

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SÃO
PAULO - IFSP CÂMPUS CAMPINAS**

LUANA IÓRIO FANTINATTI
LUCAS BIAZON PALMA
VICTOR SAMUEL DO SANTOS

BOTANY, O APLICATIVO INTELIGENTE PARA GERENCIAMENTO DE HORTAS

Campinas - SP
2024

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE SÃO
PAULO - IFSP CÂMPUS CAMPINAS

Luana Lório Fantinatti
Lucas Biazon Palma
Victor Samuel dos Santos

BOTANY, O APLICATIVO INTELIGENTE PARA GERENCIAMENTO DE HORTAS

Trabalho de Projeto Integrador do Curso de Técnico em Informática Integrado ao Ensino Médio do IFSP - Campus Campinas, como requisito parcial para conclusão de curso, iniciado em 05 de fevereiro de 2024.

Orientador: Prof. Márcio André Miranda

Campinas - SP
2024

SUMÁRIO

1.INTRODUÇÃO.....	5
2.OBJETIVOS E RELEVÂNCIA DO TRABALHO.....	5
2.1.Doenças e pragas em milharais.....	6
2.1.1. Ferrugem.....	6
2.1.2. Cercosporiose.....	6
2.2. Doenças e pragas em laranjeiras.....	7
2.2.1. Cancro Cítrico.....	7
2.2.2. Deficiência de nutrientes em laranjas.....	8
2.3. Aprendizado de máquina.....	9
2.3.1 Regressão Linear.....	10
2.3.2. Coeficiente R-quadrado.....	10
2.3.3 Overfitting.....	11
2.4. Redes Neurais.....	12
2.4.1 Redes Neurais Convolucionais.....	13
2.4.2 Segmentação Semântica.....	14
2.5 Tecnologias.....	15
2.6 Objetivos.....	15
3.METODOLOGIA.....	15
4.RESULTADOS DO PROJETO.....	17
5.CONCLUSÕES.....	23
Referências Bibliográficas.....	24

RESUMO

O intuito deste projeto é democratizar o acesso às tecnologias agrícolas para pequenos agricultores, enfrentando barreiras econômicas, falta de infraestrutura e conhecimento técnico. O projeto Botany, o aplicativo inteligente para gerenciamento de hortas, uma plataforma móvel integrada com inteligência artificial (IA), visa facilitar o manejo de hortas, utilizando modelos de Rede Neural Convolutiva (CNN) para diagnóstico de doenças, e modelos de regressão para análise preditiva. Almejando melhorar a eficiência agrícola e promover práticas sustentáveis, o projeto é fundamentado em teorias de IA aplicada à agricultura e desenvolvimento sustentável. A metodologia inclui pesquisa exploratória para entender as necessidades dos agricultores, seguida do desenvolvimento experimental dos componentes da plataforma, integrando Backend, Frontend, bancos de dados e APIs externas para garantir a escalabilidade e segurança do sistema. Espera-se que o projeto aumente a produtividade, melhore a qualidade de vida dos agricultores, reduza disparidades sociais e promova a inclusão digital. Os recursos necessários incluem equipamentos de desenvolvimento e teste, além de serviços de hospedagem, enquanto os desafios previstos envolvem a adaptação de modelos de IA a contextos específicos e a aceitação das novas tecnologias pelos agricultores. Com uma abordagem robusta e sistemática, o projeto democratização tecnológica na agricultura, propõe-se a inovar e aprimorar a eficiência agrícola, contribuindo para uma agricultura mais sustentável e inclusiva.

Palavras-chaves: horta inteligente; segmentação semântica; detecção de doenças em plantas; aplicativo móvel; rede neural; visão computacional;

1.INTRODUÇÃO

O modelo de produção da agricultura moderna se caracteriza pela abundante integração de tecnologia, com isso o processo de inovação no cultivo tem sido cada vez mais acelerado e produtivo. (CROPLIFE BRASIL, 2023). Entretanto, pequenos agricultores são atormentados por barreiras econômicas, falta de infraestrutura e conhecimento técnico, limitando-os o acesso às inovações e diminuindo sua competitividade comercial. (AGRO ESTADÃO, 2023).

A hipótese central do projeto é que a implementação de uma plataforma móvel acessível que facilite o manejo de hortas por meio de inteligência artificial, pode melhorar a produtividade e a sustentabilidade das hortas, ao mesmo tempo que reduz desigualdades sociais e promove a inclusão digital.

Utilizando modelo de Redes Neurais Convolucionais (CNN) para detecção e diagnóstico de doenças nas plantações. Além de ferramentas para gerenciar e monitorar a horta. O aplicativo, propõe minimizar a lacuna causada pela desigualdade ao acesso às tecnologias agrícolas.

Este estudo, ao explorar a aceitação e adaptação das tecnologias por agricultores com recursos limitados, contribuirá para um melhor entendimento dos impactos sociais, econômicos e ambientais dessa transformação digital. Assim, o projeto botany é relevante, pois está alinhado com questões de desenvolvimento rural e inovação tecnológica, fortalecendo a economia das áreas rurais e melhorando a qualidade de vida dos agricultores.

2.OBJETIVOS E RELEVÂNCIA DO TRABALHO

2.1.Doenças e pragas em milharais

2.1.1. Ferrugem

A ferrugem é uma doença fúngica que afeta culturas de milharais. Causada pelo fungo *Puccinia polysora*, está entre uma das principais doenças foliares do milho e pode reduzir em mais de 50% o rendimento das lavouras. Isso ocorre

quando as condições ambientais são mais favoráveis ao patógeno, ou seja, combinam temperaturas entre 26°C e 30°C e umidade relativa do ar elevada e nenhuma forma de controle é adotada. (BASF BRASIL, 2024)

O nome ferrugem faz referência à aparência dos sintomas, caracterizados por pequenas pústulas circulares ou elípticas nas folhas, que lembram material oxidado. Essas pústulas contêm estruturas reprodutivas do fungo que liberam esporos que são dispersos pelo vento, propagando a doença pelo milharal. (CASELA; FERREIRA; PINTO, 2006)

Figura 1 - Folha de milho afetada pelo fungo *Puccinia polysora*



Fonte: CASELA; FERREIRA; PINTO, 2006

2.1.2. Cercosporiose

A Cercosporiose é causada pelo fungo *Cercospora zea-maydis* que comumente ataca as folhas e frutos em desenvolvimento dos milharais. Conforme Casela e Ferreira (2023), o fungo, presente nas plantações, libera esporos, produzidos através de mitose, no ar, possibilitando a infecção de novas plantas de milho, infectando inicialmente as folhas inferiores, os sítios primários, mas de forma precoce evoluindo para as folhas mais jovens na parte superior da planta.

As lesões apresentam coloração marrom, até que, sob condições de alta umidade relativa, há a formação de densa esporulação, que dá às lesões a coloração acinzentada, característica da doença. (CASELA; FERREIRA, 2003)

Figura 2 - Folha de milho afetada pela Cercosporiose



Fonte: CROP PROTECTION, 2019

2.2. Doenças e pragas em laranjeiras

2.2.1. Cancro Cítrico

O cancro cítrico, causado pela bactéria *Xanthomonas citri* subsp. *citri*, afeta todas as espécies e variedades de citros de importância comercial. Com origem na Ásia, onde ocorre de forma endêmica em todos os países produtores, foi constatado pela primeira vez no Brasil em 1957. (FUNDECITRUS)

Os sintomas tornam-se visíveis em folhas de duas a cinco semanas após a infecção. No início, formam-se pontos escurecidos, muitas vezes com amarelecimento ao redor, resultado da multiplicação da bactéria e encharcamento do tecido vegetal. Os sintomas evoluem para pústulas de coloração marrom-clara. O cancro cítrico não provoca a morte das árvores doentes. (FUNDECITRUS)

Figura 3 - Fruta Laranja afetada pela doença cancro cítrico.



fonte: FUNDECITRUS

2.2.2. Deficiência de nutrientes em laranjas

A deficiência de nutrientes em laranjas pode comprometer significativamente a qualidade e o rendimento das frutas. Quando o solo carece de nutrientes essenciais como nitrogênio, fósforo, potássio, magnésio e zinco, as laranjeiras tendem a apresentar crescimento lento, folhas amareladas e frutos menores e de menor qualidade. A falta de magnésio, por exemplo, pode causar clorose nas folhas, enquanto a deficiência de zinco prejudica a produção de clorofila, resultando em folhas deformadas e menor produtividade. O manejo adequado da adubação e a análise frequente do solo são essenciais para garantir a saúde das plantas e a boa produção de laranjas. (BUENO, N.; GASPAROTTO, L. 1999)

Figura 4 - Folhas de laranjas com deficiência em zinco.



Fonte: BUENO, N.; GASPAROTTO, L. 1999

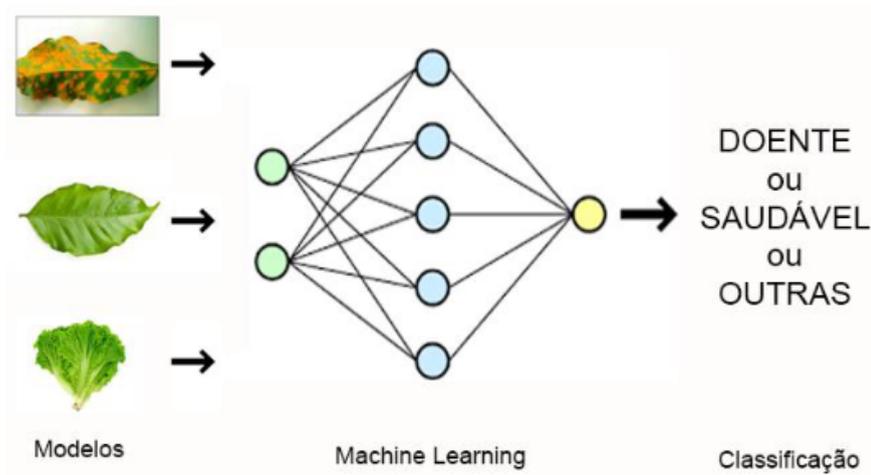
2.3. Aprendizado de máquina

Aprendizado de máquina (AM) é a ciência da programação de computadores de modo que eles possam aprender com dados.

“Alega-se que um programa de computador aprende pela experiência E em relação a algum tipo de tarefa T e alguma medida do desempenho P se o seu desempenho em T, conforme medido por P, melhora com a experiência E.” (MITCHELL, 1997)

Os diversos sistemas de aprendizado de máquina possuem características particulares e comuns que possibilitam sua classificação quanto à linguagem de descrição, modo, paradigma e forma de aprendizado utilizado.

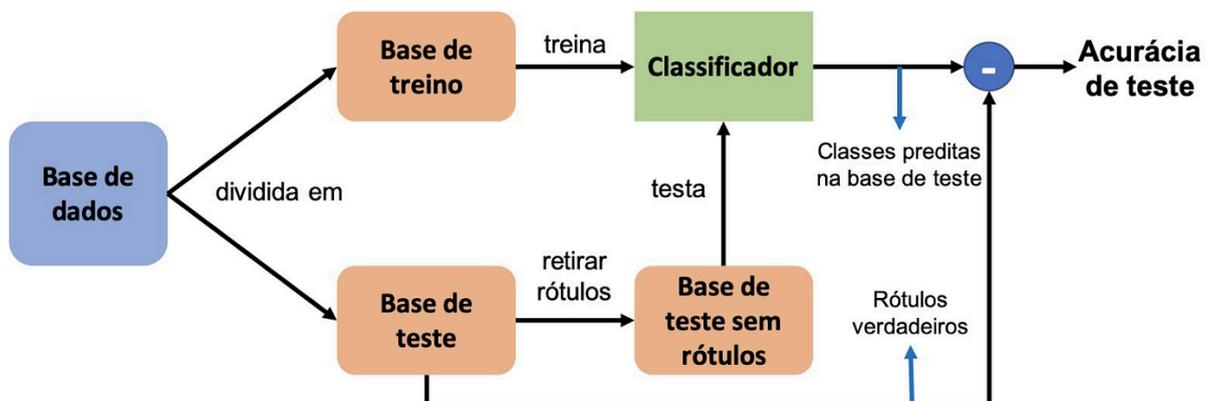
figura 5 - A hierarquia do aprendizado



font: FERREIRA, 2020

No ramo da aprendizagem de máquina supervisionada, os dados de entrada estão previamente classificados e são usados para a fase do treino da rede neuronal, recorrendo a um modelo, que procura reduzir o erro, corrigindo-se automaticamente, alterando os pesos na rede. Neste sistema, existem duas abordagens de aplicação diferentes, numa dividem-se os dados em dados de treino e dados de teste, ou outra em que se dividem em dados de treino, validação e teste. (BROWNLEE, 2016).

figura 6 - Modelo Genérico de AM

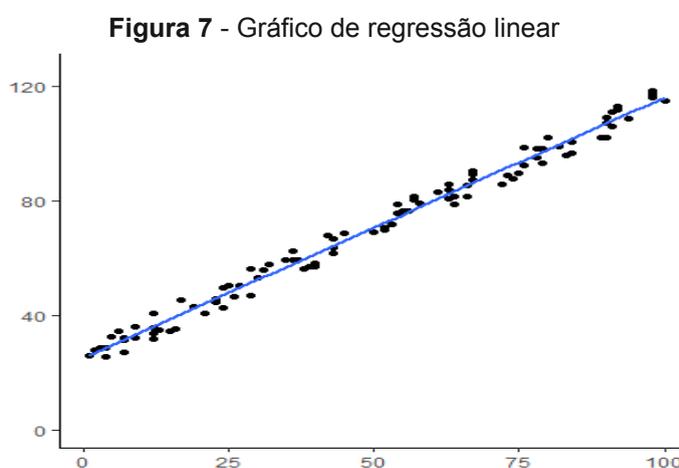


fonte: ESCOVADO, 2020

2.3.1 Regressão Linear

A regressão linear é um método estatístico utilizado para estimar o valor de uma variável com base no valor de outra. A variável que se deseja prever é denominada variável dependente, enquanto a variável usada para realizar essa previsão é chamada de variável independente. (IBM)

A regressão linear é o método mais comumente utilizado para análise preditiva.



Fonte: DAMÁSIO 2021

2.3.2. Coeficiente R-quadrado

O coeficiente R-quadrado mede a qualidade do ajuste de um modelo de regressão. Ele indica a proporção da variação total da variável dependente que é explicada pelas variáveis independentes no modelo. O valor de R-quadrado varia de 0 a 1: quanto mais próximo de 1, melhor o modelo explica os dados; um valor próximo de 0 significa que o modelo tem pouca capacidade explicativa. Em resumo, R-quadrado mostra o quão bem os dados se ajustam à linha de regressão.

Fórmula 1 - Fórmula do R-quadrado

$$R^2 = 1 - \frac{\text{Variância Residual}}{\text{Variância Total}}$$

Fonte: CÂNDIDO 2024

A variância residual é a soma dos quadrados dos resíduos (a diferença entre os valores observados e os valores previstos pelo modelo). Enquanto a variância total é a soma total dos quadrados (a variabilidade total dos dados em relação à média). (CÂNDIDO, 2024)

2.3.3 Overfitting

O overfitting, ou sobreajuste, é um comportamento indesejável em modelos de aprendizado de máquina que ocorre quando o modelo se ajusta demais aos dados de treinamento, dominando todos os padrões, incluindo ruído, mas não consegue generalizar para novos dados. (OGBEMI, 2023)

No gráfico, temos o recursos no eixo x. Em conjuntos de dados, recursos são dados que podem ser usados para prever um resultado. A variável de saída é o resultado com base nesses recursos. Os pontos azuis representam os pontos de dados onde os recursos determinam as variáveis de saída. No gráfico ótimo, o modelo tenta encontrar a tendência generalizada. Mas no gráfico overfitting, o modelo tenta dominar cada ponto de dados, resultando em uma curva assimétrica.

Figura 8 - Exemplo de modelo de regressão com overfitting



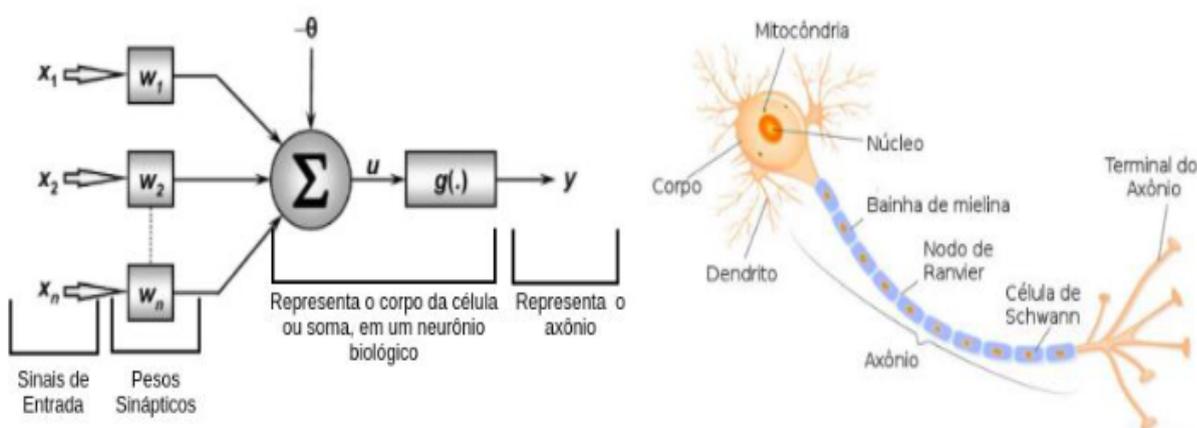
Fonte: OGBEMI, 2023

2.4. Redes Neurais

Redes neurais são modelos computacionais inspirados no funcionamento do cérebro humano, compostos por um grande número de unidades de processamento interconectadas, chamadas de neurônios artificiais.

Segundo Bento (2019), as redes neurais devem dispor de várias unidades de processamento, ou seja, os neurônios de uma rede neuronal. Característica importante é existirem pesos, que são coeficientes associados às ligações entre as unidades de processamento, sendo que o fator de aprendizagem está ligado ao ajuste destes mesmos pesos. Diferentemente do cérebro humano, o processamento é central, de forma linear e sequencial. Dentro do domínio das redes neuronais também é importante referir que existem diversas variantes, sendo as principais CNN (Convolutional Neural Networks), RNN (Recurrent Neural Networks) e DNN (Deep Neural Networks).

figura 9 - Redes Neurais



fonte: Bento, 2020

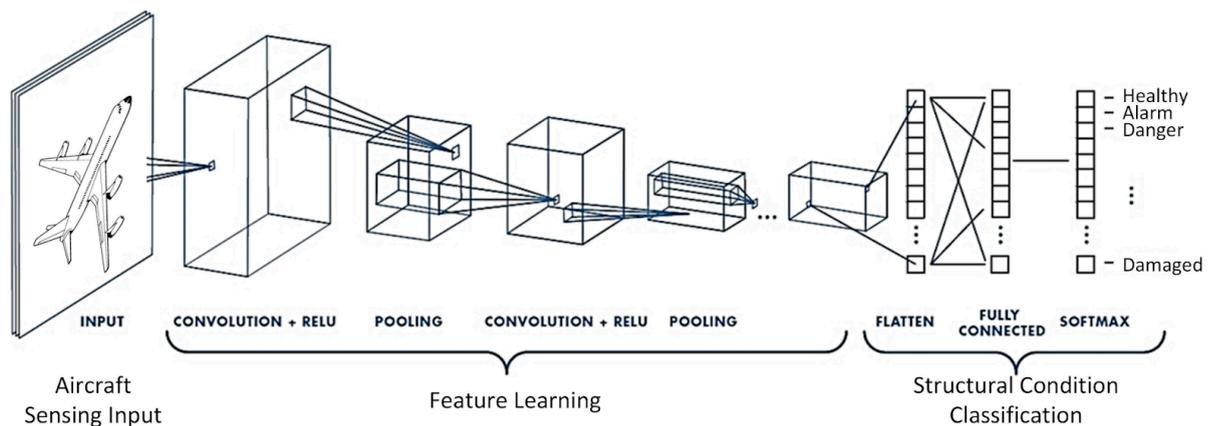
2.4.1 Redes Neurais Convolucionais

As CNNs são especialmente projetadas para processar dados de grade, como imagens. Elas consistem em camadas convolucionais que aplicam operações de convolução para extrair características espaciais locais das imagens, seguidas

por camadas de pooling para reduzir a dimensionalidade e camadas totalmente conectadas para realizar a classificação.

As CNNs são amplamente utilizadas em tarefas de visão computacional, como reconhecimento de imagens, detecção de objetos, segmentação de imagens, entre outros.

figura 10 - modelo de CNN convencional



fonte: (LeCun, Y., Bengio, Y., & Hinton, G, 2015)

As camadas convolucionais aplicam operações de convolução às imagens de entrada. A convolução é uma operação fundamental que preserva a relação espacial entre os pixels da imagem. Após as camadas convolucionais, as camadas de pooling são usadas para reduzir a dimensionalidade dos dados e extrair características mais relevantes. As camadas totalmente conectadas são responsáveis por realizar a classificação final. (GEEKSFORGEEKS, 2024)

2.4.2 Segmentação Semântica

A segmentação de imagens é um processo completo de análise de imagens que divide uma imagem digital em múltiplos segmentos e classifica as informações presentes em cada região.

As tarefas de segmentação semântica permitem que as máquinas diferenciam as várias classes de objetos e áreas de fundo em uma imagem. A segmentação de imagens e a geração de mapas de segmentação tornam-se

essenciais para treinar computadores a reconhecer contextos importantes em imagens digitais, como paisagens, retratos, imagens médicas, entre outras. (IBM)

Os modelos de segmentação semântica criam um mapa de segmentação de uma imagem de entrada. Um mapa de segmentação é, essencialmente, uma reconstrução da imagem original em que cada pixel foi codificado por sua classe semântica para criar máscaras de segmentação. Uma máscara de segmentação é apenas uma parte da imagem que foi diferenciada de outras regiões da imagem. (IBM)

Figura 11 - Exemplo de segmentação semântica, aplicação das máscaras.



Fonte: Zhang; Lipton; Li; Smola. 2021

2.5 Tecnologias

Uma framework pode ser vista como um conjunto de ferramentas e bibliotecas, e funciona como uma espécie de esqueleto de uma aplicação, permitindo desenvolver a aplicação através do uso das ferramentas e bibliotecas disponibilizadas na framework. Na área de IA, existem alguns frameworks, sendo os mais populares: TensorFlow, Keras.

2.6 Objetivos

O trabalho tem por objetivo geral a criação de uma plataforma móvel para gerenciamento de horta.

São objetivos específicos:

- I. O desenvolvimento de um modelo de Redes Neurais Convolucionais para diagnóstico de doenças em plantas;
- II. O desenvolvimento de um modelo de Aprendizado de Máquina para gerenciamento e monitoramento da horta;

- III. Avaliar a Eficiência da Plataforma: Realizar testes piloto com agricultores reais para avaliar a eficácia da plataforma Botany;

3.METODOLOGIA

O projeto Botany adotou uma abordagem metodológica de engenharia combinada de pesquisa exploratória e experimental. A fase inicial de pesquisa exploratória se concentrou em entender as necessidades dos agricultores e explorar as melhores práticas agrícolas por meio de análise de notícias, artigos e conceitos técnicos de desenvolvimento de software e uso de tecnologias digitais e IA na agricultura. Este levantamento ajudou a identificar percepções, barreiras e facilitadores para a adoção de tecnologias digitais, IA na agricultura e fundamentar o desenvolvimento da plataforma.

Com base nos dados obtidos na fase exploratória, a pesquisa avançou para a fase experimental, onde foram desenvolvidos e testados os componentes essenciais da plataforma. Inicialmente, foi realizado o design e prototipagem da interface do usuário, definindo requisitos funcionais e não funcionais que guiaram o desenvolvimento.

A etapa subsequente envolveu o desenvolvimento de modelos de inteligência artificial utilizando a linguagem de programação Python e o framework python: Tensorflow, incluindo redes neurais convolucionais (CNNs) para diagnóstico de doenças em plantas utilizando conjuntos de dados de imagens de plantas saudáveis e doentes, e modelo de análise preditiva para recomendações agronômicas utilizando regressão linear. O conjunto de dados de imagens de plantas saudáveis foram consumidos da plataforma Kaggle, uma plataforma de competição de ciência de dados e comunidade online para cientistas de dados e profissionais de aprendizado de máquina da Google LLC.

Inicialmente, o modelo de CNN foi treinado para identificar doenças como common rust e pragas em milhos, bem como cancro cítrico e deficiência de nutrientes cítricos em laranjas. A escolha dessas doenças e das culturas de milho e laranja reflete as preferências dos autores do projeto para a fase inicial de criação e treinamento do modelo de diagnóstico de doenças em plantas. O mesmo princípio é aplicado ao desenvolvimento do modelo de análise preditiva, onde foi utilizadas

informações específicas sobre as características do milho e da laranja para orientar o início da criação e treinamento desse modelo.

Após o desenvolvimento dos modelos de inteligência artificial, o projeto avançou para a implementação do software, com foco em áreas cruciais para a operação da plataforma. O backend, desenvolvido em GOLANG, gerencia a lógica da aplicação e os requisitos funcionais e não funcionais da aplicação. A interface de programação de aplicações (API) conectará o backend e frontend, que será desenvolvido em JavaScript/TypeScript utilizando a biblioteca React Native para garantir uma interface visual integrada e responsiva. O banco de dados, por sua vez, armazenará as informações dos usuários, enquanto um sistema de cache será implementado para otimizar o acesso rápido a dados frequentemente utilizados. Após a conclusão do desenvolvimento, os modelos de IA e o servidor da aplicação (backend e banco de dados) serão hospedados no serviço Amazon Web Services (AWS).

Após a conclusão do desenvolvimento do projeto, o próximo passo é avançar para a fase de testes com usuários. Nessa etapa, o objetivo é avaliar a funcionalidade, a usabilidade e a eficácia das soluções implementadas, garantindo que o sistema atenda às necessidades e expectativas dos usuários finais. Os feedbacks coletados serão fundamentais para realizar ajustes e aprimorar o projeto antes de sua versão final.

Os recursos necessários incluem computadores, laptops e smartphones para desenvolvimento e teste. Custos financeiros para serviços de hospedagem na AWS são projetados para após um ano da finalização do projeto.

4.RESULTADOS DO PROJETO

Após o treinamento inicial dos modelos de Rede Neural Convolutacional (CNN) para a identificação de doenças em plantas, como common rust e pragas em milhos, além de cancro cítrico e deficiência de nutrientes em laranjas, foi identificado um problema de overfitting. O modelo ajustou-se excessivamente aos dados de treinamento, resultando em uma capacidade reduzida de generalização e desempenho insatisfatório na fase de teste. Esse problema foi atribuído ao número insuficiente de dados de treinamento.

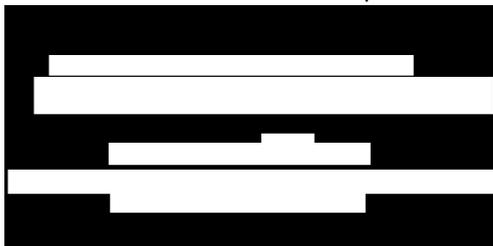
Figura 12 - Foto de uma planta de milho afetada por pragas.



Fonte: autores

Para abordar essa questão, o modelo CNN foi refeito com um aumento significativo na quantidade de dados de treinamento. O novo modelo está atualmente em fase de treinamento e os resultados preliminares são promissores. A ampliação do conjunto de dados tem contribuído para uma melhoria na capacidade de generalização do modelo, sugerindo uma redução do overfitting e uma potencial melhoria na precisão da identificação de doenças.

Figura 13 - Máscara referente a FIGURA.1 utilizada para treinamento da CNN.



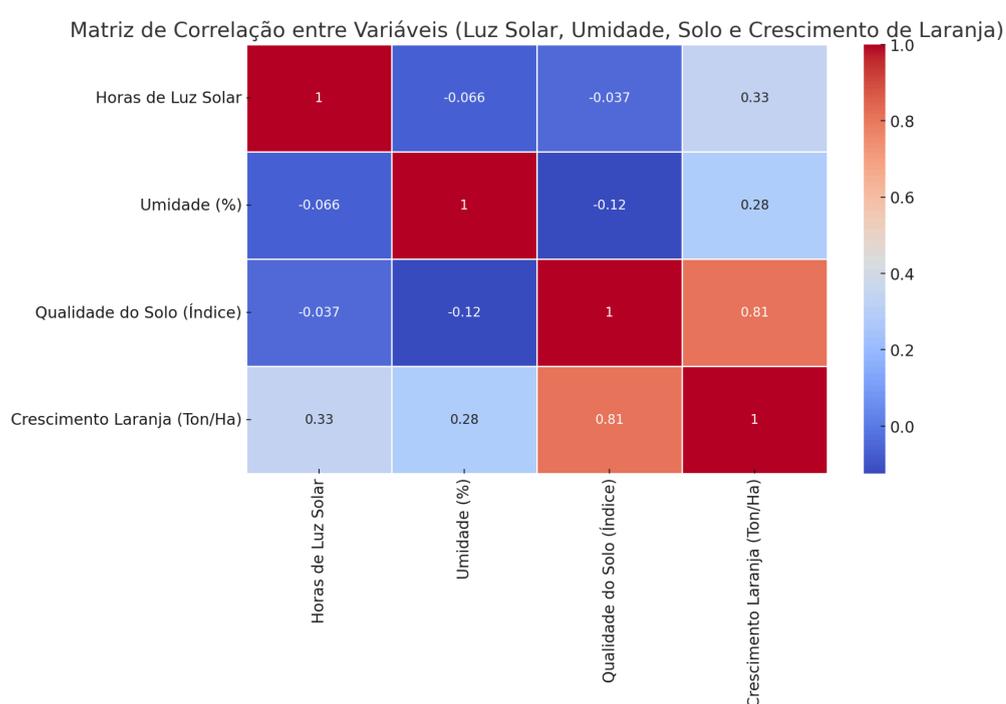
Fonte: autores

O modelo de análise preditiva desenvolvido utiliza técnicas de regressão para fornecer recomendações personalizadas aos usuários com base em dados climáticos, localização, fatores solares, umidade e características das plantas. Inicialmente, o foco está nas culturas de laranja e milho. Para gerar recomendações, o modelo integra APIs externas que fornecem dados sobre as condições climáticas e ambientais. No entanto, houve alguns problemas na integração com essas APIs, resultando em dados inconsistentes e, às vezes, incompletos. Esses problemas têm afetado a precisão das previsões e recomendações.

Os resultados preliminares indicam que o modelo é capaz de fazer previsões, mas a precisão ainda não é ideal. A correlação entre os fatores climáticos e as necessidades das plantas nem sempre está clara, e há casos em que as recomendações não correspondem às condições reais observadas.

Durante os testes iniciais com dados históricos e simulados, o modelo apresentou algumas inconsistências. Em particular, as recomendações para a gestão de umidade e fatores solares mostraram-se imprecisas em certas condições. Além disso, houve dificuldades em ajustar o modelo para refletir as variabilidades locais de forma adequada. Após ajuste do modelo e novos dados coletados, o modelo apresentou resultados positivos.

Figura 14 - Matriz de Correlação entre variáveis (luz solar, umidade, solo) e o crescimento da laranjeira



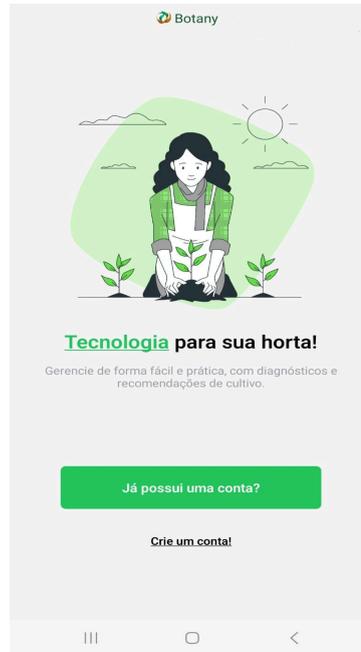
fonte: autores

A integração das APIs externas têm mostrado potencial, mas os erros na coleta e processamento dos dados precisam ser corrigidos para melhorar a confiabilidade do modelo. A análise dos resultados e o feedback dos usuários serão fundamentais para identificar e resolver os problemas. A correção dos dados inconsistentes e a recalibração do modelo são prioridades para garantir que o sistema ofereça recomendações úteis e precisas.

O desenvolvimento do backend, frontend e do design está avançando conforme o planejado, com ambos os componentes mostrando um desempenho promissor. A integração entre o backend e o frontend está funcionando bem, e as fases de teste e ajustes futuros ajudarão a garantir uma plataforma robusta e

eficiente. Com a conclusão desses estágios e a implementação dos testes finais, o projeto estará bem posicionado para oferecer uma solução eficaz e confiável para o manejo de hortas e diagnósticos de plantas.

Figura 15 - Protótipo do aplicativo do projeto democratização tecnológica na agricultura - "Tela inicial"



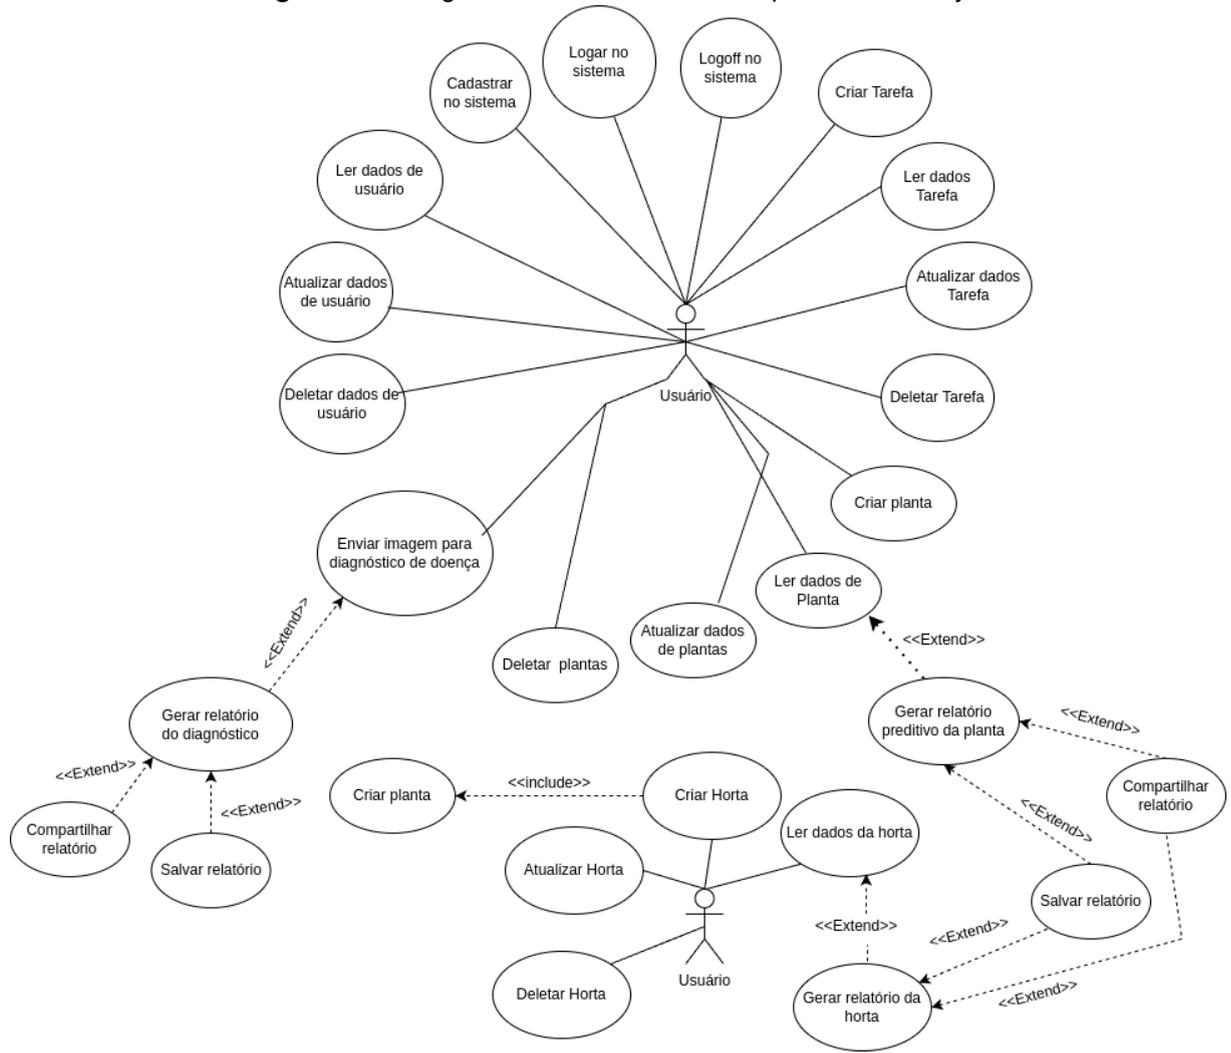
fonte: autores

Figura 16 - Protótipo do aplicativo do projeto democratização tecnológica na agricultura - "Tela Home"



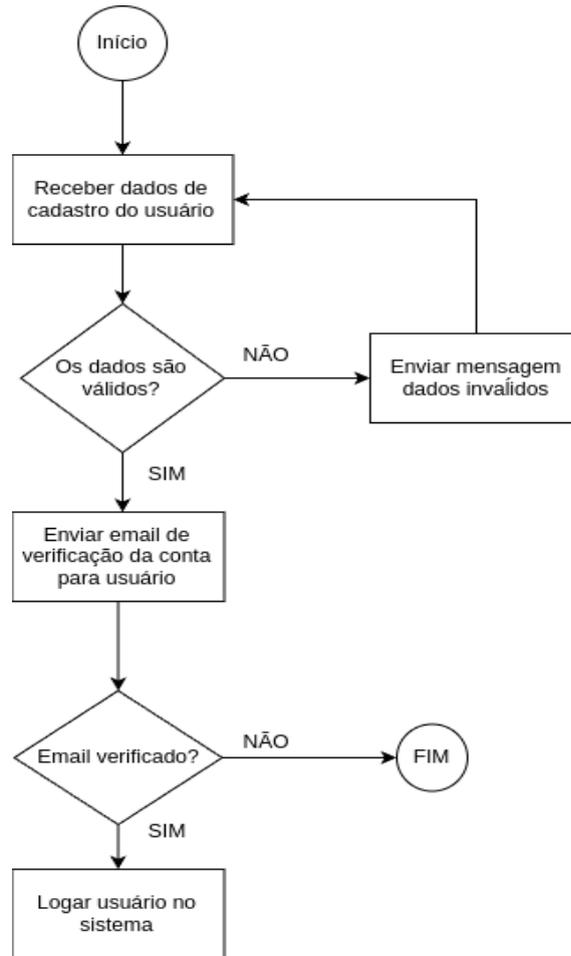
Fonte: autores

Figura 17 - Diagrama de Caso de uso do aplicativo “Botany”



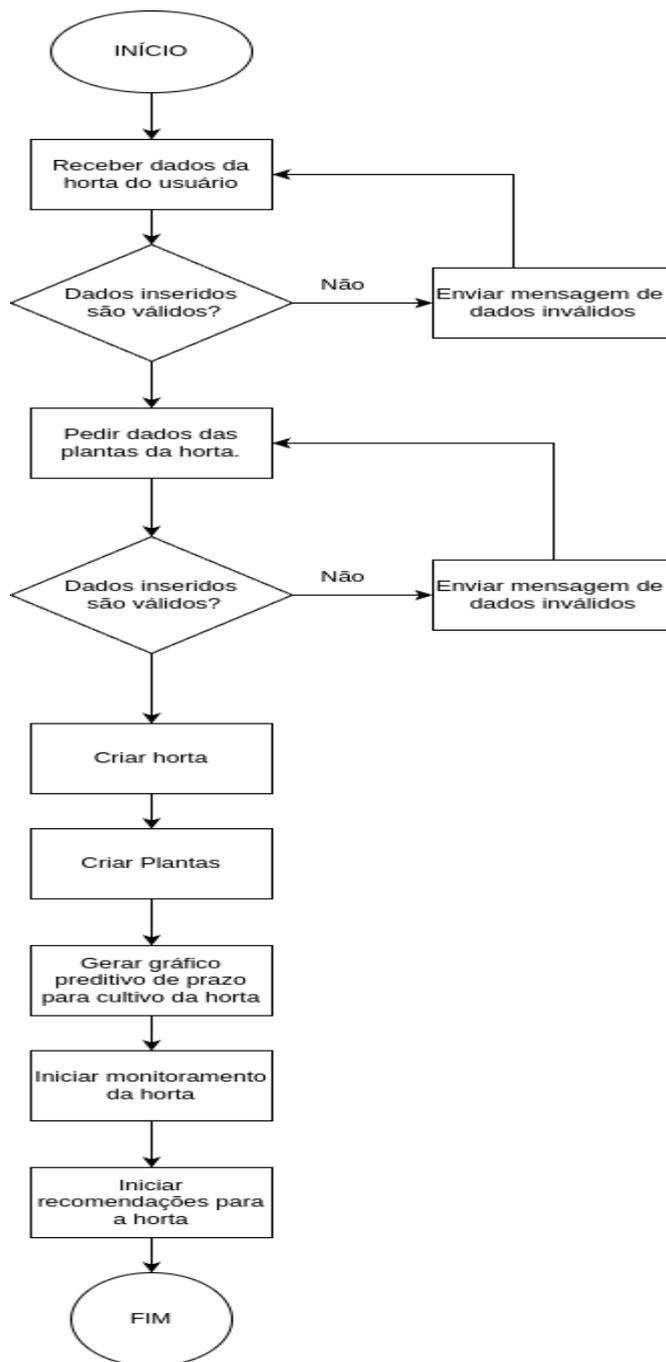
Fonte: autores

Figura 18 - Fluxo de cadastro no aplicativo Botany.



Fonte: autores

Figura 19 - Fluxo de criação de horta no aplicativo Botany



Fonte: autores

5.CONCLUSÕES

O projeto Botany demonstrou avanços significativos na criação de uma plataforma móvel integrada com inteligência artificial, alinhando-se aos objetivos estabelecidos. Os modelos de análise preditiva, desenvolvidos para prever condições de cultivo, mostraram progresso considerável, mas enfrentaram desafios com dados inconsistentes e ajustes nas previsões. A integração com APIs externas

forneceu insights valiosos, no entanto, a precisão das recomendações ainda precisa ser validada em condições reais. Por outro lado, a implementação das redes neurais convolucionais (CNNs) para diagnóstico de doenças em plantas progrediu bem após a ampliação do conjunto de dados, superando problemas iniciais de overfitting. Embora o novo modelo apresenta resultados promissores, a capacidade de generalização e a precisão final ainda estão em fase de aprimoramento.

Apesar dos desafios encontrados, os resultados obtidos estão em linha com os objetivos gerais de melhorar a eficiência e a sustentabilidade no manejo de hortas. A plataforma está avançando para uma fase em que testes adicionais e ajustes são essenciais para garantir que as soluções propostas atendam plenamente às necessidades dos usuários. O próximo passo crucial será a validação dos modelos e a coleta de feedback, o que permitirá a otimização contínua da plataforma e assegurará que as recomendações sejam úteis e precisas, promovendo um impacto positivo no manejo agrícola.

Referências Bibliográficas

AGRO ESTADÃO. Agricultura digital: conheça os avanços e os desafios no Brasil. 2023. Disponível em: <https://agro.estadao.com.br/summit-agro/agricultura-digital-conheca-os-avancos-e-os-desafios-no-brasil>. Acesso em: 19 mar. 2024.

BENTO, Daniel. Detecção e identificação de doenças em plantas utilizando Deep Learning. 2019. Dissertação (Engenharia Informática) – ISEP - DM, 2019. Disponível em: <http://hdl.handle.net/10400.22/15480>. Acesso em: 16 mar. 2024.

BROWNLEE, Jason. Master Machine Learning Algorithms: Discover how They Work and Implement Them from Scratch. [S.l.]: [s.n.], 2016.

BUENO, N.; GASPAROTTO, L. Sintomas de deficiências nutricionais em citros. Manaus: Embrapa Amazônia Ocidental, 1999. 19 p. (Embrapa Amazônia Ocidental. Circular Técnica, 6).

CASELA, C. R.; FERREIRA, A. S.; PINTO, N. F. J. A. Doenças na cultura do milho. Embrapa, Circular Técnica, n. 83, 2006.

CASELA, Carlos; FERREIRA, Alexandre. A cercosporiose na cultura do milho. 2003. Disponível em: https://ainfo.cnptia.embrapa.br/digital/bitstream/CNPMS/16175/1/Circ_24.pdf . Acesso em: 28 mar. 2024.

CROPLIFE BRASIL. Agricultura moderna: conheça as tecnologias que fazem parte do campo. 2023. Disponível em: <https://croplifebrasil.org/noticias/agricultura-moderna-conheca-as-tecnologias-que-fazem-parte-do-campo-croplife-brasil/> . Acesso em: 20 mar. 2024.

CROP PROTECTION NETWORK. Folha de milho afetada pela cercosporiose. 2019. Disponível em: <https://cropprotectionnetwork.org/encyclopedia/gray-leaf-spot-of-corn> . Acesso em: 28 mar. 2024.

ESCOVEDO, Tatiana. Machine Learning: Conceitos e Modelos — Parte I: Aprendizado Supervisionado. 2020. Disponível em: <https://tatianaesc.medium.com/machine-learning-conceitos-e-modelos-f0373bf4f445> . Acesso em: 20 mar. 2024.

FERREIRA, L. Aplicação de técnicas de machine learning na detecção de presença de doenças na folha do cafeeiro. 2020. 47 f. Dissertação (Mestrado em Produção e Gestão Agroindustrial) – Universidade de Uberaba, Uberaba-MG, 2020. Disponível em: <http://dspace.uniube.br:8080/jspui/handle/123456789/1672> . Acesso em: 14 mar. 2024.

FUNDECITRUS. Cancro cítrico. Disponível em: <https://www.fundecitrus.com.br/doencas/cancro>. Acesso em: 18 maio 2024.

GEEKSFORGEEEKS. Introduction to Convolution Neural Network. 2024. Disponível em: <https://www.geeksforgeeks.org/introduction-convolution-neural-network/> . Acesso em: 18 jun. 2024.

IBM. O que é regressão linear? Disponível em: <https://www.ibm.com/br-pt/topics/linear-regression> . Acesso em: 02 jun. 2024.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. Nature, v. 521, n. 7553, p. 436-444, 2015.

MITCHELL, T. M. Machine Learning. New York: McGraw-Hill Education, 1997. ISBN 0070428077.

OGBEMI, Mene-Ejegi. What is Overfitting in Machine Learning? 2023. Disponível em: <https://www.freecodecamp.org/news/what-is-overfitting-machine-learning/> . Acesso em: 28 mar. 2024.

SOBRAL, Lafayette Franco; ANJOS, Joézio Luiz dos; MAGALHÃES, Antonia Fonseca de Jesus; SOUZA, Luiz Francisco da Silva; BARRETO, Antonio Carlos; SILVA, José Unaldo Barbosa. Aspecto citros. 2007. p. 30. Disponível em: http://www.cpatc.embrapa.br/publicacoes_2007/aspectoscitros/cap_4.pdf . Acesso em: 12 jun. 2024.

ZHANG, Aston; LIPTON, Zachary C.; LI, Mu; SMOLA, Alexander J. Dive into Deep Learning. 2021. Disponível em: https://pt.d2l.ai/chapter_computer-vision/semantic-segmentation-and-dataset.html. Acesso em: 15 jun. 2024.