



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS CORRENTE
CURSO ANÁLISE E DESENVOLVIMENTO DE SISTEMAS - ADS

ISMAEL VIEIRA GUEDES

AGROWISE: APLICAÇÃO MÓVEL RECOMENDAÇÃO DE CULTIVOS
AGRÍCOLAS BASEADO EM APRENDIZADO DE MÁQUINA

CORRENTE - PI

2024

ISMAEL VIEIRA GUEDES

AGROWISE: APLICAÇÃO MÓVEL RECOMENDAÇÃO DE CULTIVOS AGRÍCOLAS
BASEADO EM APRENDIZADO DE MÁQUINA

Trabalho de Conclusão de Curso apresentado
como exigência parcial para obtenção do diploma
do Curso de Análise e Desenvolvimento de
Sistemas do Instituto Federal de Educação,
Ciência e Tecnologia do Piauí, Campus Corrente.

Orientador(a): Prof. Felipe Goncalves dos Santos.

Corrente - PI

2024

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD

Guedes, Ismael Vieira

G924a Agrowise : aplicação móvel recomendação de cultivos agrícolas baseadoem aprendizagem de máquina / Ismael Vieira Guedes. - 2024. 32 p.

Trabalho de Conclusão de Curso (Análise e Desenvolvimento de Sistemas) - Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Corrente, 2024.

Orientador : Prof Me. Felipe Goncalves dos Santos.

1. Analise e Desenvolvimento de Sistemas - estudo e ensino. 2. Aprendizado de máquina. 3. Flutter. 4. Django Rest Framework.
I. Título.

CDD - 004

Elaborado por Tefischer Huanderson Soares e Sousa CRB 3/1251

Ismael Vieira Guedes

AGROWISE: APLICAÇÃO MÓVEL RECOMENDAÇÃO DE CULTIVOS AGRÍCOLAS
BASEADO EM APRENDIZADO DE MÁQUINA

Trabalho de Conclusão de Curso (tipo)
apresentado como exigência parcial para obtenção
do diploma do Curso de Análise e
Desenvolvimento de Sistemas do Instituto Federal
de Educação, Ciência e Tecnologia do Piauí,
Campus Corrente.

Aprovada em: ____/____/____.

BANCA EXAMINADORA

Prof. Me. Felipe Goncalves dos Santos (Orientador)
Instituto Federal do Piauí (IFPI)

Prof. Me. Jurandir Cavalcante Lacerda Júnior
Instituto Federal do Piauí (IFPI)

Prof. Dra. Yona Serpa Mascarenhas
Instituto Federal do Piauí (IFPI)

Prof. Me. Carlos Estevão Bastos Sousa
Instituto Federal do Piauí (IFPI)

RESUMO

A agricultura passa por vários desafios, como fatores climáticos imprevisíveis e doenças que afetam as colheitas. Entretanto, a implementação de inovações tecnológicas, como o Aprendizado de Máquina, tem contribuído significativamente para o aumento do rendimento e da qualidade das colheitas. Assim, o aprendizado de máquina, ramo da Inteligência Artificial, tem sido aplicado em várias áreas, incluindo a agricultura de precisão, que utiliza grandes volumes de dados para identificar padrões complexos no solo, revolucionando os ciclos de cultivo. Além disso, integrá-lo na agricultura pode trazer melhores resultados e menores riscos à produção e ao agricultor. No trabalho é proposto o desenvolvimento de 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. A aplicação foi desenvolvida utilizando o *framework* Flutter e uma *Application Programming Interface* (API) em Django e Django Rest Framework para alimentar a aplicação.

Palavras-chaves: Agricultura; Aprendizado de máquina; Aplicativo móvel; Recomendação de cultivos; Django Rest Framework; Flutter; Scikit-Learn.

ABSTRACT

Agriculture faces several challenges, such as unpredictable weather factors and diseases that affect crops. However, the implementation of technological innovations, such as Machine Learning, has significantly contributed to increasing crop yields and quality. Thus, machine learning, a branch of Artificial Intelligence, has been applied in several areas, including precision agriculture, which uses large volumes of data to identify complex patterns in the soil, revolutionizing crop cycles. Furthermore, integrating it into agriculture can bring better results and lower risks to production and the farmer. The work proposes the development of a mobile application for crop recommendation, using a machine learning model trained with data on temperature, humidity, pH and soil information. The application was developed using the Flutter framework and an Application Programming Interface (API) in Django and Django Rest Framework to power the application.

Keywords: Agriculture; Machine learning; Mobile application; Crop recommendations; Django Rest Framework; Flutter; Scikit-Learn.

LISTA DE SIGLAS

ONU	Organização das Nações Unidas
IBGE	Instituto Brasileiro de Geografia e Estatística
API	Application Programming Interface
HTTP	Hypertext Transfer Protocol
JSON	JavaScript Object Notation
CNN	Convolutional Neural Networks
PDF	Portable Document Format

SUMÁRIO

1	INTRODUÇÃO	8
2	FUNDAMENTAÇÃO TEÓRICA	9
2.1	AGRICULTURA	9
2.2	APRENDIZADO DE MÁQUINA	10
2.2.1.	Árvore de Decisão	11
2.2.2.	Floresta Aleatória	11
2.2.3.	K-vizinhos mais próximos (KNN)	11
2.2.4.	Máquina de Vetores de Suporte (SVM)	12
2.2.5.	Naïve Bayes	12
2.3	APLICAÇÕES MÓVEIS	12
2.4	TRABALHOS RELACIONADOS	13
3	AGROWISE	17
3.1	ARQUITETURA	17
3.2	TECNOLOGIAS UTILIZADAS	18
3.2.1	Base de Dados	18
3.2.2	Scikit-Learn	19
3.2.3	Django e API Django Rest Framework	21
3.2.4	Flutter	21
4	RESULTADOS E DISCUSSÕES	22
4.1	INTERFACE DE APLICAÇÃO PROPOSTA	22
4.2	COMPARAÇÃO COM TRABALHOS ANTERIORES	25
5	CONCLUSÃO	26
	REFERÊNCIAS	27
	GLOSSÁRIO	30

1 INTRODUÇÃO

A agricultura desempenha um papel crucial no fornecimento de alimentos para o constante crescimento da população mundial. No entanto, esse setor vital enfrenta uma série de desafios significativos 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 trouxeram avanços notáveis 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 também pode contribuir para a agricultura.

Conforme Abhishek, Abhishek 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; CATAL, 2020). Ela fornece capacidade de processar grandes volumes de dados e identificar padrões complexos 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 significativamente 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 também 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.

O trabalho está estruturado em seis capítulos distintos. No Capítulo 1, é apresentada a introdução, seguida pelo Capítulo 2 dedicado à fundamentação teórica, a qual visa embasar o texto e contextualizar os temas propostos. Posteriormente, serão relatados os trabalhos relacionados à pesquisa. No Capítulo 3, serão apresentados a metodologia de pesquisa definida e aplicada, assim como o desenvolvimento do sistema. Nos Capítulos 4 e 5, serão evidenciados os resultados e discussões em relação aos outros trabalhos. Por fim, serão feitas considerações finais sobre o trabalho, reflexões sobre possíveis correções e lacunas encontradas.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo tem como propósito fundamentar os principais conceitos abordados necessários para compreensão. Como a importância da agricultura na alimentação global, e a aplicação de tecnologias como o aprendizado de máquina para melhorar a eficiência agrícola. Além disso, será discorrido uso de aplicações móveis na agricultura e apresentados os trabalhos relacionados.

2.1 AGRICULTURA

Ao longo da história, a agricultura tem desempenhado um papel crucial na alimentação da população mundial, fornecendo nutrientes essenciais para o sustento e a saúde das pessoas. Porém, o número de indivíduos impactados pela fome em todo o mundo aumentou para 828 milhões em 2021, registrando um acréscimo de aproximadamente 46 milhões desde 2020 (ONU, 2022).

Segundo o artigo publicado pelo The World Bank (2023), os sistemas alimentares atuais também ameaçam a saúde das pessoas e do planeta e geram níveis insustentáveis de poluição e desperdício. Sendo assim, é fundamental redesenhar um sistema de produção de alimentos que seja eficiente, e sustentável para garantir que todos possam ser alimentados sem prejudicar o meio ambiente (HA, 2023). Dessa forma, compreender os processos agrícolas e analisar cada componente torna-se essencial, incluindo os nutrientes do solo, os quais desempenham um papel fundamental no crescimento, na eficiência e na produtividade das culturas. Destacam-se entre esses nutrientes o nitrogênio (N), o potássio (P) e o fósforo (K), conhecidos como macronutrientes, os quais exercem funções vitais no metabolismo das plantas (UMASHANKAR DEWANGAN; TALWEKAR; BERA, 2022). Entretanto, muitos agricultores não consideram a adequação do local para determinada cultura, resultando no plantio de culturas em áreas inadequadas e, conseqüentemente, na perda de produtividade (DEY; FERDOUS; AHMED, 2024).

Contudo, a aplicação de tecnologias e conhecimentos científicos pode solucionar esse problema. De acordo com a pesquisa realizada por VAN KLOMPENBURG, KASSAHUN e CATAL (2020), o uso de ferramentas como o aprendizado de máquina pode identificar padrões, correlações e extrair conhecimento de conjuntos de dados. A pesquisa também conclui que os parâmetros mais utilizados em outros estudos são informações sobre o solo, dados solares e níveis de nutrientes. Por fim, a combinação da necessidade de inovações que auxiliem o agricultor no plantio, com tecnologias como o aprendizado de máquina, abre caminho para o desenvolvimento de novas ferramentas.

2.2 APRENDIZADO DE MÁQUINA

O aprendizado de máquina, uma ramificação da inteligência artificial, refere-se a capacidade de um sistema aprender e incorporar conhecimento a partir de grandes volumes de dados observacionais, em vez de ser pré-programado com todo esse conhecimento (WOOLF, 2009). Ademais, dentre suas utilizações temos a detecção de alarmes falsos, identificação de substâncias ilícitas, reconhecimento de padrões, conversão de texto em fala e vice-versa, sugestões de entretenimento, previsão da umidade do solo, monitoramento por vídeo, entre outros usos (JANA; BISWAS, 2021). Os algoritmos de aprendizado de máquina selecionados neste trabalho foram: Árvore de Decisão, Floresta Aleatória, K-vizinhos mais próximos (k-nearest neighbors algorithm, KNN), Máquina de Vetores de Suporte (MVS) e Naïve Bayes.

2.2.1. Árvore de Decisão

A árvore de decisão é um modelo que funciona dividindo os dados em grupos distintos de forma binária, com cada divisão tentando maximizar a separação entre os grupos. Esse modelo é fácil de entender quando têm um número pequeno de divisões, mas podem se tornar complexo e difícil de interpretar quando há muitas variáveis envolvidas (TRETTER, 2003). Basicamente, a ideia por trás das árvores de decisão é realizar divisões sucessivas nos dados, começando com a divisão que resulta na maior separação entre os grupos. Cada subgrupo formado é então dividido novamente, seguindo o mesmo princípio, até que certos critérios de parada sejam alcançados.

2.2.2. Floresta Aleatória

A Floresta Aleatória é um tipo especial de modelo de aprendizado que ajuda a reduzir erros ao fazer previsões. Em vez de depender de uma única árvore de decisão como a Árvore de Decisão, a Floresta Aleatória usa várias árvores e depois calcula a média de suas previsões (DEY; FERDOUS; AHMED, 2024). Cada árvore na floresta toma decisões de forma independente, o que ajuda a evitar o superajuste. Em vez de seguir regras específicas, as árvores dividem os dados de forma aleatória, o que contribui para uma previsão mais precisa. No final, a classe com mais votos entre todas as árvores é escolhida como a previsão final.

2.2.3. K-vizinhos mais próximos

Segundo os autores María, Isaac Segovia Ramírez e Pedro García Márquez (2023), o k-vizinhos mais próximos é um algoritmo de aprendizado de máquina supervisionado que se baseia na proximidade de amostras em um espaço de características. Ele determina a categoria de uma amostra de teste observando as categorias das k amostras mais próximas no conjunto de treinamento. Se a maioria dessas amostras pertence a uma categoria específica, a amostra de teste também é atribuída a essa categoria.

2.2.4. Máquina de Vetores de Suporte

As Máquinas de Vetor de Suporte (MVS) são ferramentas de classificação que procuram encontrar o melhor hiperplano ou separador entre classes em um conjunto de dados (PREVELATO, 2023). Esses métodos começam com a ideia de que os dados são separáveis por um separador funcional. Eles utilizam princípios como a busca por um hiperplano com a maior margem possível entre os vetores de suporte, onde a margem é a distância entre o hiperplano e os pontos mais próximos de cada classe. As Máquinas de Vetor de Suporte podem lidar com dados não linearmente separáveis através de técnicas como mapeamento para dimensões superiores (BUNGE; JUDSON, 2005). O objetivo final é encontrar um hiperplano de margem máxima, que é o que separa as classes de forma mais eficaz.

2.2.5. Naïve Bayes


O Naïve Bayes é um tipo de classificador que se baseia no teorema de Bayes e na suposição de independência entre as características (CHAKRABORTY; GHOSH; SAHA, 2020). É amplamente utilizado para criar modelos de classificação que atribuem rótulos de classe a instâncias de problema representadas como vetores de valores de recurso. Este método é comumente usado em várias áreas, incluindo diagnóstico médico automático. Ele é eficiente e escalável para problemas de aprendizado, utilizando parâmetros de variáveis lineares.

2.3 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, socialização online, comércio eletrônico e pagamento online (LI et al., 2022). Além disso, ocorreu 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 áreas rurais.

Somente no Brasil, no período de 2006 a 2017, ocorreu um aumento significativo no número de estabelecimentos agropecuários com acesso a *smartphones*, passando de 1,2 milhões para 3,1 milhões, representando um aumento de 158% (IBGE, 2019). Em virtude disso, com a distribuição em larga escala dos *smartphones*, os agricultores agora podem aproveitar recursos que anteriormente estavam fora de seu alcance (SHAH et al., 2021). No Gráfico 1 são ilustrados os diferentes domínios da agricultura em que essas aplicações já estão em uso.

Gráfico 1 - Tipos de aplicações existentes.



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

O gráfico de barras horizontal representado pelo Gráfico 1 é apresentado às diferentes categorias de aplicativos usados nos domínios da agricultura. A categoria “Gestão Agrícola” é a mais popular, seguido pelos “Aplicativos de aprendizagem e referência”.

2.4 TRABALHOS RELACIONADOS

Esta seção tem por propósito elencar e relatar trabalhos que possuem similaridade com a proposta deste trabalho. Desse modo, foram encontrados cinco artigos que possuem relação com este projeto, dentre elas a aplicação no contexto da agricultura, utilizando o mesmo modelo ou plataforma. Os autores dos trabalhos são: RAHEEM, HUSSAIN e AHMED (2023); SEXENA (2023); SRI et al. (2023); SHAH et al. (2021); e PREVELATO (2023).

O estudo feito 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.

Figura 1 - Páginas de início e formulário do sistema.

The figure consists of two screenshots of a web application. The top screenshot shows the homepage with a dark background featuring images of green seedlings in pots. The text 'CROP RECOMMENDATION SYSTEM' is prominently displayed in white, with the subtitle 'Here Are Some Questions We'll Answer' below it. A navigation bar at the top right contains links for 'Home' and 'Crop'. The bottom screenshot shows a form titled 'Find out the most suitable crop to grow in your farm'. The form includes input fields for 'Nitrogen', 'Phosphorous', 'Potassium', 'pH level', and 'Rainfall (in mm)', each with a placeholder 'Enter the value (example:50)'. There are also dropdown menus for 'State' (with 'Select State' as the placeholder) and 'City'. A blue 'Predict' button is located at the bottom of the form.

Fonte: RAHEEM, HUSSAIN e AHMED (2023)

A Figura 1, é apresentada o sistema criado por RAHEEM, HUSSAIN e AHMED (2023), onde os usuários podem inserir informações específicas sobre o solo e o clima para obter recomendações de qual cultura plantar.

Já o trabalho de NARAYANA e SAXENA (2023) integra modelos em um aplicativo web via Flask, oferece recomendações de culturas e detecção de doenças. O modelo Naïve Bayes obteve precisão de 99,71%, seguido pela Floresta Aleatória com 99,80%, enquanto a Árvore de Decisão teve 60%. Estes resultados destacam a eficácia do Naïve Bayes e Floresta Aleatória na previsão de safras em comparação com a Árvore de Decisão. A seguir, é mostrado as telas do sistema desenvolvido pelos autores NARAYANA e SAXENA (2023).

Figura 2 - Telas de recomendação e detecção de doenças.

The figure consists of two screenshots of a web application. The top screenshot, titled 'ABOUT US', shows a form for inputting various data points: Potassium (with a hint 'Enter the value (example:50)'), pH level, Rainfall (in mm), State (with a 'Select State' dropdown), and City. A blue 'Predict' button is at the bottom. The bottom screenshot is titled 'Find out which disease has been caught by your Tomato plant Based on leaf image'. It prompts the user to 'Please upload tomato leaf image' and shows a file selection interface with a 'Choose File' button and a file name '0c3eaf72d-8..._eg/11ptLR.JPG'. Below this is a thumbnail image of a green tomato leaf with some yellowing. A blue 'Predict' button is at the bottom.

Fonte: NARAYANA e SAXENA (2023).

Na Figura 2, é possível visualizar duas interfaces web diferentes para previsão de informações; a da esquerda é para prever um resultado desconhecido com base em detalhes pessoais, e a da direita é para identificar doenças em plantas de tomate analisando imagens de folhas.

O autor 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: 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. Isso resultou em uma interface amigável para agricultores inserirem informações do solo e receberem recomendações personalizadas, evidenciando a eficácia da tecnologia na otimização da produção.

Figura 3 - Interfaces de recomendação e detecção de doenças.


The figure consists of two screenshots of web interfaces. The top screenshot shows a form titled "Find out the most suitable crop to grow in your farm". It has a blue background and contains input fields for "Nitrogen", "Phosphorous", "Potassium", "ph level", "Rainfall (in mm)", and "State". Each field has a placeholder text "Enter the value (example:50)". The bottom screenshot shows a form titled "Find out which disease has been caught by your plant". It has a blue background and contains a "Please Upload The image" section with a "Choose File" button and a "diseased leaves" label. Below this is a preview of a plant with purple spots, and a "Predict" button. Both screenshots show a Windows taskbar at the bottom with various icons and a system clock.

Fonte: SRI, et al. (2023).

A Figura 3, é apresentada duas interfaces de formulário do software de SRI, et al. (2023). Uma interface com os parâmetros a serem inseridos pelos usuários e recomendar a cultura mais adequada, e a outra identifica doenças nas plantas através do upload de uma imagem.

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

Figura 4 - Telas de início e detecção da aplicação



Fonte: SHAH, et al. (2021).

Na Figura 4, é exposto um aplicativo móvel chamado “VRUTTI”, que oferece funcionalidades para prever doenças em plantas. A primeira tela exibe opções interativas como “Predict the disease” e “Ask Something”, enquanto a segunda tela apresenta a funcionalidade “Predict Plant Disease”, com instruções em hindu, para capturar uma imagem e realizar a detecção do tipo de doença.

O trabalho feito por PREVELATO (2023) visou criar um sistema de recomendação de plantio com base em algoritmos de Aprendizado de Máquina usando dados públicos de plantio. Métodos como Árvore de Decisão, Floresta Aleatória, K-Vizinhos mais próximos, Máquina de Vetores de Suporte e Naive Bayes foram aplicados, resultando em modelos com acurácia acima de 99%. Destacaram-se os modelos de Floresta Aleatória e Gaussian Naive-Bayes, este último com métricas ligeiramente superiores. Optou-se pelo modelo de Floresta Aleatória devido à sua robustez contra outliers, apesar do tempo maior de criação. A Figura 5, é visível nas páginas a funcionalidade de recomendação construídas por ele para interação com o usuário.

Figura 5 - Páginas de formulário e recomendação.

Here you can insert the features! This way the system will predict the best crop to plant!

In the (?) marks you can get some help about each feature.

Insert N (kg/ha) value: ?
 - +

Insert P (kg/ha) value: ?
 - +

Insert K (kg/ha) value: ?
 - +

Insert Avg Temperature (°C) value: ?
 - +

Insert Avg Humidity (%) value: ?
 - +

Insert pH value: ?
 Insert here the Avg Rainfall (mm) from 21 to 298

Insert Avg Rainfall (mm) value: ?
 - +

Best Crop to Plant: coconut.



Statistics Summary about coconut NPK and Weather Conditions values in the Dataset.

	N	P	K	temperature	humidity	pH	rainfall
count	100.0000	100.0000	100.0000	100.0000	100.0000	100.0000	100.0000
mean	21.9800	16.9300	30.5900	27.4099	94.8443	5.9766	175.6866
std	11.7619	8.3572	2.9886	1.3857	2.6863	0.2876	29.4723
min	0.0000	5.0000	25.0000	25.0087	90.0173	5.5016	131.0900
25%	11.7500	9.7500	29.0000	26.2987	92.5450	5.7311	149.1265
50%	24.0000	15.5000	31.0000	27.3853	94.9608	5.9907	171.9999
75%	31.0000	24.2500	33.0000	28.6002	96.7597	6.2092	202.3515
max	40.0000	30.0000	35.0000	29.8691	99.9819	6.4705	225.6324

Fonte: PREVELATO (2023).

Na Figura 5, uma interface de usuário para um sistema é apresentada, e que possui uma tela para informar os dados necessários e recomendar a melhor cultura a ser plantada com base em características inseridas, indicando “coco” como a melhor cultura a ser plantada, dadas as condições de entrada. No seguinte capítulo, será descrito o aplicativo proposto por este trabalho, bem como as informações, funcionalidades, metodologias e tecnologias aplicadas para a elaboração deste software.

3 AGROWISE

Durante a elaboração deste trabalho, foi definida uma metodologia 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 é 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 somente 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 diversos recursos úteis, como a capacidade de gerar relatórios para cada previsão, permitindo também que o usuário compartilhe facilmente o arquivo gerado e 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. Em seguida, são fornecidos mais detalhes sobre o desenvolvimento do aplicativo, incluindo sua arquitetura, as tecnologias empregadas, o modelo de aprendizado de máquina utilizado e as interfaces e funcionalidades úteis para o usuário.

3.1 ARQUITETURA

Durante a fase de elaboração da arquitetura, foi identificado que a abordagem mais adequada seria uma estrutura onde o cliente, por meio da aplicação, utilizaria os recursos disponíveis por um servidor. Para isso, é necessário que o utilizador realize uma solicitação, enviando os dados necessários, para o hospedeiro processar esses dados recebidos e retornar as recomendações para o utilizador. O aplicativo, desenvolvido utilizando o framework Flutter, atua como cliente, enviando solicitações para um servidor que é uma API construída com o framework Django Rest Framework. Em seguida, retorna os resultados das recomendações para o aplicativo. A seguir, é possível visualizar a estrutura na Figura 6.

Figura 6 - Arquitetura do sistema.



Fonte: Próprio autor (2024).

3.2 TECNOLOGIAS UTILIZADAS

Nesta seção, são detalhadas as tecnologias utilizadas e o motivo de sua escolha. Além disso, o Python foi escolhido, pois é uma linguagem de alto nível, destacando-se pela sintaxe simplificada e legibilidade (MELO, 2021). Por esse motivo, foi selecionado como a linguagem completa para o servidor, a fim de treinar o modelo e construir a API.

3.2.1 Base de Dados

Os dados utilizados provêm de uma fonte acadêmica indiana disponível na plataforma Kaggle, abrangendo informações sobre cultivo na Índia (INGLE, 2020). A base de dados contém um conjunto de parâmetros e informações sobre 22 culturas que são: arroz, milho, grão de bico, feijão, feijão bóer, feijão traça, feijão mungo, feijão preto, lentilha, romã, banana, manga, uvas, melancia, melão almiscarado, maçã, laranja, mamão, coco, algodão, juta e café. Os parâmetros considerados incluem características do solo, sendo eles: nitrogênio, fósforo, potássio, temperatura, umidade, potencial hidrogeniônico (pH) e pluviosidade.

3.2.2 Scikit-Learn


A primeira parte no desenvolvimento do sistema é 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 análise preditiva de dados. Construída sobre as bibliotecas do Python NumPy, SciPy e Matplotlib, ela é acessível a todos e reutilizável em vários contextos (PEDREGOSA et al., 2011). Nesse sentido, foram aplicadas técnicas e ferramentas para o treinamento do modelo de aprendizado de máquina definido pelo autor PREVELATO (2023) em seu trabalho.

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.

O autor GAURAV (2023) define cada uma das métricas de acurácia, precisão e revocação. A acurácia avalia quantas previsões corretas existem entre todas as previsões feitas. Embora seja uma medida comumente empregada, pode não ser apropriada nos casos em que há um 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 para todas as previsões positivas, enquanto a revocação avalia a proporção de previsões positivas verdadeiras para todas as instâncias positivas reais. A precisão torna-se crítica quando o custo dos falsos positivos é alto, enquanto a revocação é indispensável quando o custo dos falsos negativos é significativo. Em muitos cenários, essas métricas fornecem informações mais esclarecedoras em comparação com a precisão.

No Gráfico 2, os resultados são apresentados de forma detalhada os resultados de cada um dos cinco modelos, e agrupando os resultados de cada pela métrica que está sendo avaliada. A análise desses resultados é crucial para fundamentar a escolha final do modelo, que seja 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, Naïve Bayes e Floresta Aleatória se destacam, mostrando as maiores pontuações em todas as métricas. Esses dois modelos demonstram ser mais robustos e confiáveis do que os outros dois.

Enquanto Naïve Bayes é elogiado por sua simplicidade e rapidez, a Floresta Aleatória se destaca por sua flexibilidade e precisão. Apesar do modelo baseado em Naïve Bayes ter métricas ligeiramente superiores às apresentadas pelo modelo de Floresta Aleatória, ambos alcançam pontuações superiores a 99%. Entretanto, uma fraqueza significativa 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 que melhor atenderá ao propósito do trabalho se justifica pela sua pontuação superior em relação aos demais e por ser o modelo mais utilizado em trabalhos similares. Assim, optar por este modelo é a decisão mais adequada.

3.2.3 Django e API Django Rest Framework

O próximo passo crucial para avançar no desenvolvimento do sistema é a criação do servidor web responsável por disponibilizar o modelo treinado por meio de uma API. Nesse sentido, optou-se pelo framework Django, uma estrutura web Python de alto nível que favorece o desenvolvimento ágil, apresentando um design limpo e pragmático (DJANGO, 2019). Além disso, ele aborda grande parte das complexidades do desenvolvimento web, permitindo que os desenvolvedores se concentrem na criação do aplicativo sem a necessidade de reinventar soluções já consolidadas. Com o servidor em funcionamento, é preciso integrá-lo com uma *Application Programming Interface* (API), que é uma coleção de código existente que outros programadores podem chamar para ajudar a realizar tarefas de programação (STYLOS; MYERS, 2007).

Logo, sua função é auxiliar o desenvolvedor durante a fase de desenvolvimento até a fase de produção, quando o sistema já está disponibilizado para os usuários ou outros desenvolvedores utilizarem a API. Assim, o *framework* Django Rest Framework foi escolhido, pois possui uma extensa documentação e ótimo suporte da comunidade, visto que é o framework em Python mais utilizado por empresas reconhecidas internacionalmente, como Mozilla, Red Hat, Heroku e Eventbrite (CHRISTIE, 2011).

3.2.4 Flutter

Após a conclusão do servidor, é feita a etapa de criação da interface pela qual os usuários terão acesso aos serviços oferecidos pela API. A responsabilidade por essa etapa recai sobre uma aplicação dedicada à utilização do serviço fornecido pela API. O Flutter foi eleito como o *framework*, que é uma avançada estrutura de código aberto desenvolvida pelo Google, projetada para a criação eficiente de aplicativos multiplataforma (FLUTTER, 2023). Sua característica distintiva reside na capacidade de compilar código nativamente para dispositivos móveis, web, desktop e incorporados a partir de uma única base de código. Além disso, o uso de vários pacotes do Flutter torna os recursos utilizados por aplicativos muito mais eficientes e rápidos (SHAH et al., 2021). No próximo capítulo, será visto todos os conceitos aplicados para o desenvolvimento do servidor e do cliente e os resultados obtidos.

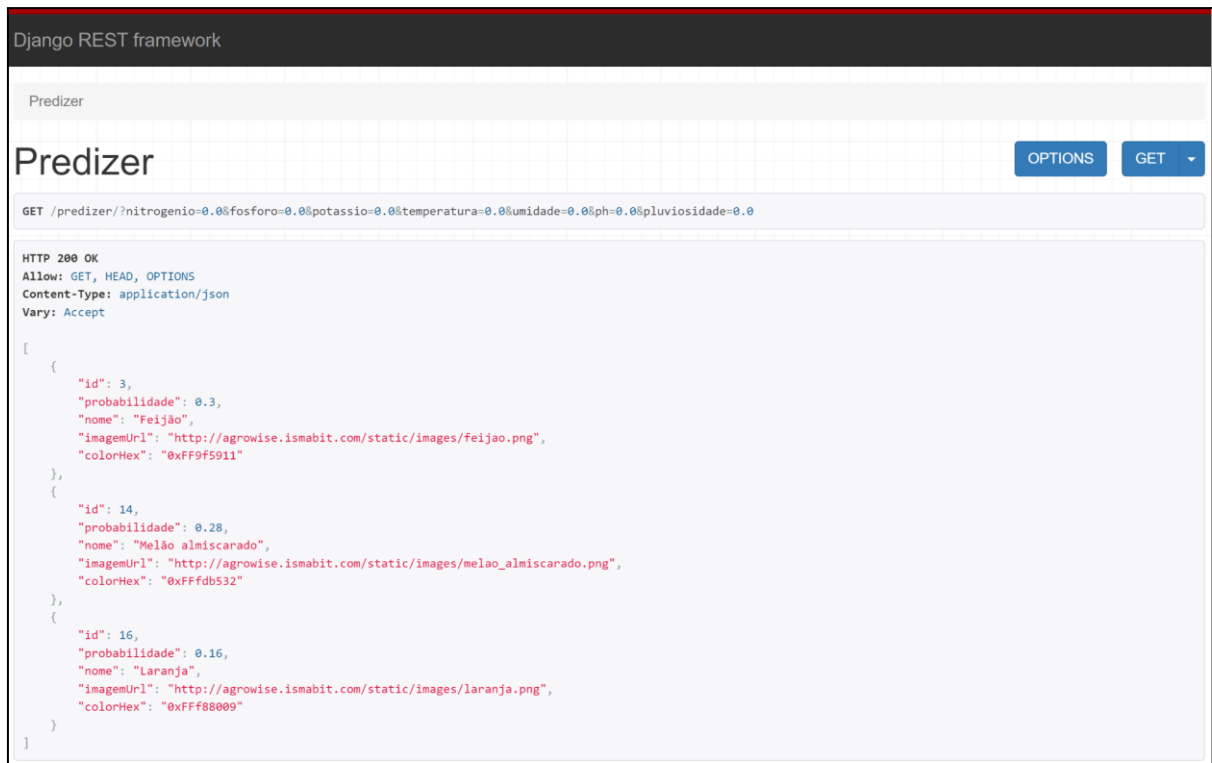
4 RESULTADOS E DISCUSSÕES

Este trabalho resultou no desenvolvimento de uma aplicação móvel que faz recomendações de cultivos, e uma API. Onde foi necessário pesquisar e estudar sobre tecnologias Flutter, Django, Django Rest Framework e Scikit-Learn. Além disso, realizar uma pesquisa em busca de trabalhos semelhantes e suas contribuições. Assim, aplicando os conhecimentos obtidos, foi desenvolvido o sistema que integra o servidor composto pelo servidor Django, e a API Django Rest Framework, e também o cliente utilizando o *framework* Flutter a para construir a interface da aplicação.

4.1 INTERFACE DE APLICAÇÃO PROPOSTA

Nas Figuras 7, 8 e 9, é possível visualizar cada componente do sistema, após a conclusão das técnicas e metodologias propostas. Essas representações gráficas oferecem uma visão detalhada e abrangente de como cada elemento do sistema interage entre si.

Figura 7 - Interface da API de recomendação.




Fonte: Próprio autor (2024).

Na Figura 7 é apresentado como o aplicativo realiza a comunicação com a API e envia uma requisição via protocolo HTTP com os parâmetros necessários. Em seguida, a API se comunica com o modelo, enviando os parâmetros que incluem nitrogênio, fósforo, potássio, temperatura, umidade, potencial hidrogeniônico e pluviosidade. Por fim, o modelo retorna uma lista contendo os índices das previsões, juntamente com as probabilidades. Assim, a API é responsável por retornar um JSON que contém as previsões, incluindo informações como o índice, a probabilidade, uma imagem e cor correspondente à cultura para visualização e estilização.

Como colocado por MOURA e COSTA (2018) desenvolver uma interface que facilite a comunicação entre humanos e máquinas é desafiador devido à natureza humana das interações. Não é aceitável esperar que os usuários assumam a responsabilidade de aprender a usar um sistema complexo. Logo, criar uma interface auto explicativa, direta e familiar ao usuário é de suma importância.


Figura 8 - Interface da aplicação com telas de listagem e cadastro.



Fonte: Próprio autor (2024).

A Figura 8 é apresentada uma tela inicial onde já é possível visualizar uma lista das recomendações geradas e que podem ser favoritadas. Nesse sentido, a próxima tela apresenta um formulário onde cada parâmetro possui um ícone correspondente, e uma seção para visualização de mais informações. Além disso, na tela seguinte, caso o usuário informe dados inválidos a qualquer parâmetro, o formulário mostra avisos de informações incorretas, oferecendo um *feedback* informativo (AELA, 2023).

Figura 9 - Interface da aplicação com telas de detalhes e relatório.



Fonte: Próprio autor (2024).

Na Figura 9, é retornado o resultado gerado pela recomendação feita no formulário ou acessado por meio da tela inicial. Em cada tela de detalhamento, as informações das recomendações, bem como os parâmetros utilizados para gerá-las, são armazenadas localmente no dispositivo. Além disso, o aplicativo oferece uma funcionalidade útil para o compartilhamento das previsões, permitindo a geração de um relatório em *Portable Document Format* (PDF) ou documento portátil, que contém todas as informações relevantes sobre as recomendações realizadas. A aplicação está disponível gratuitamente para baixar somente para smartphones Android na plataforma *Google Play Store*¹. Como também, a API está disponível para utilização por meio do site Agrowise².

4.2 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. A Tabela 1, é apresentada as principais diferenças entre os artigos publicados e as principais contribuições deste trabalho.

Tabela 1 - Trabalhos relacionados.

Trabalhos	Recursos	Modelo	API	Plataforma
(RAHEEM; HUSSAIN; AHMED, 2023)	Recomendação de Cultivo	Floresta Aleatória	Não	Web
(P; SAXENA, 2023)	Recomendação de Cultivo e Detecção de doenças	Floresta Aleatória	Não	Web
(SRI et al., 2023)	Recomendação de Fertilizantes e Detecção de doenças	Floresta Aleatória	Não	Web
(SHAH et al., 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).

Na Tabela 1, é notório que a maioria dos trabalhos usa o modelo de Floresta Aleatória, com 83,3% dos trabalhos utilizando o modelo. Entretanto, apenas o trabalho feito por SHAH, et al (2021) usa o modelo CNN para detecção de doenças. Ainda mais, apenas este trabalho disponibiliza uma API, o que pode limitar a sua acessibilidade e integração com outras aplicações. A maioria dos trabalhos é baseada na web, e apenas dois trabalhos são implementados em mobile, utilizando o Flutter.

¹ Disponível em: <<https://play.google.com/store/search?q=agrowise>>. Acesso em: 2 mar. 2024.

² Disponível em: <<https://agrowise.ismabit.com/>>. Acesso em: 2 mar. 2024.

5 CONCLUSÃO

Com base nos resultados obtidos e discutidos, é evidente que este trabalho conseguiu concluir seu objetivo com êxito. A aplicação demonstrou sua capacidade de fornecer recomendações atendendo assim às necessidades identificadas no início do projeto. Além disso, a aplicação poderá continuar sendo aprimorada e refinada com base no feedback dos usuários e na evolução das tecnologias subjacentes.

Utilizando tecnologias recentes e inovadoras, foi possível desenvolver um sistema acessível para usuários utilizarem, uma API para uso que contém um modelo treinado e avaliado, a Floresta Aleatória, bem como um aplicativo desenvolvido em Flutter.

É importante ressaltar que, embora os modelos desenvolvidos sejam ferramentas valiosas para 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 vista como uma complementação ao expertise humano, 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. Como trabalhos futuros, recomenda-se a expansão da base de dados, aprimoramentos na interface do usuário e a incorporação de novas funcionalidades, visando atender às demandas em constante evolução do setor agrícola e promover uma agricultura mais sustentável e eficiente.

REFERÊNCIAS

ABHISHEK; ABHISHEK DHANKAR; GUPTA, N. A Systematic Review of Techniques, Tools and Applications of Machine Learning. **2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV)**.

AELA, E. **Interação Humano-Computador: Tudo Que Você Precisa Saber**. Disponível em: <<https://aelaschool.com/pt/designdeinteracao/interacao-humano-computador-tu-do-que-voce-precisa-saber/>>. Acesso em: 17 de fev. de 2024.

B. SWATHI SRI et al. An Improved Machine Learning based Crop Recommendation System. 23 de mar. de 2023.

BUNGE, J. A.; JUDSON, D. H. Data Mining. **Encyclopedia of Social Measurement**, p. 617–624, 2005.

CHAKRABORTY, D.; GHOSH, A.; SAHA, S. A survey on Internet-of-Thing applications using electroencephalogram. **Elsevier eBooks**, p. 21–47, 1 jan. 2020.

CHRISTIE, T. **Home - Django REST framework**. Disponível em: <<https://www.django-rest-framework.org/>>. Acesso em: 16 de fev. de 2024.

DEY, B.; FERDOUS, J.; AHMED, R. Machine learning based recommendation of agricultural and horticultural crop farming in India under the regime of NPK, soil pH and three climatic variables. **Heliyon**, p. e25112–e25112, 1 jan. 2024.

DJANGO, **The Web framework for perfectionists with deadlines | Django**. Disponível em: <<https://djangoproject.com>>. Acesso em: 23 de dez. 2023.

FLUTTER. **Flutter - Beautiful native apps in record time**. Disponível em: <<https://flutter.dev/>>. Acesso em: 25 de dez. 2023.

GAURAV, P. **Mastering Classification Metrics: A Beginners Guide [Part 1: Accuracy, Precision, and Recall]**. Disponível em: <<https://medium.com/@prateekgaurav/mastering-classification-metrics-a-beginners-guide-part-1-accuracy-precision-and-recall-fbadc90654ab>>. Acesso em: 22 fev. 2024.

HA, L. T. An investigation of digital integration's importance on smart and sustainable agriculture in the European region. **Resources Policy**, v. 86, p. 104158, 1 out. 2023.

HAMDAN, M. F. et al. Green Revolution to Gene Revolution: Technological Advances in Agriculture to Feed the World. **Plants**, v. 11, n. 10, p. 1297, 12 mai. 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?source=download>>. Acesso em: 28 fev. 2024.

JANA, M.; BISWAS, S. Intelligent and smart enabling technologies in advanced applications: recent trends. **Recent Trends in Computational Intelligence Enabled Research**, p. 355–365, 2021.

LI, T. et al. Smartphone App Usage Analysis: Datasets, Methods, and Applications. **IEEE Communications Surveys & Tutorials**, v. 24, n. 2, p. 937–966, 2022.

MARÍA, A.; ISAAC SEGOVIA RAMÍREZ; PEDRO, F. K-nearest neighbour and K-fold cross-validation used in wind turbines for false alarm detection. **Sustainable Futures**, v. 6, p. 100132–100132, 1 dez. 2023.

MELO, **O que é Python? [Guia para iniciantes]**. Disponível em: <<https://tecnoblog.net/responde/o-que-e-python-guia-para-iniciantes/>>. Acesso em: 23 fev. 2024.

ABDUL RAHEEM, M.; SABIR HUSSAIN, M.; AHMED, S. A. Machine Learning based Crop Recommendation on a Cloud. 7 abr. 2023.

MOURA, M. R. d. A.; COSTA, L. S. F. Levantamento de artigos sobre interação humano-computador em periódicos de ciência, tecnologia e sociedade. Revista Tecnologia e Sociedade, Universidade Tecnológica Federal do Paraná (UTFPR), v. 14,n. 33, 2018. ISSN 1809-0044.

NARAYANA P; SAXENA, S. Online Crop Doctor using Machine Learning and DeepLearning. 4 mai. 2023.

ONU, **Mudança climática influencia na perda da produção agrícola para pragas,conclui estudo apoiado pela FAO.**
Disponível em:
<<https://brasil.un.org/pt-br/130780-mudan%C3%A7a-clim%C3%A1tica-influencia-na-perda-da-produ%C3%A7%C3%A3o-agr%C3%ADcola-para-pragas-conclui-estudo>>. Acesso em: 01 de fev. 2024.

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. et al. Scikit-learn: Machine learning in Python. **Journal of MachineLearning Research**, v. 12, p. 2825–2830, 2011.

PREVELATO, M. Sistema de recomendação de plantio utilizando aprendizado de máquina. 2023.

SHAH, S. et al. A Flutter Application For Farmers. **2021 Asian Conference on Innovation in Technology (ASIANCON)**, 27 ago. 2021.

STYLOS, J.; MYERS, B. Mapping the Space of API Design Decisions. **IEEE Symposium on Visual Languages and Human-Centric Computing (VL/HCC 2007)**, set. 2007.

TRETTETTER, M. J. Data Mining. **Elsevier eBooks**, p. 477–488, 1 jan. 2003.

THE WORLD BANK. **Agriculture and Food**. Disponível em:

<<https://www.worldbank.org/en/topic/agriculture/overview>>. Acesso em: 10 jan.2024.

UMASHANKAR DEWANGAN; TALWEKAR, R. H.; BERA, S. Systematic Literature Review on Crop Yield Prediction using Machine & Deep Learning Algorithm. 2 dez. 2022.

VAN KLOMPENBURG, T.; KASSAHUN, A.; CATAL, C. Crop yield prediction using machine learning: A systematic literature review. **Computers and Electronics in Agriculture**, v. 177, p. 105709, out. 2020.

WOOLF, B. P. Machine Learning. **Building Intelligent Interactive Tutors**, p. 221–297, 2009.

GLOSSÁRIO

API (Application Programming Interface): é um conjunto de normas que possibilita a comunicação entre plataformas através de uma série de padrões e protocolos.

Framework: é um termo inglês que, em sua tradução direta, significa estrutura. De maneira geral, essa estrutura é feita para resolver um problema específico.

Feedback: é uma resposta oferecida a um estímulo como uma forma de avaliação.

Desktop: uma palavra em inglês que representa o ambiente principal do computador.

Web: é uma palavra inglesa que significa teia ou rede.

Smartphones: é um dispositivo móvel que desempenha diversas funções computacionais, geralmente equipado com uma tela sensível ao toque.