CLASSIFICAÇÃO AUTOMÁTICA DE ALTERAÇÕES FOLIARES POR MEIO DE APRENDIZAGEM DE MÁQUINA EM AMBIENTE MOBILE

Rebeca do Carmo Ganzerla, Jéssica Kimie Dairiki, Bruno Michel Pera

Instituto Educacional Ribeiro Goulart, Rua Isaac Newton, 37, Jardim Oriental, 12236-240, São José dos Campos-SP, Brasil.

rbcaganzerla@gmail.com, jessicakdairiki@gmail.com, brunomichel00@gmail.com

Resumo

Contextualização: alterações visuais em folhas constituem um problema adequado para atividades educacionais de visão computacional e agricultura digital. Objetivo: desenvolver o EcoPlant, protótipo móvel capaz de receber uma fotografia de folha e apresentar a classe prevista e a pontuação de confiança. Metodologia: o aplicativo foi desenvolvido no MIT App Inventor e integrado a um classificador de imagens treinado por exemplos no Google Teachable Machine, organizado em três classes — folha saudável, ferrugem e mancha foliar — com regra heurística de interface que considera incertos os resultados inferiores a 60%. Resultados: foram implementados o carregamento do modelo, a seleção de imagem, a pré-visualização e o fluxo de solicitação da classificação; entretanto, a documentação experimental disponível não registra um conjunto de teste independente nem o quantitativo e a procedência completa das imagens, o que impede relatar acurácia, precisão, revocação e F1-Score de forma cientificamente válida. Discussão: essa limitação reforça a necessidade de separar a demonstração tecnológica da validação do classificador, sobretudo porque modelos de visão computacional podem perder desempenho fora das condições de treinamento. Conclusão: o EcoPlant demonstra viabilidade como recurso educacional e prova de conceito para aprendizagem de máquina em ambiente mobile, sem pretensão de diagnóstico agronômico.

Palavras-chave: Agricultura digital. Aprendizagem de máquina. Visão computacional. Aplicativos móveis.

Área do Conhecimento: Ciências Exatas e da Terra - Ciência da Computação.

Introdução

A observação de folhas é uma estratégia recorrente para reconhecer alterações de cor, manchas, deformações e outros sinais associados ao estado da planta. Em sistemas computacionais, essas características podem ser tratadas como padrões visuais, permitindo a construção de classificadores para apoio à agricultura digital. Revisões recentes mostram, contudo, que a utilidade desses sistemas depende da qualidade dos dados e da capacidade de generalizar para imagens obtidas fora de condições controladas (Salka et al., 2025; Sumith; Rashmi, 2026).

O uso de redes neurais profundas tornou a classificação de doenças foliares tecnicamente viável, inclusive em dispositivos com recursos limitados. Estudos clássicos já demonstravam o potencial de redes neurais para esse domínio, mas também registravam queda de desempenho quando o cenário de teste diferia do treinamento; trabalhos recentes com arquiteturas leves reforçam a importância de modelos eficientes e de validação em condições próximas ao uso real (Mohanty; Hughes; Salathé, 2016; Karim et al., 2024).

A programação visual pode reduzir a barreira técnica para projetos educacionais de inteligência artificial. O Teachable Machine foi concebido como ferramenta web acessível para criação de modelos de classificação, enquanto o MIT App Inventor disponibiliza recursos para aprendizagem de máquina e classificação de imagens em aplicativos móveis, incluindo a apresentação de níveis de confiança ao usuário (Carney et al., 2020; Google, s.d.; MIT App Inventor, 2026a; 2026b).

Com base nesse contexto, este trabalho teve como objetivo desenvolver o EcoPlant, um protótipo educacional para fotografar ou selecionar uma imagem de folha, encaminhá-la a um classificador previamente treinado e apresentar a classe prevista com sua confiança. A proposta prioriza a compreensão do fluxo de aprendizagem de máquina e a comunicação de incerteza, sem equiparar a saída do classificador a um diagnóstico agronômico (Carney et al., 2020; Salka et al., 2025).

Metodologia

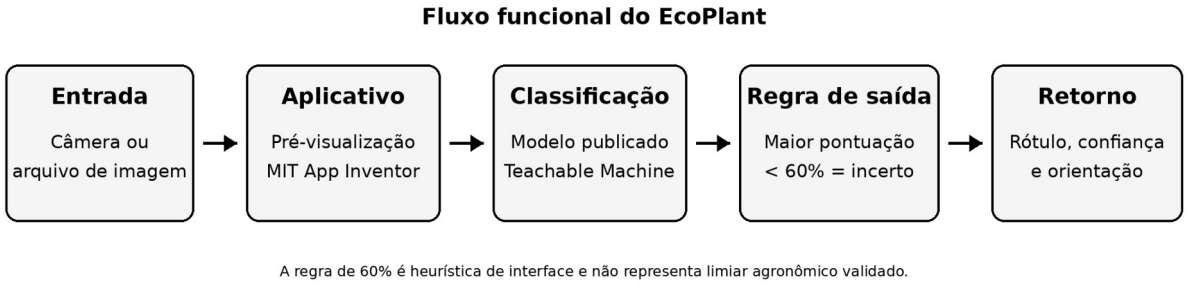
O estudo foi conduzido como desenvolvimento tecnológico de caráter aplicado, organizado em quatro etapas: definição do escopo, preparação do acervo de imagens, treinamento do classificador e

integração ao aplicativo. Foram definidas três categorias de saída — folha saudável, ferrugem e mancha foliar — e a técnica empregada corresponde à classificação multiclasse supervisionada de imagens, operacionalizada por um classificador treinado por exemplos e publicado no Google Teachable Machine. O projeto utilizou a ferramenta como serviço de treinamento e inferência, sem implementar manualmente uma arquitetura de rede neural do zero (Carney et al., 2020; Google, s.d.).

As imagens foram preparadas considerando uma folha por fotografia e variações de ângulo, distância, iluminação, fundo e intensidade dos sintomas. A documentação original do projeto, entretanto, não registra de modo rastreável a fonte, o número total de imagens nem a distribuição por classe. Por essa razão, o acervo desta versão deve ser entendido como material de prototipagem e não como base experimental validada. Essa limitação é relevante, pois a literatura mostra que bases pouco diversas ou excessivamente controladas favorecem avaliações otimistas e menor generalização (Mohanty; Hughes; Salathé, 2016; Sumith; Rashmi, 2026).

No aplicativo, desenvolvido no MIT App Inventor, o modelo publicado é carregado em um componente WebViewer. O usuário seleciona ou fotografa uma folha, confere a pré-visualização e aciona a análise. A interface foi configurada para exibir o rótulo de maior pontuação e a confiança correspondente. Como regra de comunicação, valores inferiores a 60% são tratados como incertos, acompanhados da recomendação de repetir a captura em melhores condições; esse limite é apenas heurístico e não representa um critério agronômico validado (MIT App Inventor, 2026a; 2026b).

Figura 1 - Arquitetura e sequência do fluxo de funcionamento do EcoPlant.



Fonte: elaborado pelos autores (2026).

Para uma avaliação quantitativa do classificador, seria necessário manter um conjunto de teste independente, registrar a classe verdadeira e a classe prevista de cada imagem e calcular, no mínimo, acurácia, precisão, revocação e F1-Score. Como o material disponibilizado para este artigo não contém esses registros, não foram produzidos valores numéricos artificiais; a avaliação apresentada limita-se à validação funcional da integração entre interface e modelo (Salka et al., 2025).

Resultados

O desenvolvimento resultou em uma interface móvel com indicação do estado de carregamento do modelo, campo de configuração, comando para obter a fotografia, pré-visualização e área destinada ao retorno da classificação. O protótipo também inclui ações para limpar a entrada e recarregar o analisador. A captura disponível no material do projeto, apresentada na Figura 2, registra o aplicativo em dispositivo Android antes da execução de uma classificação completa.

Figura 2 - Tela do EcoPlant em dispositivo Android, no estado anterior à classificação.



Fonte: elaborado pelos autores (2026).

A Tabela 1 sintetiza os componentes efetivamente implementados no protótipo. Diferentemente da versão anterior, a tabela é apresentada nesta seção por representar uma entrega do desenvolvimento e foi ajustada para não ultrapassar as margens nem utilizar linhas verticais.

Tabela 1 - Componentes e funções do protótipo.

Componente	Implementação	Função
Entrada	Câmera ou seletor de imagem	Obter a fotografia da folha
Visualização	Componente Image	Exibir a imagem escolhida
Classificação	Modelo publicado no WebViewer	Retornar rótulo e confiança
Controle	Botões analisar, limpar e recarregar	Organizar o fluxo de uso
Saída	Rótulos de resultado e confiança	Comunicar a previsão ao usuário

Fonte: elaborado pelos autores (2026).

Quanto ao desempenho do modelo de inteligência artificial, não há no material-base uma matriz de confusão nem contagens de verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos que permitam calcular métricas confiáveis. Assim, acurácia, precisão, revocação e F1-Score permanecem não determinados nesta versão. Esse resultado deve ser interpretado como evidência de implementação do fluxo tecnológico, e não como comprovação de desempenho diagnóstico.

Esse cuidado é coerente com estudos recentes, que relatam alto desempenho de modelos de classificação foliar em bases controladas, mas ressaltam que a implantação prática exige diversidade de dados, validação independente e análise das condições de captura. Modelos leves voltados a dispositivos de borda também mostram que desempenho, latência e robustez precisam ser avaliados conjuntamente antes do uso em campo (Karim et al., 2024; Salka et al., 2025; Sumith; Rashmi, 2026).

Discussão

O principal mérito do EcoPlant está na integração de programação móvel, aquisição de imagens e aprendizagem de máquina em uma solução compreensível para estudantes. A classificação treinada por exemplos favorece a discussão de conceitos como classes, amostras, confiança e erro de previsão; ao mesmo tempo, evidencia que o modelo aprende regularidades estatísticas presentes no conjunto de treinamento e não realiza diagnóstico agronômico por conhecimento causal (Carney et al., 2020; Salka et al., 2025).

A literatura mostra que imagens obtidas em cenários controlados podem produzir resultados elevados sem garantir o mesmo comportamento em condições reais. Variações de fundo, iluminação, enquadramento, resolução e domínio de aquisição continuam sendo desafios centrais em sistemas de detecção de doenças de plantas, o que reforça a necessidade de um conjunto de teste independente e de fotografias representativas do ambiente de uso (Mohanty; Hughes; Salathé, 2016; Ferentinos, 2018; Sumith; Rashmi, 2026).

A confiança exibida pela interface deve ser entendida como pontuação produzida pelo classificador, e não como probabilidade clínica ou agronômica de doença. A regra de 60% adotada no protótipo tem finalidade comunicacional e precisa ser validada em estudos futuros. Trabalhos com modelos leves em dispositivos de borda demonstram que a implantação móvel é viável, mas depende de avaliação objetiva de precisão e robustez antes de orientar decisões de campo (Karim et al., 2024).

Como evolução de engenharia, o aplicativo poderá registrar histórico de análises e permitir atualização centralizada do modelo. Tais extensões não foram avaliadas neste estudo e, portanto, não são apresentadas como ganho comprovado de desempenho. Para o escopo atual, o impacto mais relevante é educacional: ferramentas de programação visual e classificação acessível podem aproximar estudantes de conceitos de inteligência artificial e agricultura digital por meio da construção de protótipos concretos (Carney et al., 2020; MIT App Inventor, 2026a).

Conclusão

O EcoPlant demonstrou a viabilidade de integrar um aplicativo móvel a um classificador de imagens treinado por exemplos para explorar alterações foliares em contexto educacional. A principal contribuição do trabalho não está em afirmar capacidade diagnóstica, mas em oferecer uma prova de conceito que torna visíveis etapas essenciais de um sistema de inteligência artificial — aquisição da imagem, classificação, apresentação da confiança e tratamento de incerteza — contribuindo para a aproximação entre ensino de computação e agricultura digital.

A ausência de rastreabilidade completa do acervo e de um conjunto de teste independente impede concluir sobre acurácia ou eficácia agronômica. Como continuidade da pesquisa, recomenda-se documentar a origem e a quantidade de imagens, realizar divisão formal entre treinamento e teste e avaliar o modelo com acurácia, precisão, revocação e F1-Score em condições variadas de captura. A partir dessa validação, será possível determinar com maior segurança o potencial do EcoPlant para aplicações além do uso didático.

Referências

CARNEY, M. et al. **Teachable Machine: Approachable Web-Based Tool for Exploring Machine Learning Classification.** Extended Abstracts of the 2020 CHI Conference on Human Factors in Computing Systems, p. 1-8, 2020. DOI: 10.1145/3334480.3382839.

FERENTINOS, K. P. **Deep learning models for plant disease detection and diagnosis.** Computers and Electronics in Agriculture, v. 145, p. 311-318, 2018. DOI: 10.1016/j.compag.2018.01.009.

GOOGLE. Teachable Machine. [s.d.]. Disponível em: https://teachablemachine.withgoogle.com/. Acesso em: 13 ago. 2026.

KARIM, M. J. et al. **Enhancing agriculture through real-time grape leaf disease classification via an edge device with a lightweight CNN architecture and Grad-CAM.** Scientific Reports, v. 14, art. 16022, 2024. DOI: 10.1038/s41598-024-66989-9.

MIT APP INVENTOR. **Personal Image Classifier: Part 1.** Cambridge: Massachusetts Institute of Technology, 2026a. Disponível em: https://appinventor.mit.edu/explore/resources/ai/personal-image-classifier-part1. Acesso em: 13 ago. 2026.

MIT APP INVENTOR. **Introduction to Machine Learning: Image Classification.** Cambridge: Massachusetts Institute of Technology, 2026b. Disponível em: https://appinventor.mit.edu/explore/resources/ai/image-classification-look-extension. Acesso em: 13 ago. 2026.

MOHANTY, S. P.; HUGHES, D. P.; SALATHÉ, M. **Using deep learning for image-based plant disease detection.** Frontiers in Plant Science, v. 7, art. 1419, 2016. DOI: 10.3389/fpls.2016.01419.

SALKA, T. D. et al. **Plant leaf disease detection and classification using convolution neural networks model: a review.** Artificial Intelligence Review, v. 58, art. 322, 2025. DOI: 10.1007/s10462-025-11234-6.

SUMITH, N.; RASHMI, M. **A systematic review of deep learning and super resolution techniques for leaf level and canopy level plant disease detection.** Discover Artificial Intelligence, v. 6, art. 316, 2026. DOI: 10.1007/s44163-026-00973-2.