

Campinas, SP / Janeiro, 2025

Usando padrões de ondas cerebrais de fitopatologistas para reconhecimento de doenças da soja e do milho

Jayme Garcia Arnal Barbedo⁽¹⁾, Yonatan Meir⁽²⁾⁽¹⁾ Pesquisador, Embrapa Agricultura Digital, Campinas, SP. ⁽²⁾ Pesquisador, InnerEye, Herzliya, Israel.

Introdução

As doenças de plantas impactam significativamente a produtividade agrícola, levando a mais de 14% de perdas globais de culturas, de acordo com a Organização das Nações Unidas para Alimentação e Agricultura (FAO) (FAO, 2021). A detecção eficaz e oportuna dessas doenças é crucial para gerenciar e mitigar seus efeitos deletérios sobre as culturas. No entanto, os métodos tradicionais de detecção de doenças de plantas geralmente dependem de inspeções visuais por especialistas humanos, que são intensivas em mão de obra, lentas e impraticáveis para aplicação em larga escala (Charlton et al., 2019). Métodos laboratoriais, como análises microbiológicas, moleculares ou imunológicas, são igualmente demorados e podem não fornecer respostas imediatas necessárias para intervenções em tempo hábil (Barbedo, 2016).

Avanços recentes em inteligência artificial (IA) e aprendizado profundo mostraram potencial na automação do processo de detecção de doenças de plantas, usando imagens digitais (Chen et al., 2020). Esses modelos usam visão computacional para analisar sintomas visuais em folhas e caules de plantas, classificando e identificando doenças de maneira eficaz. Apesar de seu potencial, a eficácia desses modelos é limitada pela necessidade de grandes quantidades de dados rotulados para treinar os sistemas de IA com acurácia. A rotulagem desses conjuntos de dados é um desafio significativo, pois

requer um esforço manual extenso de especialistas da área, desviando recursos das tarefas principais de reconhecimento de padrões (Barbedo, 2022).

O estudo apresentado aqui é uma extensão do trabalho realizado entre os anos de 2022 e 2023 em parceria com as empresas Macnica DHW e InnerEye. A solução nesse estudo original aproveita padrões de ondas cerebrais de especialistas em fitopatologia usando tecnologia de eletroencefalograma (EEG). Ao capturar e decodificar esses padrões de ondas cerebrais, o estudo visa incorporar o conhecimento especializado diretamente nos modelos de IA, reduzindo assim a necessidade de rotulagem manual demorada e aumentando a robustez e precisão dos sistemas de reconhecimento de doenças de plantas baseados em IA (Netzer; Geva, 2020). A maior parte do método desenvolvido foi descrito em detalhes por Meir et al. (2023).

Este comunicado técnico relata a extensão do método original publicado em Meir et al. (2023), o qual era capaz somente de identificar a presença ou ausência das doenças. Essa nova versão é capaz de diferenciar três doenças da soja e três doenças do milho. Nesse contexto, a metodologia original será descrita de maneira resumida, sendo detalhados apenas os ajustes realizados para preparar o modelo para a identificação das doenças do milho e da soja.

Materiais e métodos

Conjunto de dados da soja

O conjunto de dados para a soja incluiu tanto folhas saudáveis quanto afetadas por ferrugem, oídio e mancha alvo (Figura 1).

Imagem: Cláudia Vieira Godoy

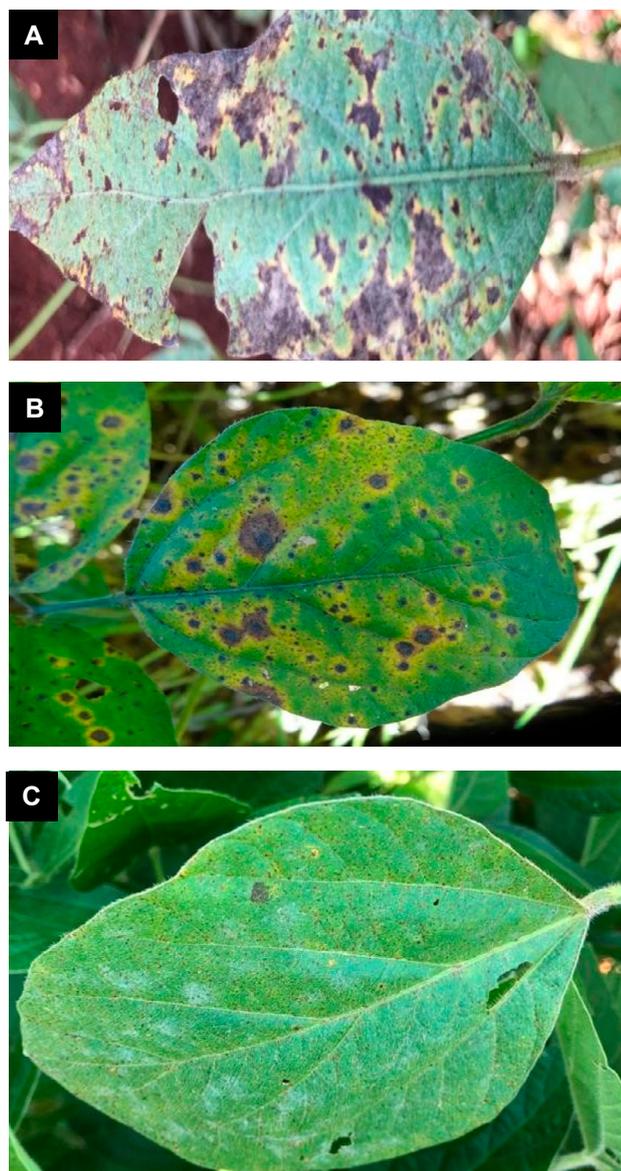


Figura 1. Exemplos de folhas de soja com: (A) ferrugem; (B) oídio; (C) mancha alvo.

Todas as imagens foram capturadas nos campos experimentais da Embrapa Soja, em Londrina (PR). A coleta teve como objetivo cobrir uma ampla gama de variações naturais, como iluminação, sombreamento e diferentes cultivares, para introduzir variabilidade realista nos dados (Barbedo, 2018). Essa abordagem é crucial para garantir que os modelos de IA treinados nesses dados possam generalizar bem para condições do mundo real. As imagens foram capturadas usando um iPhone 7, e sua distribuição é apresentada na Tabela 1.

Conjunto de dados do milho

O conjunto de dados para o milho incluiu tanto folhas saudáveis quanto afetadas por mancha de turcicum, enfezamento e mancha branca (Figura 2).

Imagem: Rodrigo Veras da Costa

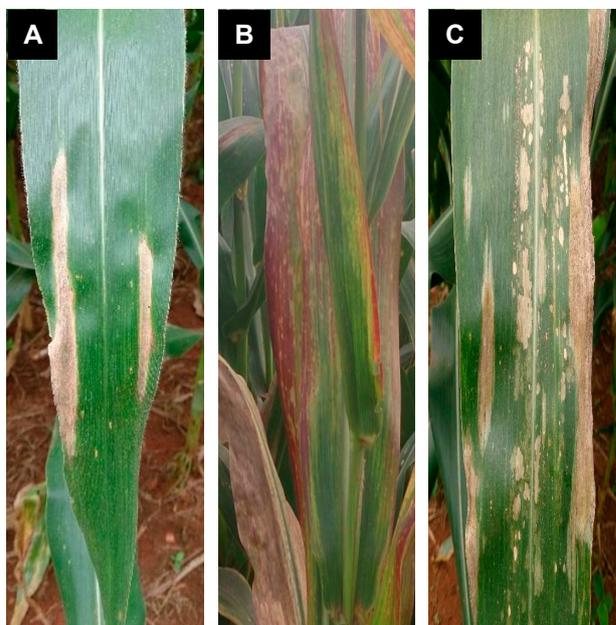


Figura 2. Exemplos de folhas de milho afetadas por: (A) mancha de turcicum; (B) enfezamento; (C) mancha branca.

Todas as imagens foram capturadas nos campos experimentais da Embrapa Milho e Sorgo, em Sete Lagoas (MG). Como no caso da soja, houve a preocupação de cobrir uma ampla gama de variações naturais. As imagens do milho também foram capturadas usando um iPhone 7, e sua distribuição é apresentada na Tabela 2.

Tabela 1. Distribuição do número de imagens de doenças da soja coletadas pelos fitopatologistas.

	Saudável	Oídio	Ferrugem	Mancha Alvo	Total
Treinamento	794	359	701	174	2028
Validação	176	95	194	42	507
Teste	173	82	159	40	454
Total	1143	536	1054	256	2989

Tabela 2. Distribuição do número de imagens de doenças do milho capturadas pelos fitopatologistas.

	Saudável	Mancha Turcicum	Enfezamento	Mancha Branca	Total
Treinamento	65	62	81	157	365
Validação	9	10	33	39	91
Teste	15	14	21	36	86
Total	89	86	135	334	644

Treinamento inicial

Dois modelos principais foram treinados para este estudo: um modelo de IA básico clássico em dados de imagens digitais e um modelo baseado em EEG que utiliza sinais de ondas cerebrais registrados de especialistas durante tarefas de classificação de imagens (Figura 3). O modelo de IA clássico foi construído usando uma rede neural convolucional (CNN) com uma arquitetura ResNet50 pré-treinada no ImageNet, conhecida por sua capacidade de generalização quando aplicada a tarefas baseadas em imagens (Guo et al., 2017). O modelo foi ajustado com várias técnicas de aumento de imagens, como rebatimentos, rotações e recortes, para melhorar sua robustez à variabilidade nas imagens de entrada (Müller et al., 2019).

O modelo baseado em EEG usou dados de ondas cerebrais de especialistas em fitopatologia registrados enquanto visualizavam sequências rápidas de imagens (três imagens por segundo). Os sinais de EEG foram processados para remover ruídos e artefatos, como piscadas, usando Análise de Componentes Independentes (ICA) e filtragem

passa-banda para reter apenas as frequências relevantes (Alpert et al., 2014). Esses dados foram então usados para treinar modelos que podem inferir o nível de confiança do especialista na identificação de doenças de plantas a partir da atividade cerebral.

Tanto os modelos baseados em imagens quanto os baseados em EEG foram implementados usando Python e o framework TensorFlow, treinados em uma máquina com CPU Intel^(R) Core^(TM) i7-7700 @ 3.60GHz, x86_64, 32GB de RAM, GPU GeForce GTX 1080 e sistema operacional OS 20.04.4 LTS.

No trabalho original (Meir et al., 2023), o modelo fornecia uma classificação binária, diferenciando folhas da soja saudáveis e doentes. Nessa extensão do trabalho original, modelos foram treinados para o milho e para a soja em ambos os casos considerando quatro possíveis classificações, saudável e três diferentes doenças, conforme descrito nas seções anteriores. A arquitetura de rede utilizada foi similar, mudando apenas o número de classes potenciais na saída do modelo.

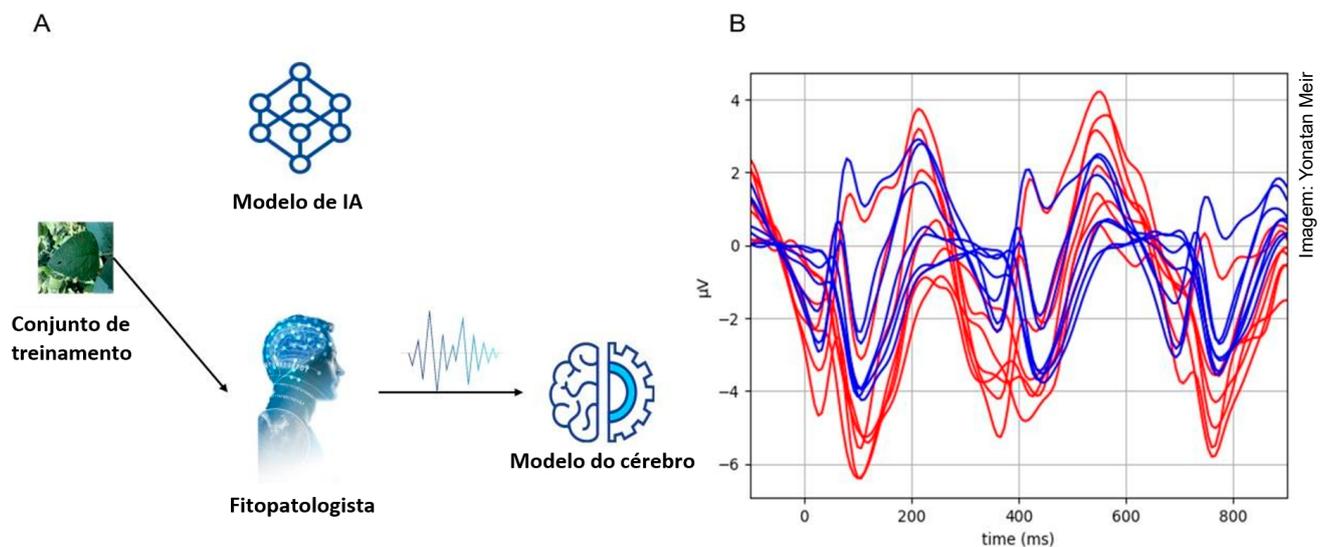


Figura 3. (A) Cada imagem do conjunto de treinamento é usada para treinar tanto o modelo de IA inicial quanto o classificador cerebral de EEG. (B) A resposta cerebral média de um fitopatologista para folhas doentes (vermelho) e folhas saudáveis (azul) nos sete eletrodos do dispositivo de EEG.

Melhorando o modelo de visão computacional com rótulos suaves baseados em EEG

O conceito de rótulos suaves derivados de sinais de EEG é central para este estudo. Ao contrário dos rótulos binários tradicionais que classificam rigidamente as imagens de acordo com as classes adotadas, os rótulos suaves fornecem uma probabilidade que indica a confiança na classificação (Figura 4).

Esses rótulos permitem que o modelo de IA dê pesos diferentes às imagens durante o treinamento, dependendo da pontuação de confiança associada a cada imagem. Esse processo é facilitado por meio de uma estrutura de “humano-no-loop”, onde especialistas fornecem “feedback” em tempo real por meio de seus sinais cerebrais enquanto visualizam as imagens. Essa abordagem não só acelera o processo de rotulagem, mas também aumenta a capacidade do modelo de generalizar para novos dados, incorporando efetivamente a expertise e a incerteza humana nos sistemas de IA (Peterson et al., 2019).

Experimentos

Cinco experimentos distintos foram conduzidos para avaliar a eficácia da abordagem baseada em EEG proposta

- 1) Treinamento do modelo de IA clássico: três diferentes arquiteturas de CNN (ResNet-50, MobileNet, EfficientNet) foram testadas usando um pequeno subconjunto de dados rotulados para simular cenários do mundo real onde os dados muitas vezes são limitados (Müller et al., 2019). O objetivo era estabelecer um *benchmark* de desempenho contra o qual as melhorias baseadas em EEG poderiam ser medidas.
- 2) Treinamento dos modelos de EEG: os dados de EEG coletados de quatro especialistas em fitopatologia foram usados para treinar modelos que capturam os padrões cognitivos únicos associados ao reconhecimento de doenças. Cada modelo foi avaliado usando validação cruzada de cinco dobras (*5-fold cross-validation*) para garantir consistência e confiabilidade em diferentes conjuntos de treinamento e teste (Vaisman, 2024). Os resultados destacaram variações no desempenho do modelo, provavelmente devido a diferenças individuais nos traços cognitivos e na qualidade dos sinais de EEG.
- 3) Integração de modelos de EEG individuais com o modelo de IA: a integração envolveu a incorporação dos rótulos suaves baseados nos EEGs de cada especialista individualmente ao modelo de IA clássico. Esse processo visou quantificar a melhora na acurácia quando os dados de ondas

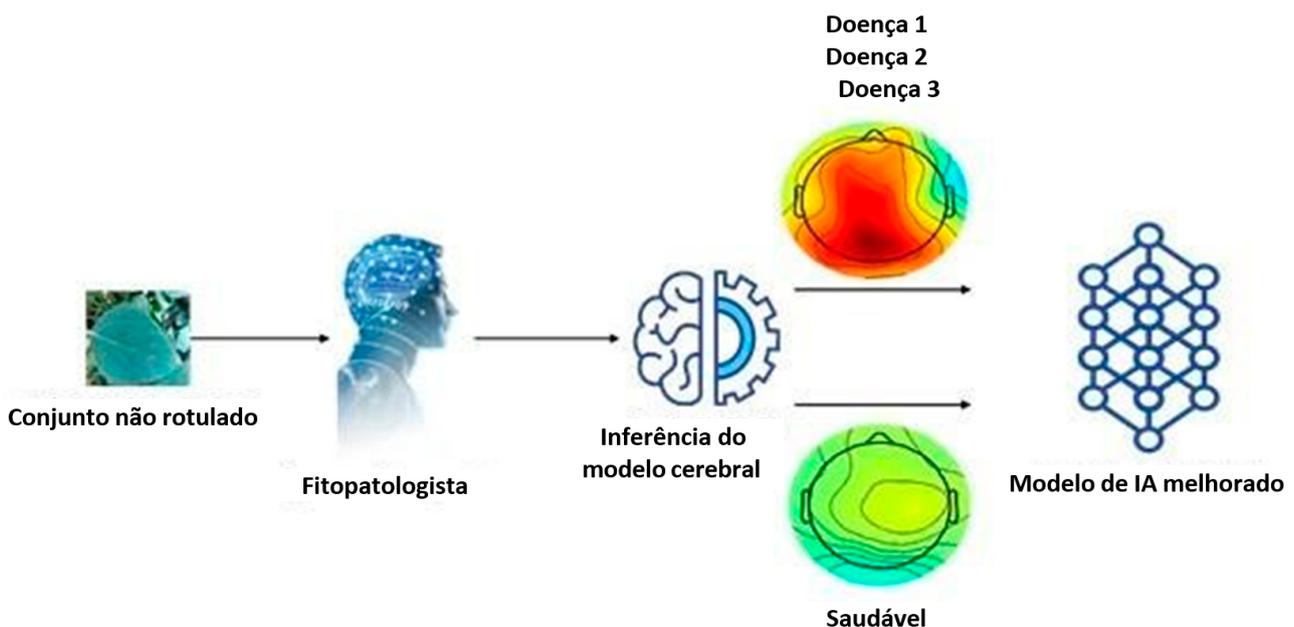


Figura 4. Imagens selecionadas a partir do conjunto não rotulado são apresentadas em rápida sucessão aos fitopatologistas.

cerebrais de especialistas foram incluídos (Alpert et al., 2014).

- 4) Combinação de modelos de EEG de todos os especialistas: os resultados dos modelos de especialistas individuais foram combinados para produzir um modelo único que explorasse o conhecimento coletivo de todos os participantes. Essa abordagem levou a uma melhoria significativa no desempenho do modelo, conforme reportado na próxima seção, indicando a robustez da incorporação de múltiplas perspectivas.
- 5) Aprendizado ativo com abordagem brain-in-the-loop: a estratégia de aprendizado ativo reduziu o número de amostras necessárias para alcançar alta acurácia, selecionando apenas as amostras mais informativas para treinamento adicional. Essa abordagem, combinada com “feedback” em tempo real do EEG, reduziu quase pela metade a quantidade de dados rotulados necessários (de 2000 para 1100 amostras) (Wang et al., 2022; Zhang et al., 2023).

Resultados e discussão

Desempenho do modelo de IA

Nos experimentos originais (classificação binária), o modelo de IA clássico, sem a inclusão dos sinais cerebrais, alcançou uma acurácia de 0,968 no conjunto de teste. Apesar do bom desempenho, certas limitações foram identificadas, particularmente no manejo de sintomas de doenças ambíguas ou leves, que são comuns nos estágios iniciais de infecção (Jiang et al., 2019). O desempenho do modelo reflete os desafios inerentes ao treinamento com pequenos conjuntos de dados limitados, onde a variabilidade em condições como iluminação e fundo pode afetar a precisão.

Desempenho dos modelos de EEG

Nos experimentos originais, quando os modelos baseados em EEG foram utilizados isoladamente, observou-se grande variação nos resultados dependendo do especialista, com acurácias variando entre 0,65 a 0,87 quando aplicados ao conjunto de teste. Acredita-se que essas diferenças resultem de características psicológicas e cognitivas individuais, bem como dos diferentes níveis de conforto dos especialistas com o equipamento de EEG (Alpert et al., 2014). No entanto, o desvio padrão relativamente baixo dos resultados (0,009 a 0,025) sugere

que os classificadores baseados em EEG são estáveis e confiáveis, proporcionando uma base sólida para maior integração com modelos de IA.

Modelos de IA melhorados com integração de EEG

O modelo original, integrando rótulos suaves baseados em EEG com os modelos de IA, resultou em uma melhora significativa no desempenho da classificação. Os modelos combinando os dados de EEG de todos os especialistas alcançaram uma acurácia de 0,995 no conjunto de teste. Esta melhoria ilustra a eficácia dos rótulos suaves em capturar a incerteza e o julgamento sutil dos especialistas, aumentando assim a robustez do modelo e reduzindo o *overfitting* (Peterson et al., 2019; Netzer; Geva, 2020).

A Figura 5 a seguir mostra a matriz de confusão (tabela comparando as previsões do modelo com os valores reais) obtida para o conjunto de imagens da soja no conjunto de teste. A acurácia obtida para o reconhecimento de doenças foi de 0,954, enquanto a acurácia para a diferenciação entre folhas doentes e saudáveis foi de 0,965.

	Saudável	Oídio	Ferrugem	Mancha Alvo
Saudável	167	1	5	0
Oídio	8	71	3	0
Ferrugem	2	0	156	1
Mancha Alvo	0	0	1	39

Imagem: Jayme Garcia Arnal Barbedo

Figura 5. Matriz de confusão mostrando a distribuição dos erros para as imagens da soja. Quanto mais escuras as células, maior o índice de acerto.

Durante o processo de captura, foram também obtidas 97 imagens em que havia a presença simultânea de ferrugem e oídio. Elas não foram consideradas nos experimentos principais, mas foram submetidas ao modelo treinado para verificar como este se comportaria nesses casos.

Na Figura 6, cada ponto corresponde a uma imagem contendo sintomas das duas doenças. O eixo horizontal representa a probabilidade atribuída ao oídio e o eixo vertical a probabilidade atribuída à

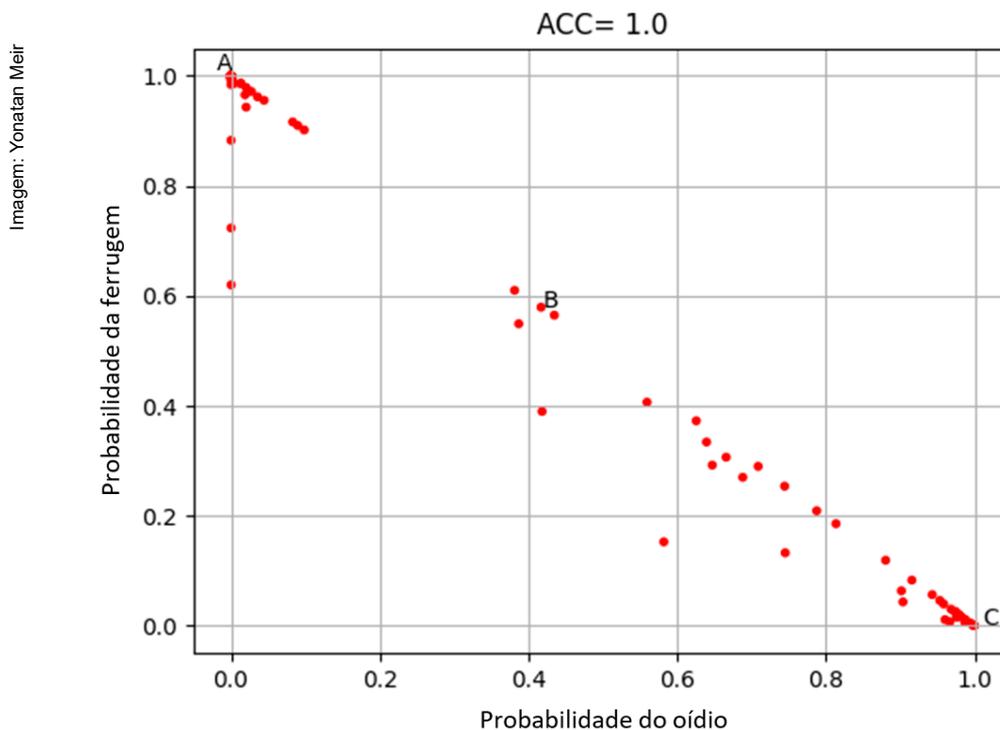


Figura 6. Distribuição de probabilidades para as imagens contendo ferrugem e oídio simultaneamente.

ferrugem. A função de ativação da camada de saída do modelo é do tipo *softmax*, portanto, a soma das probabilidades é sempre 1. Assim, os pontos ao longo da diagonal da figura correspondem aos casos em que o modelo corretamente considera que as folhas analisadas têm probabilidade zero de serem saudáveis ou conterem mancha alvo.

Considerando que foram poucos os casos que se desviaram da diagonal, pode-se afirmar que o modelo poderá eventualmente ser capaz de classificar múltiplas doenças que ocorram simultaneamente. É importante destacar ainda que todas as 97 imagens foram classificadas como ferrugem ou oídio.

A Figura 7 mostra a matriz de confusão obtida para o conjunto de imagens do milho. A acurácia obtida para o reconhecimento de doenças no conjunto de teste foi de 0,930, enquanto a acurácia para a diferenciação entre folhas doentes e saudáveis no conjunto de teste foi de 0,942.

Resultados da abordagem cérebro-no-loop

A abordagem cérebro-no-loop, aprimorada com aprendizado ativo, levou a uma redução de 50% no número de amostras necessárias para treinar modelos acurados. Ao focar nas amostras mais informativas, a abordagem efetivamente reduz pela metade o esforço de rotulagem, mantendo exatamente a

mesma acurácia ao mesmo tempo em que economiza tempo e recursos (Meir et al., 2023).

Considerações finais

A extensão do modelo original, de um classificador binário para um capaz de reconhecer diferentes doenças da soja, foi bem sucedida. Com um total de quase 3 mil imagens, a base de dados utilizada nos experimentos inclui uma ampla gama de condições

Imagem: Jayme Garcia Arnal Barbedo

	Saudável	Mancha Turcicum	Enfezamento	Mancha Branca
Saudável	10	0	0	5
Mancha Turcicum	0	20	0	1
Enfezamento	0	0	36	0
Mancha Branca	0	0	0	14

Figura 7. Matriz de confusão mostrando a distribuição dos erros para as imagens do milho. Quanto mais escuras as células, maior o índice de acerto.

encontradas na prática, o que contribui para uma melhor robustez do modelo. Contudo, o modelo deverá ser continuamente retreinado à medida que novas imagens forem capturadas, a fim de reduzir ao máximo os erros cometidos.

No caso do milho, o primeiro modelo treinado já foi capaz de reconhecer as doenças. Por ter um conjunto de imagens menor (644 amostras), os resultados obtidos são um pouco menos representativos quando comparados aos resultados obtidos para a classificação das doenças em soja, já que uma grande quantidade de condições práticas provavelmente não está representada nesse conjunto de dados. Como no caso da soja, o modelo será continuamente retreinado a fim de melhorar sua robustez e desempenho.

De maneira geral, o estudo demonstrou o potencial de usar rótulos suaves baseados em EEG para melhorar significativamente os modelos de IA para reconhecimento de doenças de plantas. Os resultados sugerem que incorporar o conhecimento de especialistas diretamente através de sinais de EEG pode resolver muitos dos desafios relacionados aos dados que limitam a aplicação prática da IA na agricultura. Pesquisas futuras avaliarão a robustez dos modelos com conjuntos de dados mais diversos e independentes e determinarão o número ideal de especialistas necessários para o treinamento eficiente do modelo.

Um aplicativo para Android foi desenvolvido pela empresa Macnica (parceira do projeto) para realizar o diagnóstico de doenças em campo usando os modelos treinados (tela da versão de setembro de 2024 é mostrada na Figura 8). Esse aplicativo depende de conexão com a internet para fornecer uma resposta, uma vez que os modelos são executados nas instalações da empresa InnerEye (parceira do projeto) em Israel. Porém, caso não haja conectividade, o aplicativo armazena as imagens e as descarrega quando encontra conectividade. O usuário tem a opção de desabilitar o uso da rede 4G/5G, sendo que nesse caso as imagens só são enviadas na presença de uma conexão via wi-fi. Após a captura das imagens, o usuário pode preencher um campo com o problema que ele acredita estar causando os sintomas. Isso visa criar uma nova base de imagens já pré-annotadas para futuro retreinamento do modelo. Testes limitados com produtores vêm sendo realizados, sendo que a versão final está prevista para ser lançada em meados de 2025.

Os modelos treinados até setembro de 2024 ainda consideram um conjunto limitado de doenças, porém o leque de estresses considerados (doenças e outros problemas) deverá crescer à medida em que imagens em quantidade e qualidade suficientes sejam capturadas em campo. Há ainda planos para que o aplicativo faça parte de um sistema maior, no qual outras ferramentas (meteorologia, recomendações de manejo, fluxo de caixa, etc.) estarão presentes.



Imagem: Jayme Garcia Arnal Barbedo

Figura 8. Tela do aplicativo para reconhecimento de doenças em plantas.

Referências

- ALPERT, G. F.; MANOR, R.; SPANIER, A. B.; DEOUELL, L. Y.; GEVA, A. B. Spatiotemporal representations of rapid visual target detection: a single-trial EEG classification algorithm. **IEEE Transactions on Biomedical Engineering**, v. 61, n. 8, p. 2290-2303, 2014. DOI: <https://doi.org/10.1109/tbme.2013.2289898>.
- BARBEDO, J. G. A. A review on the main challenges in automatic plant disease identification based on visible range images. **Biosystems Engineering**, v. 144, p. 52-60, Apr. 2016. DOI: <https://doi.org/10.1016/j.biosystemseng.2016.01.017>.
- BARBEDO, J. G. A. Deep learning applied to plant pathology: the problem of data representativeness. **Tropical Plant Pathology**, v. 47, n. 1, p. 85-94, Feb. 2022. DOI: <https://doi.org/10.1007/s40858-021-00459-9>.
- BARBEDO, J. G. A. Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification. **Computers and Electronics in Agriculture**, v. 153, p. 46-53, Oct. 2018. DOI: <https://doi.org/10.1016/j.compag.2018.08.013>.
- CHARLTON, D.; TAYLOR, J. E.; VOUGIOUKAS, S.; RUTLEDGE, Z. Innovations for a shrinking agricultural workforce. **Choices**, v. 34, n. 1, p. 1-8, 2019. DOI: <https://doi.org/10.22004/ag.econ.288509>.
- CHEN, J.; CHEN, J.; ZHANG, D.; SUN, Y.; NANEHKARAN, Y. Using deep transfer learning for image-based plant disease identification. **Computers and Electronics in Agriculture**, v. 173, 105393, June 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105393>.
- FAO. **Climate change fans spread of pests and threatens plants and crops, new FAO study**. Rome, 2021. Disponível em: <https://www.fao.org/newsroom/detail/Climate-change-fans-spread-of-pests-and-threatens-plants-and-crops-new-FAO-study/en>. Acesso em: 28 mar. 2023.
- GUO, C.; PLEISS, G.; SUN, Y.; WEINBERGER, K. Q. On calibration of modern neural networks. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 34., 2017, Sydney. **Proceedings** [...]. Red Hook: Curran Associates, 2017. p. 1321-1330.
- JIANG, P.; CHEN, Y.; LIU, B.; HE, D.; LIANG, C. Real-time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks. **IEEE Access**, v. 7, p. 59069-59080, 2019. DOI: <https://doi.org/10.1109/ACCESS.2019.2914929>.
- MEIR, Y.; BARBEDO, J. G. A.; KEREN, O.; GODOY, C. V.; AMEDI, N.; SHALOM, Y.; GEVA, A. B. Using brainwave patterns recorded from plant pathology experts to increase the reliability of AI-based plant disease recognition system. **Sensors**, v. 23, n. 9, p. 4272, 2023. DOI: <https://doi.org/10.3390/s23094272>.
- MÜLLER, R.; KORNBLITH, S.; HINTON, G. When does label smoothing help? In: INTERNATIONAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS, 33., 2019, Vancouver. **Proceedings** [...]. Red Hook: Curran Associates, 2019. p. 4694-4703. NeurIPS 2019.
- NETZER, E.; GEVA, A. B. Human-in-the-loop active learning via brain computer interface. **Annals of Mathematics and Artificial Intelligence**, v. 88, p. 1191-1205, 2020. DOI: <https://doi.org/10.1007/s10472-020-09689-0>.
- PETERSON, J. C.; BATTLEDAY, R. M.; GRIFFITHS, T. L.; RUSSAKOVSKY, O. Human uncertainty makes classification more robust. In: INTERNATIONAL CONFERENCE ON COMPUTER VISION, 2019, Seoul. **Proceedings** [...]. Piscataway: IEEE, 2019. p. 9617-9626. DOI: <https://doi.org/10.1109/ICCV.2019.00971>.
- VAISMAN, S. **S9554 - Fast training of deep neural networks using brain-generated labels**. Disponível em: <https://developer.download.nvidia.com/video/gputechconf/gtc/2019/presentation/s9554-fast-training-of-deep-neural-networks-using-brain-generated-labels.pdf>. Acesso em: 13 dez. 2024.
- WANG, F.; WANG, H.; ZHOU, X.; FU, R. A driving fatigue feature detection method based on multifractal theory. **IEEE Sensors Journal**, v. 22, n. 19, p. 19046-19059, 2022. DOI: <https://doi.org/10.1109/JSEN.2022.3201015>.
- ZHANG, X.; HUANG, D.; LI, H.; ZHANG, Y.; XIA, Y.; LIU, J. Self-training maximum classifier discrepancy for EEG emotion recognition. **CAAI Transactions on Intelligence Technology**, v. 8, n. 4, p. 1480-1491, Dec. 2023. DOI: <https://doi.org/10.1049/cit2.12174>.

Embrapa Agricultura Digital

Av. Dr. André Tosello, 209
Cidade Universitária, Campinas, SP
13083-886

www.embrapa.br/agricultura-digital
www.embrapa.br/fale-conosco/sac

Comitê Local de Publicações

Presidente: *Júlio Esquerdo*

Secretária-executiva: *Sônia Ternes*

Membros: *Adauto Mancini, Alan Nakai, Carla Osawa, Geraldo Cançado, Graziella Galinari, Joice Bariani, Juliana Yassitepe, Luiz Cunha, Magda Cruciol e Paula Falcão*

Comunicado Técnico 140

e-ISSN 2764-7412
Janeiro, 2025

Revisão de texto: *Graziella Galinari*

Normalização bibliográfica: *Carla Osawa, CRB-8/10421*

Projeto gráfico: *Leandro Sousa Fazio*

Diagramação: *Magda Cruciol*

Publicação digital: PDF



**Ministério da
Agricultura e Pecuária**

Todos os direitos reservados à Embrapa.