

AGROWISE: Aplicação Móvel para Recomendação de Cultivos Agrícolas Baseado em Aprendizado de Máquina

Ismael Vieira Guedes¹, Felipe Gonçalves dos Santos¹, Thiago Reis da Silva²

¹Instituto Federal de Educação, Ciência e Tecnologia do Piauí (IFPI) – Campus Corrente, PI – Brasil

²Instituto Federal de Educação, Ciência e Tecnologia do Maranhão (IFMA) – Campus São João dos Patos, MA – Brasil

ismael.basic@gmail.com; felipe.santos@ifpi.edu.br;
thiago.reis@ifma.edu.br

Abstract. Agriculture faces challenges such as unpredictable climatic factors and crop diseases. The implementation of technological innovations, such as Machine Learning, has increased crop yield and quality. This branch of Artificial Intelligence is applied in precision agriculture, which uses large volumes of data to identify soil patterns, revolutionizing cultivation cycles. Integrating machine learning into agriculture can improve results and reduce risks. This paper proposes a mobile application for crop recommendation, using a machine learning model trained with data on temperature, humidity, pH, and soil information.

Resumo. A agricultura enfrenta desafios como fatores climáticos imprevisíveis e doenças nas colheitas. A implementação de inovações tecnológicas, como o Aprendizado de Máquina, tem aumentado o rendimento e a qualidade das colheitas. Esse ramo da Inteligência Artificial é aplicado na agricultura de precisão, que usa grandes volumes de dados para identificar padrões no solo, revolucionando os ciclos de cultivo. Integrar o aprendizado de máquina na agricultura pode melhorar os resultados e reduzir riscos. Este trabalho propõe uma aplicação móvel para recomendação de cultivos, utilizando um modelo de aprendizado de máquina treinado com dados de temperatura, umidade, pH e informações do solo.

1. Introdução

A agricultura desempenha um papel crucial no fornecimento de alimentos para o crescimento da população mundial. No entanto, esse setor vital enfrenta uma série de desafios que impactam diretamente a produção agrícola (ONU, 2021). Entre eles, destacam-se fatores climáticos imprevisíveis e a propagação de doenças e pragas que afetam as colheitas.

A implementação de inovações tecnológicas na agricultura trouxe avanços no aumento do rendimento e da qualidade das colheitas, para atender à demanda global por alimentos. A busca por novas tecnologias como conservação de sementes, melhoramento seletivo e genética por mutação, impulsionaram significativamente a produção agrícola (Hamdan *et al.*, 2022). Nesse sentido, uma nova tecnologia emergente, o aprendizado de máquina, vem revolucionando outras áreas como saúde, segurança, educação e pode contribuir para a agricultura.

Conforme Dhankar e Gupta (2021), o aprendizado de máquina, um dos ramos da inteligência artificial, tem possibilitado a criação de ferramentas na descoberta de prevenção de doenças, na pesquisa e desenvolvimento de medicamentos para a saúde, além de contribuir para a criação de mecanismos de autenticação e protocolos essenciais para a cibersegurança.

Outra importante utilização do aprendizado de máquina é a agricultura de precisão, que vem abrindo novos caminhos na agricultura (Van Klompenburg, Kassahun e Catal, 2020), fornecendo capacidade de processar grandes volumes de dados e identificar padrões em parâmetros do solo que estão revolucionando a maneira como entendemos e prevemos os ciclos de cultivos. Com isso, o desenvolvimento de ferramentas de plantio inteligentes são fundamentais para o desenvolvimento agrícola. E este por sua vez contribui para acabar com a pobreza extrema e alimentar cerca de 10 bilhões de pessoas até 2050 (The World Bank, 2023). Assim sendo, a integração do aprendizado de máquina na agricultura pode trazer melhores resultados e menores riscos à produção e ao agricultor.

A mesclagem dessa tecnologia por meio de uma aplicação móvel representa um avanço na acessibilidade e usabilidade para agricultores que podem ter acesso instantâneo à nova tecnologia. Assim, auxiliando na tomada de decisões importantes de maneira eficiente, rápida e otimizada para processos agrícolas. Dessa forma, oferecer uma ferramenta prática é fundamental para pequenos, médios e grandes agricultores. Outrossim, disponibilizar o acesso a novas tecnologias de aprendizado de máquina pode influenciar positivamente toda a comunidade agrícola, e reduzir os impactos negativos ambientais e financeiros de uma região.

Portanto, o trabalho propõe uma aplicação para recomendação de culturas. A aplicação utiliza um modelo de aprendizado de máquina treinado com uma base de dados formada por parâmetros de temperatura, umidade, potencial hidrogeniônico (pH) e informações do solo. Ademais, a aplicação foi desenvolvida utilizando o *framework* Flutter. Assim como, foi desenvolvido uma *Application Programming Interface* (API), em Django e Django Rest Framework, para alimentar a aplicação que deseje utilizar o modelo em outros sistemas.

Neste contexto, o restante deste artigo está organizado da seguinte forma. A Seção 2 discute sobre aplicações móveis. Em seguida, a Seção 3 apresenta os trabalhos relacionados. Já a Seção 4 apresenta o AGROWISE, destacando a arquitetura, as tecnologias utilizadas, a base de dados e a biblioteca python Scikit-Learn. Os principais resultados são discutidos em mais detalhes na Seção 5. Por fim, na Seção 6 são apresentadas as considerações finais e perspectivas de trabalhos futuros.

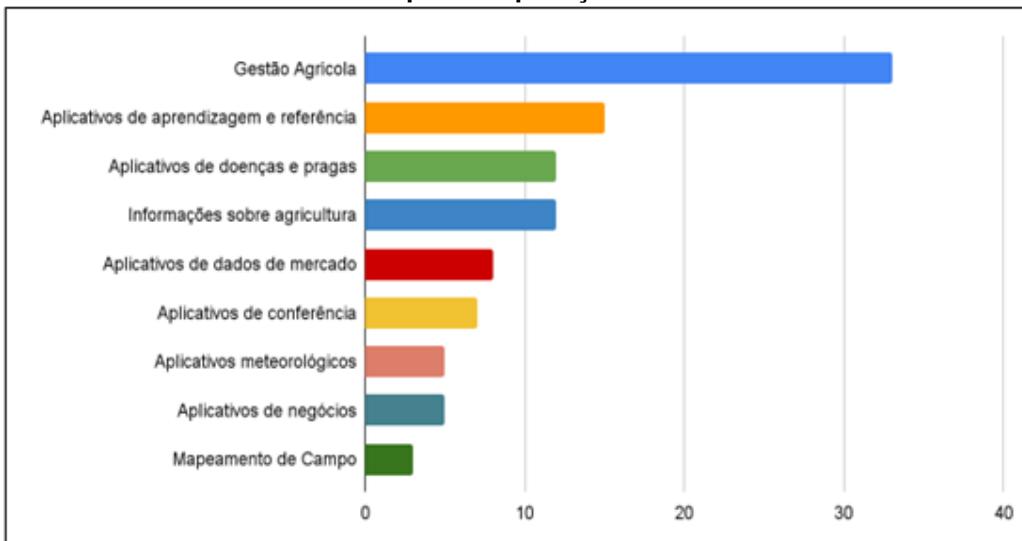
2. Aplicações Móveis

As aplicações móveis são ferramentas que disponibilizam serviços e recursos de forma simplificada para smartphones. Por exemplo, permitem o acesso a uma variedade de serviços da internet, incluindo mensagens instantâneas, comércio eletrônico e pagamentos online (Li *et al.*, 2022). Além disso, houve uma expansão no número de smartphones em todo o mundo, o que contribuiu para a disponibilização de serviços em áreas de difícil acesso, como as zonas rurais.

No Brasil, entre 2006 e 2017, houve um aumento no número de estabelecimentos agropecuários com acesso a smartphones, que passou de 1,2 milhões para 3,1 milhões,

representando um crescimento de 158% (IBGE, 2017). Em virtude dessa ampla distribuição de smartphones, os agricultores agora podem aproveitar recursos que antes estavam fora de seu alcance (Shah *et al.*, 2021). O Gráfico 1 ilustra os diferentes domínios da agricultura em que essas aplicações estão sendo utilizadas, apresentando as categorias de aplicativos mais relevantes. A categoria “Gestão Agrícola” é a mais popular, seguida pelos “Aplicativos de Aprendizagem e Referência”.

Gráfico 1: Tipos de aplicações existentes.



Fonte: Adaptado de SHAH et al. (2021).

3. Trabalhos Relacionados

Esta seção tem como objetivo apresentar e discutir trabalhos relacionados à presente proposta. Foram identificados cinco estudos que abordam temas semelhantes, especialmente no contexto da agricultura, utilizando modelos ou plataformas comparáveis. Os estudos selecionados são: Raheem, Hussain e Ahmed (2023); Narayana e Sexena (2023); Sri *et al.* (2023); Shah *et al.* (2021); e Prevelato (2023).

O estudo realizado por Raheem, Hussain e Ahmed (2023) buscou recomendar cultivos para agricultores usando aprendizado de máquina e parâmetros do solo, visando aumentar a produtividade e reduzir a quebra de safra. Usando técnicas de limpeza de dados e algoritmos como Floresta Aleatória e XGBoost, alcançou-se uma precisão de 98,9% e 98,2%, respectivamente, em prever culturas baseadas em fatores do solo e clima. Esses resultados destacam o potencial da tecnologia para recomendações precisas de cultivos agrícolas.

Em contrapartida, o estudo de Narayana e Saxena (2023) integra modelos em um aplicativo web via Flask, oferecendo recomendações de culturas e detecção de doenças. O modelo Naive Bayes obteve uma precisão de 99,71%, seguido pela Floresta Aleatória com 99,80%, enquanto a Árvore de Decisão teve 60%. Esses resultados destacam a eficácia do Naive Bayes e da Floresta Aleatória na previsão de safras em comparação com a Árvore de Decisão.

O estudo de Sri *et al.* (2023) buscou aprimorar a produtividade agrícola por meio de um modelo de aprendizado de máquina integrando dados climáticos e históricos. Utilizando algoritmos como Máquinas de Vetor de Suporte, K-vizinhos mais próximos e Floresta Aleatória, o modelo alcançou precisão de 92% na previsão do rendimento da

safra, 96% na identificação de doenças e 94% na recomendação de fertilizantes, destacando o potencial do aprendizado de máquina na agricultura.

Os autores Shah *et al.* (2021), propuseram o desenvolvimento de um aplicativo para oferecer suporte tecnológico aos agricultores, utilizando um modelo de aprendizado profundo para detectar mais de 39 doenças em plantações. Por meio de redes neurais convolucionais, o sistema alcançou uma média de 85% de precisão na detecção de doenças, utilizando um conjunto de dados com mais de 5.000 instâncias rotuladas. Essa solução proporciona aos agricultores maior controle sobre suas plantações, fornecendo informações para melhorar a produção agrícola.

A pesquisa realizada por Prevelato (2023) teve como objetivo criar um sistema de recomendação de plantio com base em algoritmos de Aprendizado de Máquina, utilizando dados públicos de plantio. Foram aplicados métodos como Árvore de Decisão, Floresta Aleatória, K-Vizinhos mais próximos, Máquina de Vetores de Suporte e Naive Bayes, resultando em modelos com uma acurácia superior a 99%. Os modelos de Floresta Aleatória e Gaussian Naive-Bayes se destacaram, sendo este último ligeiramente superior em métricas. Optou-se pelo modelo de Floresta Aleatória devido à sua robustez contra *outliers*, apesar do tempo de criação ser maior.

4. AGROWISE

A metodologia utilizada nesta pesquisa foi composta por seis etapas distintas: pesquisa exploratória, definição da arquitetura, seleção de uma base de dados, treinamento do modelo, desenvolvimento do sistema web e a aplicação móvel. Ao seguir e executar essa metodologia, o objetivo deste trabalho foi desenvolver uma aplicação móvel denominada Agrowise.

O Agrowise é um aplicativo de recomendação de cultivos que utiliza um modelo de aprendizado de máquina para fazer suas previsões. Ademais, o usuário precisa fornecer dados do solo, como os níveis de nitrogênio, potássio, fósforo, temperatura, umidade, potencial hidrogeniônico e índice pluviométrico. Com essas informações, o aplicativo gera previsões com a probabilidade de acerto de cada cultivo, dependendo dos dados fornecidos. Além disso, a aplicação oferece recursos, como a capacidade de gerar relatórios para cada previsão, permitindo também que o usuário compartilhe o arquivo gerado obtendo dados relevantes.

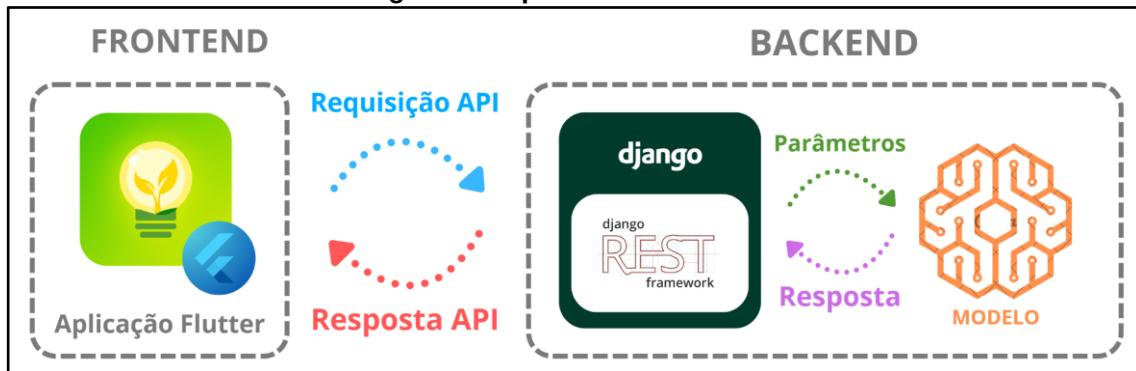
O aplicativo foi desenvolvido com o objetivo de ser o mais intuitivo, fácil, direto e rápido possível. Com apenas alguns cliques, o usuário pode acessar os recursos disponíveis sem a necessidade de criar uma conta. A seguir, serão detalhadas as etapas de desenvolvimento do aplicativo, incluindo sua arquitetura, as tecnologias utilizadas, o modelo de aprendizado de máquina implementado, bem como as interfaces e funcionalidades disponíveis para o usuário.

4.1 Arquitetura

Durante a fase de elaboração da arquitetura, identificou-se que a abordagem mais adequada seria uma estrutura em que o cliente, por meio da aplicação, utilizasse os recursos fornecidos por um servidor. Para isso, o usuário deve realizar uma solicitação, enviando os dados necessários, para que o servidor processe essas informações e retorne as recomendações. O aplicativo, desenvolvido utilizando o *framework* Flutter, atua como cliente, enviando solicitações a um servidor que utiliza uma API construída com o Django *Rest Framework*. Em seguida, o servidor retorna os resultados das recomendações para o

aplicativo. A estrutura pode ser visualizada na Figura 1.

Figura 1: Arquitetura do sistema.



Fonte: Próprio Autor (2024).

4.2 Tecnologias Utilizadas

Nesta subseção, são detalhados as tecnologias utilizadas e os motivos de sua escolha. O Python foi selecionado por ser uma linguagem de alto nível, reconhecida por sua sintaxe simplificada e legibilidade (Cruz, 2015). Devido a essas características, Python foi escolhido como a linguagem principal para o servidor, sendo utilizada tanto para o treinamento do modelo quanto para a construção da API.

4.3 Base de Dados

Os dados utilizados foram obtidos de uma fonte acadêmica indiana disponível na plataforma Kaggle, contendo informações sobre cultivos na Índia (Ingle, 2020). A base de dados abrange 22 culturas: arroz, milho, grão-de-bico, feijão, feijão-bóer, feijão-traça, feijão-mungo, feijão-preto, lentilha, romã, banana, manga, uvas, melancia, melão-alfazema, maçã, laranja, mamão, coco, algodão, juta e café. Os parâmetros considerados incluem características do solo, como nitrogênio, fósforo, potássio, temperatura, umidade, potencial hidrogeniônico (pH) e pluviosidade.

4.4 Scikit-Learn

A primeira etapa no desenvolvimento do aplicativo foi a criação do modelo, que deve ser treinado utilizando metodologias e tecnologias que apresentem o melhor desempenho. O Scikit-Learn é uma biblioteca em Python que oferece ferramentas simples e eficientes para a análise preditiva de dados. Construída sobre as bibliotecas NumPy, SciPy e Matplotlib, ela é acessível a todos e reutilizável em diversos contextos (Pedregosa *et al.*, 2011). Nesse sentido, foram aplicadas técnicas e ferramentas para o treinamento do modelo de aprendizado de máquina definido por Prevelato (2023).

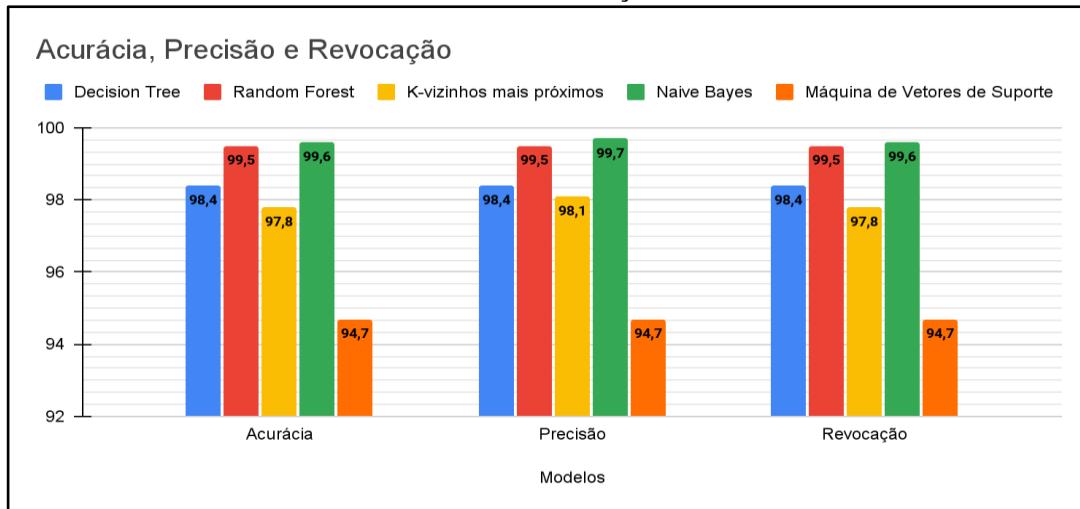
Segundo indicado por Prevelato (2023), para treinar um modelo, é necessário definir, preparar e separar os dados de treinamento e de teste. Em seguida, realizar testes com os modelos utilizando métricas úteis, a fim de obter o modelo mais adequado e com os melhores resultados. Os modelos escolhidos com base no artigo de referência foram Árvore de Decisão, Floresta Aleatória, K-vizinhos mais próximos (KNN), Máquina de Vetores de Suporte (MVS) e Naive-Bayes, especificamente o Gaussian Naive-Bayes.

Gaurav, Chitra e Munish (2022) define as métricas de acurácia, precisão e revocação. A acurácia avalia a proporção de previsões corretas em relação a todas as previsões feitas. Embora seja uma medida comumente utilizada, pode não ser apropriada

em casos de desequilíbrio significativo entre as classes ou quando os custos associados a falsos positivos e falsos negativos são diferentes. A precisão quantifica a proporção de previsões positivas verdadeiras em relação a todas as previsões positivas, enquanto a revocação avalia a proporção de previsões positivas verdadeiras em relação a todas as instâncias positivas reais. A precisão é crítica quando o custo dos falsos positivos é elevado, enquanto a revocação é indispensável quando o custo dos falsos negativos é significativo. Em muitos cenários, essas métricas oferecem informações mais esclarecedoras em comparação com a acurácia.

No Gráfico 2, os resultados de cada um dos cinco modelos são apresentados de forma detalhada, agrupados pela métrica que está sendo avaliada. A análise desses resultados fundamenta a escolha final do modelo mais adequado às necessidades específicas do projeto.

Gráfico 2: Métricas de avaliação dos modelos.



Fonte: Próprio Autor (2024).

As pontuações altas indicam que os cinco modelos são capazes de realizar previsões ou classificações corretas na maioria dos casos, independentemente da métrica utilizada. No entanto, Naive Bayes e Floresta Aleatória se destacam, apresentando as maiores pontuações em todas as métricas. Esses dois modelos demonstram ser mais robustos e confiáveis em comparação aos demais.

Enquanto Naive Bayes é elogiado por sua simplicidade e rapidez, a Floresta Aleatória se destaca por sua flexibilidade e precisão. Embora o modelo baseado em Naive Bayes apresente métricas ligeiramente superiores às do modelo de Floresta Aleatória, ambos alcançam pontuações superiores a 99%. Entretanto, um ponto falho do modelo Gaussian Naive-Bayes é sua suposição de independência entre os atributos, o que pode limitar sua capacidade de interpretar relacionamentos entre os atributos em novas amostras, conforme observado por Prevelato (2023).

A escolha do modelo de Floresta Aleatória é justificada por sua pontuação superior em comparação aos outros modelos e por sua ampla aplicação em trabalhos semelhantes. Portanto, optar por esse modelo é a decisão mais adequada para alcançar os objetivos do projeto.

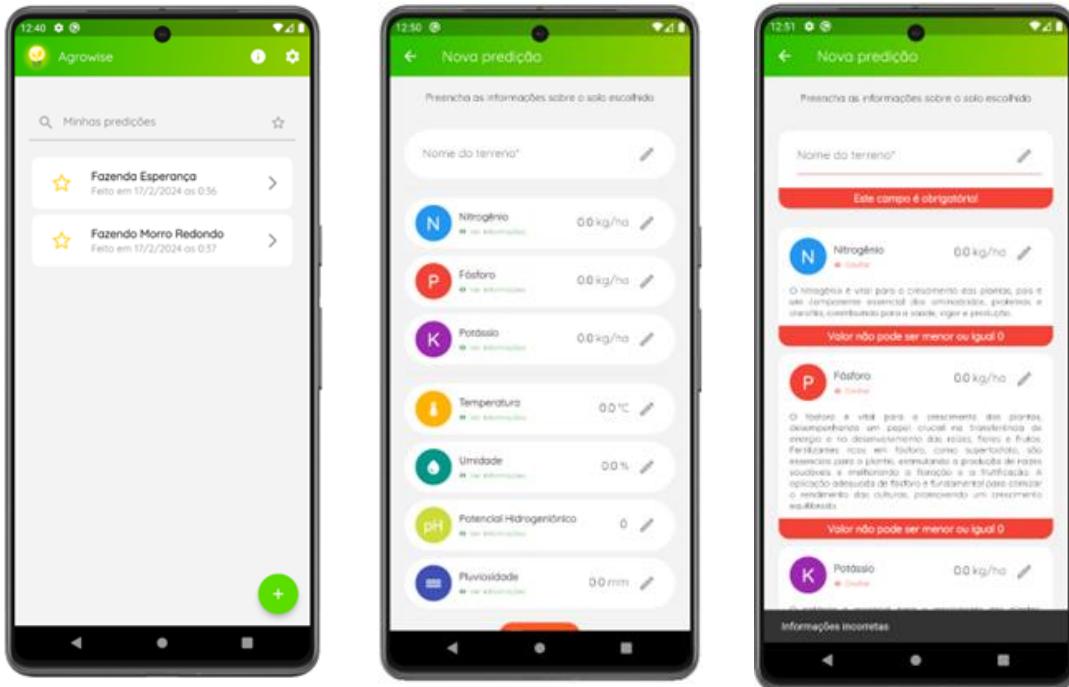
5. Resultados e Discussões

Este trabalho resultou no desenvolvimento de uma aplicação móvel que faz recomendações de cultivos, além de uma API. Para isso, foi necessário pesquisar e estudar tecnologias como Flutter, Django, Django Rest Framework e Scikit-Learn. Também foi realizada uma pesquisa em busca de trabalhos semelhantes e suas contribuições. Assim, aplicando os conhecimentos adquiridos, foi desenvolvido um sistema que integra o servidor, composto pelo Django e pela API Django Rest Framework, e o cliente, utilizando o framework *Flutter* para construir a interface da aplicação.

5.1 Interface da Aplicação

Na Figura 2, é possível visualizar cada componente do sistema após a aplicação das técnicas e metodologias propostas. Essas representações gráficas oferecem uma visão de como cada elemento do sistema interage entre si.

Figura 2: Interface da aplicação com telas de listagem e cadastro.



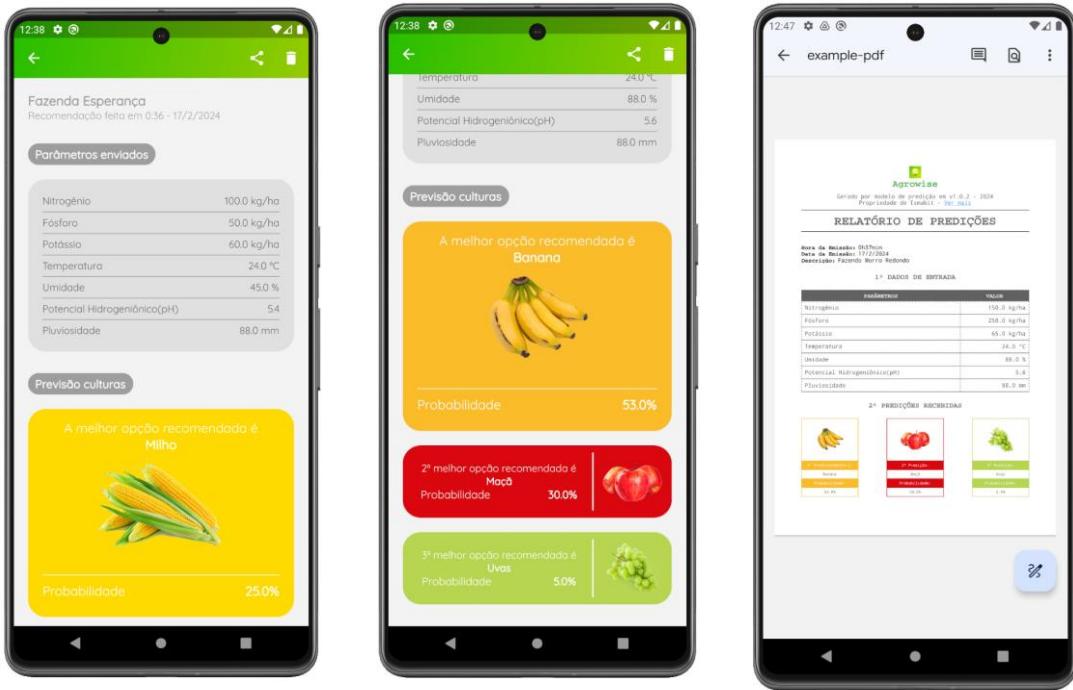
Fonte: Próprio Autor (2024).

Segundo Moura e Costa (2018), desenvolver uma interface que facilite a comunicação entre humanos e máquinas é desafiador devido à complexidade das interações humanas. Não é aceitável esperar que os usuários assumam a responsabilidade de aprender a usar um sistema complexo. Portanto, é importante criar uma interface autoexplicativa, intuitiva e familiar ao usuário.

A Figura 3 apresenta a tela inicial, onde é possível visualizar uma lista das recomendações geradas, que podem ser favoritas. Na sequência, a próxima tela exibe um formulário em que cada parâmetro possui um ícone correspondente, além de uma seção para visualização de mais informações. Caso o usuário insira dados inválidos em qualquer parâmetro, o formulário fornece avisos sobre informações incorretas, oferecendo um feedback informativo. Na mesma figura, são exibidos os resultados gerados pela recomendação feita no formulário ou acessados por meio da tela inicial. Em cada tela de detalhamento, as informações das recomendações, assim como os parâmetros utilizados para gerá-las, são armazenadas localmente no dispositivo. O aplicativo também oferece

uma funcionalidade útil para compartilhar as predições, permitindo a geração de um relatório em formato *Portable Document Format* (PDF), que contém todas as informações relevantes sobre as recomendações realizadas.

Figura 3: Interface da aplicação com telas de detalhes e relatório.



Fonte: Próprio autor (2024).

5.2 Comparação com Trabalhos Anteriores

Ao analisar as contribuições de outros trabalhos em relação a este, podemos extrair e categorizar cada uma das contribuições de cada trabalho. Assim, categorias foram definidas quanto aos recursos disponibilizados, ao modelo treinado, a interface de programação de aplicações, a plataforma utilizada.

Assim, o Quadro 1 apresenta as principais diferenças entre os artigos publicados e as contribuições deste trabalho. Nela, é notório que a maioria dos estudos utiliza o modelo de Floresta Aleatória, com 83,3% dos trabalhos adotando essa abordagem. No entanto, apenas o estudo realizado por Shah *et al.* (2021) emprega o modelo CNN para detecção de doenças. Além disso, somente esse trabalho disponibiliza uma API, o que pode limitar sua acessibilidade e integração com outras aplicações. A maioria das pesquisas é baseada na web, enquanto apenas dois estudos foram implementados em dispositivos móveis, utilizando o Flutter.

Quadro 1: Trabalhos relacionados.

Trabalhos	Recursos	Modelo	API	Plataforma
Raheem, Hussain e Ahmed, 2023	Recomendação de Cultivo	Floresta Aleatória	Não	Web
Narayana e Saxena, 2023	Recomendação de Cultivo e Detecção de doenças	Floresta Aleatória	Não	Web

Sri <i>et. al.</i> , 2023	Recomendação de Fertilizantes e Detecção de doenças	Floresta Aleatória	Não	Web
Shah <i>et al.</i> , 2021	Chat e Detecção de doenças	Rede Neural Convolucional (CNN)	Não	Mobile
Prevelato (2023)	Recomendação de Cultivo	Floresta Aleatória	Não	Web
Este Trabalho	Recomendação de Cultivo	Floresta Aleatória	Sim	Mobile

Fonte: Próprio autor (2024).

6. Considerações finais e perspectivas de futuros trabalhos

Com base nos resultados obtidos e discutidos, a pesquisa alcançou seu objetivo com êxito. A aplicação demonstrou sua capacidade de fornecer recomendações que atendem às necessidades identificadas no início do estudo. Além disso, a ferramenta poderá ser aprimorada e refinada com base no feedback dos usuários e na evolução das tecnologias.

Por meio da utilização de tecnologias recentes, foi possível desenvolver um sistema acessível aos usuários, incluindo uma API que contém um modelo treinado e avaliado, além de um aplicativo desenvolvido em Flutter. É importante ressaltar que, embora os modelos implementados sejam ferramentas para auxiliar os agricultores na tomada de decisões, eles não substituem o conhecimento e a experiência prática dos profissionais do setor. Portanto, a aplicação dessas tecnologias deve ser considerada como uma complementação à expertise humana, visando alcançar melhores resultados e uma gestão mais eficiente das atividades agrícolas.

Este estudo destaca a importância da pesquisa interdisciplinar e da colaboração entre diferentes áreas do conhecimento. Para trabalhos futuros, recomenda-se a expansão da base de dados, aprimoramentos na interface do usuário e a incorporação de novas funcionalidades, com o objetivo de atender às demandas em constante evolução do setor agrícola e promover uma agricultura sustentável e eficiente.

Referencias

- Cruz, F. Python: Escreva seus primeiros programas. Editora Casa do Código, 2015.
- Dhankar, A.; Gupta, N. A systematic review of techniques, tools and applications of machine learning. In: IEEE Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks – ICICV, pp. 764-768, 2021.
- Gaurav, A.; Chitra, L.; Munish, J. Data Analytics: Principles, Tools, and Practices: A Complete Guide for Advanced Data Analytics Using the Latest Trends, Tools, and Technologies (English Edition). BPB Publications, 2022.
- Hamdan, M. F.; Noor, S. N. M.; Abd-Aziz, N.; Pua, T. L.; Tan, B. C. Green revolution to gene revolution: Technological advances in agriculture to feed the world. Plants, 11(10), 2022.
- IBGE, Censo Agro 2017: população ocupada nos estabelecimentos agropecuários cai 8,8% | Agência de Notícias. Disponível em:

<<https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/25789-censo-agro-2017-populacao-ocupada-nos-estabelecimentos-agropecuarios-cai-8-8>>. Acesso em: 23 fev. 2024.

Ingle, Crop Recommendation Dataset. Disponível em: <<https://www.kaggle.com/datasets/atharvaingle/crop-recommendation-dataset?resource=download>>. Acesso em: 28 fev. 2024.

Li, T.; Xia, T.; Wang, H.; Tu, Z.; Tarkoma, S.; Han, Z.; Hui, P. Smartphone app usage analysis: datasets, methods, and applications. *IEEE Communications Surveys and Tutorials*, 24(2), 937-966, 2022.

Moura, M. R. A.; Costa, L. S. F. Levantamento de artigos sobre interação humano-computador em periódicos de ciência, tecnologia e sociedade. In: *Revista Tecnología e Sociedad*, v. 14, n. 33, 2018.

Narayana, P; Saxena, S. Online Crop Doctor using Machine Learning and Deep Learning. 2023.

ONU. Número de pessoas afetadas pela fome sobe para 828 milhões em 2021. Disponível em: <<https://brasil.un.org/pt-br/189062-n%C3%BAmero-de-pessoas-afetadas-pela-fome-sobe-para-828-milh%C3%B5es-em-2021>>. Acesso em: 20 fev. 2024.

Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Duchesnay, E. Scikit-learn: Machine learning in python journal of machine learning research. *Journal of machine learning research*, 12, 2825-2830, 2011.

Prevelato, M. Sistema de recomendação de plantio utilizando aprendizado de máquina. 2023. 83 f. Trabalho de Conclusão de Curso (Engenharia de Controle e Automação) – Universidade Federal de Uberlândia, Uberlândia, 2023.

Raheem, M. A.; Hussain, M. S.; Ahmed, S. A. Machine Learning based Crop Recommendation on a Cloud. In *IEEE 8th International Conference for Convergence in Technology (I2CT)* (pp. 1-5), 2023.

Sri, B. S.; Pavani, G.; Sindhuj, B. Y. S.; Swapna, V.; Priyanka, P. L. An Improved Machine Learning based Crop Recommendation System. In *IEEE International Conference on Sustainable Computing and Data Communication Systems (ICSCDS)* (pp. 64-68), 2023.

Shah, S.; Jain, N.; Shah, S.; Bide, P. J. A Flutter Application For Farmers. In *IEEE Asian Conference on Innovation in Technology (ASIANCON)* (pp. 1-8), 2021.

The World Bank. Agriculture and Food. Disponível em: <<https://www.worldbank.org/en/topic/agriculture/overview>>. Acesso em: 10 jan. 2024.

Van Klompenburg, T.; Kassahun, A.; Catal, C. Crop yield prediction using machine learning: A systematic literature review. *Computers and electronics in agriculture*, 177, 105709, 2020.