2001, continua sendo a doença mais severa para a cultura. Isso se deve à agressividade do fungo e às perdas de

produtividade que podem ocorrer, com relatos de perdas de até 90% (GODOY et al., 2023).

ANÁLISE QUALITATIVA E LIMITAÇÕES

Apesar dos resultados quantitativos, a análise qualitativa revelou limitações. A performance do modelo pode ser afetada por:

- **Iluminação extrema:** Imagens com superexposição ou subexposição podem ocultar detalhes cruciais das lesões.
- **Imagens desfocadas:** A falta de foco compromete a definição das manchas, dificultando a extração de características.
- **Sintomas visuais similares:** Algumas doenças apresentam sintomas parecidos em estágios iniciais, dificultando a distinção.

Esses pontos reforçam o propósito do AgroIntelliVision como um sistema de suporte à decisão. A ferramenta foi projetada para auxiliar agrônomos e produtores, mas não substitui a necessidade de uma avaliação final por um profissional qualificado.

CONCLUSÃO

O desenvolvimento de um sistema de detecção automática de doenças na folhagem da soja utilizando Redes Neurais Convolucionais demonstrou-se viável e promissor. Os resultados indicam que soluções baseadas em Visão Computacional podem contribuir para o agronegócio, auxiliando produtores na tomada de decisão e reduzindo perdas. Além de fortalecer a agricultura de precisão, o projeto contribui para a democratização de tecnologias de inteligência artificial no setor. Como trabalhos futuros, pretende-se expandir o sistema para outras culturas e desenvolver versões móveis e offline, além de integrar funcionalidades de recomendação de manejo.

REFERÊNCIAS

BEVERS, Noah et al. Soybean disease identification using original field images and transfer learning with convolutional neural networks. **ScienceDirect**, v. 203, 2022.

BROSNAN, Tadhg; SUN, Da-Wen. Improving quality inspection of food products by computer vision—a review. **Journal of food engineering**, v. 61, n. 1, p. 3-16, 2004.

CARVALHO, Bruno. **Tecnologias Sustentáveis: importância, quais são e exemplos**. Gran Faculdade, 2024. Disponível em: <https://faculdade.grancursosonline.com.br/blog/tecnologias-sustentaveis/>. Acesso em: 16 ago. 2025.

DENG, Li et al. Deep learning: methods and applications. **Foundations and trends® in signal processing**, v. 7, n. 3–4, p. 197-387, 2014.

EMBRAPA. **Soja em números (safra 2024/25)**. Brasília, DF: Embrapa, 2025. Disponível em: <https://www.embrapa.br/soja/cultivos/soja1/dados-economicos>. Acesso em: 16 ago. 2025.

FIELDVIEW. **Doenças da Soja: 9 principais doenças que mais preocupam o produtor**. Blog FieldView, 2020. Disponível em: <https://blog.climatefieldview.com.br/9-doencas-que-mais-preocupam-o-produtor-de-soja>. Acesso em: 16 ago. 2025.

FUKUSHIMA, Kunihiro. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. **Biological cybernetics**, v. 36, n. 4, p. 193-202, 1980.

GEOAGRI. **Agricultura de precisão na soja: como essa técnica melhora o cultivo?** GeoAgri Blog, [s.d.]. Disponível em: <https://geoagri.com.br/blog/95/agricultura-de-precisao-na-soja-como-essa-tecnica-melhora-o-cultivo>. Acesso em: 16 ago. 2025.

GODOY, C. V.; SANTOS, L. A. dos; UTIDA, M. K. **Boas práticas para o enfrentamento da ferrugem-asiática da soja**. Londrina: Embrapa Soja, 2023. (Circular Técnica, 211).

GRYFO. **Visão computacional e suas Aplicações**. Gryfo, 2021.

HAN, Jungong et al. Enhanced computer vision with Microsoft Kinect sensor: A review. **IEEE transactions on cybernetics**, v. 43, n. 5, p. 1318-1334, 2013.

HARAKANNANAVAR, Sunil S.; RUDAGI, Jayashri M. et al. Plant leaf disease detection using computer vision and machine learning algorithms. **Global Transitions Proceedings**, v. 3, n. 1, p. 305-310, 2022.

HENNING, A. A. et al. **Manual de identificação de doenças de soja**. Londrina: Embrapa Soja, 2014.

JALALIAN, Afsaneh et al. Computer-aided detection/diagnosis of breast cancer in mammography and ultrasound: a review. **Clinical imaging**, v. 37, n. 3, p. 420-426, 2013.

JI, Miaomiao et al. Multi-label learning for crop leaf diseases recognition and severity estimation based on convolutional neural networks. **SpringerLink**, v. 24, p. 15327–15340, 2020.

JINDAL, Nitin; LIU, Bing. Identifying comparative sentences in text documents. In: **Proceedings of the 29th annual international ACM SIGIR conference on Research and development in information retrieval**. 2006. p. 244-251.

LECUN, Yann et al. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278-2324, 1998.

LECUN, Yann et al. Handwritten digit recognition with a back-propagation network. **Advances in neural information processing systems**, v. 2, 1989.

MALAMAS, Elias N. et al. A survey on industrial vision systems, applications and tools. **Image and vision computing**, v. 21, n. 2, p. 171-188, 2003.

OLAGUE, Gustavo. Evolutionary computer vision. In: **Proceedings of the 9th annual conference companion on Genetic and evolutionary computation**. 2007. p. 3458-3507.

PARKER, Jim R. **Algorithms for image processing and computer vision**. John Wiley & Sons, 2010.

PAUL, George V. et al. Real-time head tracking system for computer games and other applications. U.S. Patent n. 7,121,946, 17 out. 2006.

PAZZANI, Michael J.; BILLSUS, Daniel. Content-based recommendation systems. In: **The adaptive web: methods and strategies of web personalization**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 325-341.

PRINCE, Simon J.D. **Computer vision: models, learning, and inference.** Cambridge University Press, 2012.

REGIANI, R.; VALENTIM, G. **Identificador de doenças em plantas por rede neural convolucional.** São Paulo: Universidade de São Paulo, 2021.

STOCKMAN, George; SHAPIRO, Linda G. **Computer vision.** Prentice Hall PTR, 2001.

SZELISKI, Richard. **Computer Vision: Algorithms and Applications.** New York: Springer, 2010.

TETILA, Everton Castelhão; MACHADO, Bruno Brandoli et al. Detection and classification of soybean pests using deep learning with UAV images. **Computers and Electronics in Agriculture**, v. 179, 2020.