

Caracterização de PANC Orientada Por Aprendizagem Profunda

Characterization of PANC Guided by Deep Learning

Davi Torres Araújo	{ davi.araujo8@fatec.sp.gov.br }
João Arthur Almeida Gomes	{ joao.gomes50@fatec.sp.gov.br }
Matheus Felipe Gomes da Silva	{ matheus.silva457@fatec.sp.gov.br }
Frederico Barbosa Muniz	{ frederico.muniz@fatec.sp.gov.br }
Thissiany Beatriz Almeida	{ thissiany.almeida@fatec.sp.gov.br }

RESUMO

Este estudo teve como objetivo caracterizar Plantas Alimentícias Não Convencionais (PANC) utilizando técnicas de Aprendizagem Profunda para promover sua aceitação na dieta brasileira. Um dos focos principais foi o desenvolvimento de um aplicativo que utiliza Inteligência Artificial (IA) para identificar e caracterizar essas plantas. Foram coletadas 1.354 imagens de três PANC: inhame, ora-pro-nobis e hibisco. A IA obteve acurácia entre 91,16% e 99,91% na classificação. O aplicativo fornece ainda a identificação das PANC e oferece receitas e orientações de uso. A pesquisa destacou a importância de aumentar o volume de dados para melhorar a eficácia do modelo de IA, possibilitando futuramente a inclusão de mais espécies de PANC. O projeto reforça a importância das PANC na alimentação e a necessidade de conscientizar a população sobre seus benefícios, oferecendo uma plataforma acessível para promover uma dieta mais diversificada e saudável.

PALAVRAS-CHAVE: PANC; Inteligência Artificial; Caracterização; Alimentação.

ABSTRACT

This study aimed to characterize Non-Conventional Edible Plants (PANC) using Deep Learning techniques to promote their acceptance in the Brazilian diet. One of the main focuses was the development of an application that utilizes Artificial Intelligence (AI) to identify and characterize these plants. A total of 1,354 images of three PANC species—yam, ora-pro-nobis, and hibiscus—were collected. The AI achieved accuracy rates between 91.16% and 99.91% in classification. The application also provides PANC identification and offers recipes and usage guidelines. The research emphasized the importance of increasing the data volume to enhance the AI model's effectiveness, enabling the inclusion of more PANC species in the future. The project underscores the significance of PANC in nutrition and the need to raise public awareness about their benefits, offering an accessible platform to promote a more diverse and healthy diet.

KEYWORDS: PANC; Artificial Intelligence; Characterization; Nutrition.

INTRODUÇÃO

O projeto Osiris, que visa promover o conhecimento e o consumo de PANC, está intrinsecamente ligado ao Objetivo de Desenvolvimento Sustentável 2 (ODS 2) da Agenda 2030 da ONU. O ODS 2 busca acabar com a fome, alcançar a segurança alimentar e melhorar a nutrição, promovendo a agricultura sustentável. O termo PANC foi cunhado por Valdely Ferreira Kinupp em 2007, referindo-se a plantas alimentícias não convencionais (Casemiro; Vendrami, 2021). Essas são hortaliças, frutos ou verduras incomuns no cotidiano, com fácil acesso e cultivo, representam uma opção de baixo custo para diversificar a alimentação. No Brasil, existem aproximadamente 3 mil espécies documentadas de PANC, mas a falta de divulgação sobre seus benefícios limita seu reconhecimento (Liberalesso, 2019). Nesse sentido, o projeto propõe um sistema para identificar e caracterizar PANC, oferecendo informações sobre suas características, cultivo e receitas culinárias.

A difícil adesão pela população pode ser explicada pela capacidade dos seres humanos de percepção em relação a plantas. A grande maioria da população não tem conhecimento de plantas popularmente denominadas “daninhas” ou mato, que podem enriquecer a alimentação de um ponto

de vista nutricional (Lara *et al.*, 2019). Normalmente as percebemos de forma menos nítida do que os animais, ou nem as percebemos (Simonetti; Simonetti; Fariña, 2021). Essa incapacidade de percepção é definida como "cegueira botânica" e consiste na incapacidade de reconhecer a importância das plantas na biosfera e no cotidiano, incluindo os aspectos estéticos e biológicos exclusivos das plantas, além da ideia de que as plantas sejam seres inferiores aos animais, portanto, não merecedoras de atenção equivalente. (Wandersee; Schussler, 1999)

O projeto aborda o estudo de três PANC: o inhame, a ora-pro-nóbis e o hibisco. O inhame (Fotografia 1a), caracterizado por sua pele rugosa e polpa branca, é uma PANC de ambientes úmidos, com potencial tanto para consumo próprio quanto para comercialização (Damo *et al.*, 2020). A ora-pro-nóbis (Fotografia 1b), uma planta resistente e de fácil cultivo, é consumida na alimentação e utilizada na medicina, destacando-se pelo seu alto valor nutricional (Almeida *et al.*, 2014). Por fim, o hibisco (Fotografia 1c) tem suas flores e sementes utilizadas na produção de bebidas e alimentos, sendo regulamentado pela Anvisa para consumo em chás e como fonte de proteína (Maciel *et al.*, 2012).


Fotografia 1 – Imagens das PANC



(a) Inhame



(b) Ora-pro-nóbis



(c) Hibisco

Fonte: Autoria Própria (2024)

Para compreender o cenário PANC em Registro, São Paulo, foi realizada uma pesquisa de campo com nove participantes, envolvendo feirantes, produtores e restaurantes. A coleta de dados, feita em outubro de 2023, investigando o conhecimento popular, uso e comércio dessas plantas. A pesquisa mostrou que, apesar da maioria dos entrevistados conhecerem as plantas, menos da metade sabia o que são PANC, destacando a necessidade de mais conscientização sobre seu valor alimentar e sustentável. Os restaurantes, que apresentaram maior conhecimento sobre PANC, demonstram mais interesse em incorporá-las devido ao foco na diversificação de cardápios, o que aponta uma oportunidade para outros setores expandirem seus horizontes e promoverem o uso sustentável das PANC.

Tendo em vista o cenário atual das PANC no Brasil, a proposta desse projeto é auxiliar na identificação e caracterização das PANC a fim de expandir o conhecimento relacionado a elas, visando promover uma maior aceitação e inclusão desses alimentos no cotidiano, a fim de oferecer uma alternativa alimentar. A ideia de apresentar o máximo de informação possível sobre as PANC é fornecer estímulo visual, dados técnicos, científicos e tradicionais, experiências pessoais, e motivação gastronômica para incentivar seu consumo por meio da criação de receitas que utilizem esses alimentos

OBJETIVO

O objetivo deste projeto consiste em desenvolver uma Inteligência Artificial (IA), junto a um aplicativo móvel, que visa auxiliar no processo de identificação e caracterização das PANC, por meio da prospecção de informações das PANC, compartilhamento de receitas que utilizam PANC e incentivo ao consumo das PANC. Deste modo, tornam o projeto um meio para a inserção dessas plantas no cotidiano da população.

ESTADO DA ARTE

O processo de caracterização de plantas, embora essencial, pode ser desafiador devido à grande variação genética entre as espécies, especialmente quando se trata de PANC. Além disso, as técnicas de análise podem ser complexas e custosas, limitando sua aplicação em algumas áreas de pesquisa. Com o avanço da tecnologia, a aprendizagem profunda surge como uma alternativa promissora para a identificação de elementos por meio de imagens.

Um estudo realizado por (Pinto, 2021) propõe a classificação qualitativa de imagens de batata-doce brasileira roxa com base em técnicas de aprendizagem profunda. Utilizando uma Rede Convolucional (CNN), o estudo alcançou uma acurácia de 90,14%, demonstrando eficácia no propósito. No entanto, o projeto não foi implementado em produção e se limitou à análise de apenas uma espécie de batata-doce.

Outro trabalho, realizado por (BATISTA *et al.*, 2023), focou na identificação de feijão-caupi através do processamento de imagens digitais de sementes. Utilizando técnicas de inteligência artificial, o estudo identificou que os algoritmos Perceptron Multicamadas (MLP) e Máquina de Vetores de Suporte (SVM) apresentaram os melhores resultados. Apesar de contribuir tanto academicamente quanto praticamente, o trabalho foi exploratório e não apresentou uma solução final completa.

(Marques Junior, 2019) abordou a eliminação de plantas daninhas utilizando visão computacional e IA. Seu estudo analisou o desempenho de quatro arquiteturas de redes neurais convolucionais na classificação de cinco espécies de plantas daninhas. A arquitetura InceptionV3 apresentou o melhor desempenho, com 88,50% de exatidão na classificação. Assim como os trabalhos anteriores, o projeto de Marques foi exploratório e não resultou na integração dos métodos de análise de imagens em um software de produção.

Embora todos os projetos utilizem técnicas de aprendizagem de máquina para a caracterização de plantas, cada um apresenta suas particularidades. Enquanto os projetos de Pinto e Batista se assemelham no uso de CNNs, o projeto de Marques apresenta uma maior variedade de espécies botânicas em sua base de dados. Por sua vez, este projeto diferencia-se ao apresentar um software como solução, buscando uma maior diversidade na identificação de várias espécies, especialmente as PANC, marginalizadas pela falta de conhecimento da população.

METODOLOGIA

A IA proposta neste projeto visa a caracterização das 3 PANC objetos de estudo. Deste modo, poderemos avaliar a eficácia da IA no processo de caracterização das PANC, de modo que ela possa se tornar um meio para a inserção dessas plantas na alimentação. O aplicativo móvel, visa ser construído para ser uma via de acesso ao processo de caracterização, retirando a IA de um escopo de pesquisadores e ampliando o seu uso para a população.

O hardware, utilizado para a etapa de treinamento da IA, utiliza um processador AMD Ryzen 5 3400G com quatro núcleos e oito threads, 8 GB de memória RAM DDR4 com frequência de

2666 MHz, um SSD SATA de 240 GB, placa de vídeo Radeon RX 570 Series 4 GB de memória GDDR5 e tecnologia de 14 nanômetros. Esta configuração permitiu que o treinamento dos modelos fosse realizado em tempo viável, permitindo um melhor refinamento das variáveis de entrada e aperfeiçoamento da IA.

A IA foi desenvolvida utilizando a biblioteca de Aprendizado de Máquina Tensorflow Keras, junto ao Direct Machine Learning, uma API de baixo nível para Aprendizado de Máquina e a arquitetura Visual Geometry Group com dezesseis camadas (VGG16). Esta escolha tecnológica proporcionou uma base sólida para a construção de modelos de Aprendizado Profundo (Islam *et al.*, 2019). A construção da IA envolveu a aplicação de técnicas avançadas de Aprendizado Profundo, como Redes Neurais Convolucionais (CNN) e Redes Neurais Recorrentes (RNN), garantindo uma abordagem robusta e eficaz na análise e interpretação dos dados relacionados às plantas.

Para atender ao processo de treinamento da IA, fornecemos uma base de dados composta por imagens das três PANC objetos de estudo. Foram coletadas 1354 imagens no total, divididas entre às três classes: 701 de inhame, 380 de ora-pro-nóbis e 273 de hibisco. O método utilizado para dividir a base entre treinamento e validação foi o *holdout* estratificado, na proporção de 20% para validação e o restante para treinamento, assegurando que a amostragem aleatória fosse feita de maneira a garantir que cada classe fosse adequadamente representada tanto no conjunto de treinamento quanto no de validação.

A função *Softmax* foi utilizada no final para converter as saídas brutas do modelo em probabilidades compreensíveis para cada classe, transformando um vetor de números em uma distribuição de probabilidade, onde a soma dos valores será sempre 1. Dessa forma, facilita a interpretação dos resultados e permite que o modelo atribua uma probabilidade a cada classe que estava no treinamento. Essa função pode ser representada pela Equação (1).

$$u = \sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (1)$$

Os parâmetros recebidos são as saídas da camada anterior do modelo, e a equação retorna as probabilidades relativas entre as classes. A classe com a maior probabilidade será a predição final. Portanto, a função *Softmax* influencia diretamente qual classe é escolhida pelo modelo, tornando suas saídas fáceis de interpretar.

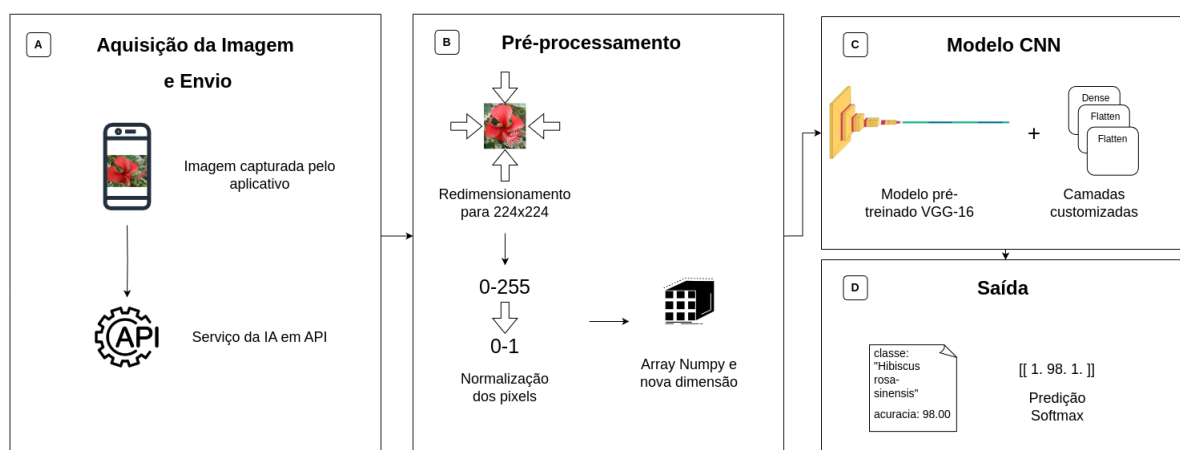
Para a utilização da IA e da sua capacidade de caracterização, faz-se necessário que o usuário a acesse através do aplicativo móvel. O processo percorrido pela imagem fornecida para o sistema, até o resultado proveniente da análise pode ser descrita pelo Fluxograma 1, passando pelos seguintes passos:

- a) **Captura da Imagem e Envio para o Serviço de IA.** O processo começa quando o usuário captura uma imagem da planta utilizando o aplicativo. Essa imagem é então enviada para uma API, responsável por salvar os dados da requisição no banco e acionar o serviço de caracterização. Esse serviço é responsável por receber a imagem e encaminhá-la para a etapa de pré-processamento e classificação. O papel da API é facilitar a comunicação entre o aplicativo e o modelo de IA.
- b) **Pré-processamento da Imagem.** O pré-processamento submete a imagem a uma série de transformações necessárias para prepará-la para a rede neural. A primeira sendo o redimensionamento, onde a imagem é redimensionada para 224x224 pixels, sendo o tamanho esperado pelo modelo da CNN que será utilizado para a classificação. Em seguida, ocorre a normalização dos pixels, onde os valores são ajustados da faixa de 0–255 para uma escala entre 0 e 1, o que facilita o processamento pela rede neural e melhora

a eficiência computacional. Subsequentemente, a imagem é transformada em um vetor NumPy, que é a forma de dados usada pelas bibliotecas de Aprendizado de Máquina. Além disso, uma nova dimensão é adicionada ao vetor, pois o modelo espera um lote de imagens, mesmo que seja apenas uma imagem por análise.

- c) **Classificação com o Modelo de CNN.** Depois que a imagem é pré-processada, ela é enviada para o modelo de CNN. No caso, o modelo utilizado é uma VGG16, que já foi treinada com milhões de imagens, fornecendo uma base poderosa para identificar características visuais em novas imagens. Este modelo foi modificado com camadas personalizadas para ajustá-lo especificamente à tarefa de classificação de PANC. As camadas personalizadas foram adicionadas no topo da arquitetura VGG16 e são responsáveis por adaptar o modelo às três classes específicas deste projeto.
- d) **Geração do Resultado.** Após a imagem passar pelo modelo CNN, o resultado é gerado. A rede neural produz probabilidades associadas a cada uma das classes de plantas. Esse resultado passa pela função *Softmax*, que converte as saídas em probabilidades compreensíveis. O modelo seleciona a classe com a maior probabilidade como a previsão final. A resposta final é então retornada em formato JSON, contendo a classe prevista e a acurácia associada à previsão.

Fluxograma 1 – Fluxograma do processo de caracterização



Fonte: Autoria Própria (2024)

O uso da aplicação móvel visa essencialmente disponibilizar um meio para ser viável que a população tenha acesso à funcionalidade de caracterização das PANC de forma fácil e prática, visando o objetivo de disseminar o conhecimento envolto delas, e assim, promovendo a aderência dessa alternativa alimentar. Além disso, identifica-se necessária a aplicação para que os recursos da IA esteja disponível para que pesquisadores e botânicos possam utilizá-la em situações de campo.

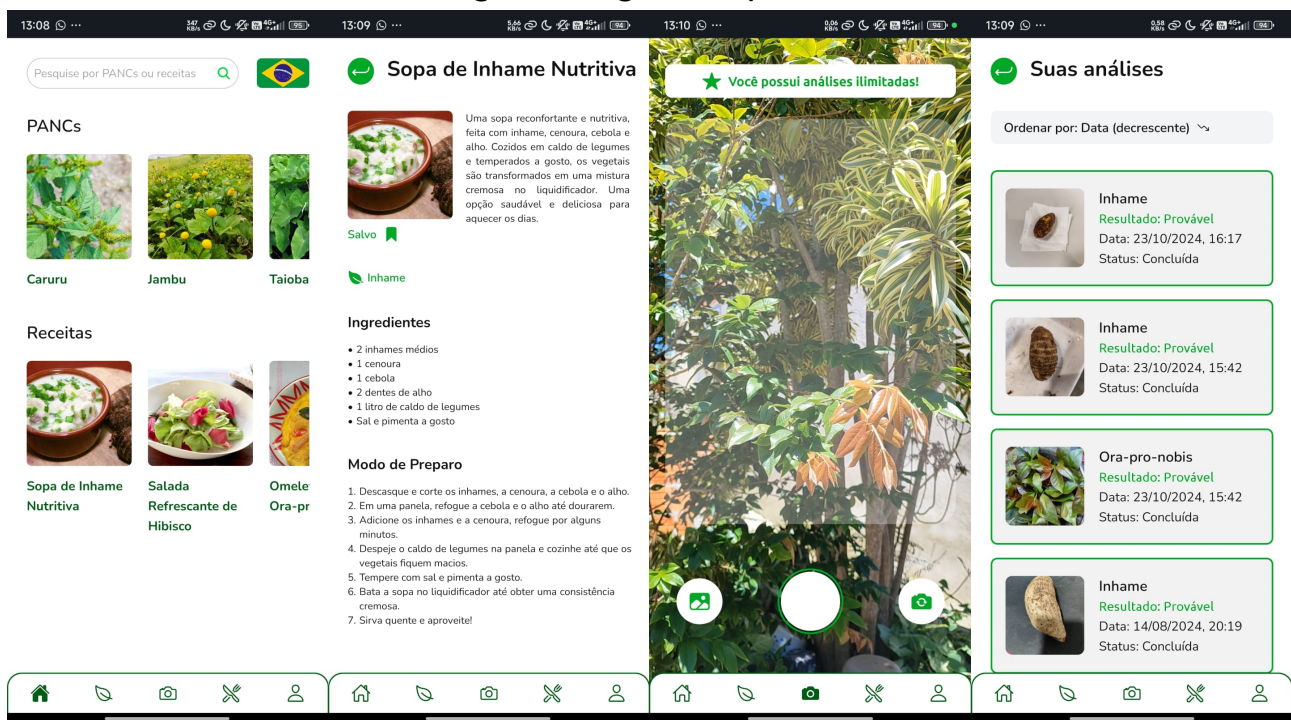
Para este projeto, foi desenvolvida uma API, a qual permite que o aplicativo envie solicitações para recuperar informações, como dados de usuário, conteúdo ou atualizações, e permite que o aplicativo envie dados para serem armazenados ou processados no servidor. A API, construída em Spring Boot 3.2.4, desempenha um papel vital na segurança, autenticação e autorização, garantindo que apenas solicitações autorizadas sejam atendidas. Além disso, a integração com o banco de dados não-relacional MongoDB é crucial para o armazenamento persistente de informações, permitindo que o aplicativo acesse e atualize dados de maneira eficiente.

Ao acessar o aplicativo, o usuário será redirecionado para a tela de início Figura 1a a

qual contém dois carrosséis, referentes as PANC e receitas recomendadas. Essa interface pretende recepcionar o usuário ao aplicativo e fornecer atalhos às outras seções do sistema. Ao utilizar a barra de busca na tela de início, o usuário será redirecionado para a tela de busca, onde poderá ser feita as buscas sobre PANC ou receitas, a fim de obter mais informações específicas sobre determinado item.

Após as listagens dos itens na busca, o usuário poderá clicar nos itens para obter mais informações, sendo possível obter dois tipos de resultados da busca, PANC ou Receitas. Ao clicar em uma PANC, o sistema abrirá a tela de informações da PANC, onde contém o nome, descrição, benefícios e modo de cultivo das PANC. Porém, se o usuário clicar em alguma receita, ele será direcionado a tela de receita Figura 1b, onde se apresenta o nome, descrição, ingredientes, modo de preparo e um destaque para quais PANC são utilizadas no preparo. As receitas podem ser adicionadas pelos usuários, já as PANC são oriundas do banco de dados do projeto.

Figura 1 – Páginas do Aplicativo



(a) Página Inicial

(b) Página de Receita

(c) Câmera da Análise

(d) Página das Análises

Fonte: Autoria Própria (2024)

Além das PANC e Receitas, o sistema também aborda as análises de caracterização dessas plantas. Para utilizar a funcionalidade de caracterização, é necessário clicar no ícone de câmera, e será redirecionado a tela da câmera Fig. 1c, na qual o usuário pode tirar uma foto na hora ou selecioná-la de sua galeria. Por seguinte, a imagem será enviada para a análise, a qual é realizada pela IA. Após o término da análise, o usuário pode consultar o resultado da análise em seu perfil Figura 1d, as quais são compostas pela data de realização, acurácia e a classe predita.

Para garantir a confiabilidade dos resultados, foram realizados Testes Unitários no serviço de IA. Visando a conformidade dos testes com a construção do serviço, foi utilizada a biblioteca Pytest, da linguagem Python. Essa biblioteca foi escolhida devido à sua simplicidade e flexibilidade na escrita de testes. Durante a execução, representado pela Fig. 2, foi obtida uma cobertura de código de 100%, assegurando que todas as partes do serviço foram testadas. Além disso, todos os testes passaram com sucesso, indicando a robustez e a correta implementação do sistema.

Figura 2 – Execução dos Testes Unitários


```
----- coverage: platform linux, python 3.10.12-final-0 -----
Name                               Stmts  Miss  Cover   Missing
-----
app.py                             29      0  100%
services/image_processor.py         24      0  100%
tests/__init__.py                   0      0  100%
tests/test_app.py                   31      0  100%
tests/test_image_processor.py       43      0  100%
-----
TOTAL                               127     0  100%
```

Fonte: Autoria Própria (2024)

RESULTADOS PRELIMINARES

Inicialmente, quando o modelo é treinado por 20 épocas, a acurácia é de 84,62% para um terço da base, 91,16% para dois terços, e 97,43% para a base completa. Esses valores indicam que o modelo melhora significativamente sua capacidade de prever corretamente à medida que mais dados são fornecidos. Com um terço da base, a acurácia é consideravelmente mais baixa, o que sugere que o modelo enfrenta dificuldades em generalizar bem com menos dados. Por outro lado, quando se utiliza a base completa, a acurácia sobe consideravelmente, como apresentado no Gráfico 1, evidenciando que um maior volume de dados ajuda o modelo a capturar padrões de maneira mais eficiente desde o início.

Gráfico 1 – Acurácia dos modelos treinados



Fonte: Autoria Própria (2024)

Após 40 épocas de treinamento, ambas as bases fracionadas chegaram a mesma acurácia de 98,90%. O modelo com a base completa, no entanto, continua a se destacar, atingindo uma acurácia ainda mais alta de 99,26%. Nesse estágio, o modelo parece ter aproveitado ao máximo os dados disponíveis, e os ganhos adicionais de desempenho são menores, sugerindo que já está próximo de seu limite de aprendizado, especialmente para os grupos com menos dados.

Finalmente, após 80 épocas, o comportamento dos três cenários começa a se diferenciar mais. O modelo com um terço da base permanece estável, com uma acurácia de 98,90%, o que indica que o treinamento adicional não traz mais benefícios significativos. O modelo com dois terços da base experimenta uma leve melhora, atingindo 99,45%, mostrando que a adição de mais épocas pode proporcionar algum ganho. Já o modelo com a base completa chega a uma acurácia de 99,91%, praticamente eliminando erros de previsão.

O volume de dados tem um impacto direto e positivo na acurácia do modelo. Enquanto o modelo com menos dados rapidamente atinge um platô de desempenho, modelos treinados com mais dados continuam a melhorar com o aumento do número de épocas. Esse fato pode evidenciar um possível caso de *overfitting*, onde o modelo se comporta muito bom em relação à base de treinamento, porém pode vir a apresentar dificuldades em atingir uma alta taxa de precisão quando se trata de novos dados.

A análise dos resultados sugere que o modelo treinado com a base completa pode estar sujeito a *overfitting*, especialmente considerando que o treinamento já começa com uma acurácia elevada, rapidamente atingindo valores acima de 90%. Esse comportamento inicial indica que o modelo pode estar capturando padrões específicos da base de treinamento desde o início, o que, aliado ao ajuste fino nas últimas camadas do VGG16, permite uma rápida escalada da acurácia. Embora o uso de técnicas de aumento de dados, como rotação, deslocamento e espelhamento, contribua para melhorar a generalização, essa alta precisão nos dados de treinamento nem sempre é garantia de um bom desempenho em dados novos. Estratégias adicionais de regularização, como *dropout* ou ajuste no número de épocas, podem ajudar a controlar o *overfitting* e aumentar a robustez do modelo em novos cenários.

Outro fator, é o tamanho da base de dados que pode influenciar na quantidade de épocas, já que pela extensa quantidade de imagens de cada classe, pode acabar sendo necessária menos épocas para atingir um comportamento esperado de um modelo treinado corretamente. Às duas melhores acurácias apresentadas para o uso constante da IA, no aplicativo móvel, foram treinadas com apenas 20 épocas, sendo às duas com maior quantidade de imagens, no caso o modelo de dois terços da base, com acurácia de 91,16% e o modelo com a base completa, com acurácia de 97,43%.

CONCLUSÃO

A divulgação das PANC enfrenta entraves como a dificuldade na obtenção de informações e a inserção dessas hortaliças na alimentação. A falta de demanda, causada pelo desconhecimento da população, agrava o problema, assim como a pouca visibilidade dos produtores. No entanto, embora o termo PANC seja pouco conhecido, muitas dessas plantas já são familiares para a população, podendo facilitar a introdução de outras PANC na alimentação cotidiana.

A proposta do projeto Osiris tem o potencial de gerar impactos sociais positivos, incluindo a promoção da educação alimentar e o empoderamento de comunidades locais. Ambientalmente, o incentivo ao consumo das PANC pode contribuir para a preservação da biodiversidade e práticas agrícolas mais sustentáveis. Economicamente, o projeto pode criar oportunidades de negócios locais, valorizando produtos regionais e reduzindo a dependência de importações alimentares.

Do ponto de vista econômico, a proposta do projeto Osiris se mostra viável devido à sua abordagem inovadora e ao potencial de mercado que oferece. Embora seja necessário um maior aporte financeiro para que o projeto atinja um patamar de negócios. Seria necessária uma infraestrutura de nuvem robusta para aportar a aplicação mobile e seus serviços na nuvem, possibilitando alta disponibilidade para os usuários consumirem suas funcionalidades.

A implementação do aplicativo com Inteligência Artificial trouxe diversos benefícios à população

ao promover a disseminação das PANC. A tela de início, com carrosséis de PANC e receitas recomendadas, facilita o acesso a informações e incentiva a inclusão dessas plantas na alimentação. A barra de busca permite encontrar rapidamente dados específicos sobre PANC e receitas, enriquecendo o conhecimento e facilitando sua incorporação na dieta.

O processo de treinamento e validação da Inteligência Artificial foi efetivamente suportado pelo equipamento utilizado, visto o objetivo do projeto em entregar uma prova de conceito no âmbito acadêmico. Agora para uma identificação mais robusta, vê-se necessária uma maior capacidade computacional para gerar modelos mais precisos, de forma mais rápida, possibilitando uma quantidade maior de épocas do treinamento. A IA demonstrou-se ser bem eficiente tratando-se da identificação de cada classe, porém ainda apresenta dificuldades na identificação de imagens externas ao escopo da botânica.

Em relação à base de dados, seria necessária a construção de uma maior quantidade de cenários, com mais imagens, aumentando a diversificação das espécies das PANC e das imagens da própria base, ampliando assim a capacidade de caracterização da IA. Para este processo, a participação de biólogos botânicos voltados a pesquisa das PANC pode agregar valor significativo para identificar as características mais intrínsecas dessas plantas.

O aplicativo fornece detalhes sobre cada PANC, além de receitas que utilizam essas plantas, incentivando uma alimentação mais diversificada e saudável. A funcionalidade de caracterização de PANC, permite identificar plantas por meio de fotos, aumentando a segurança no consumo. Essas funcionalidades promovem a conscientização, incentivam o cultivo sustentável e fortalecem a conexão entre a população e o meio ambiente, contribuindo para a segurança alimentar e a valorização dos recursos naturais locais.

REFERÊNCIAS

ALMEIDA, Martha Elisa Ferreira de *et al.* Caracterização química das hortaliças não-convencionais conhecidas como ora-pro-nobis. **Biosci. j.(Online)**, p. 431–439, 2014.

BATISTA, Gabriel de Azevedo *et al.* Identificação De cultivares de feijão caupi a partir de imagens digitais de sementes e técnicas de inteligência artificial. Universidade Federal de Campina Grande, 2023.

CASEMIRO, Ítalo de Paula; VENDRAMI, Ana Lúcia do Amaral. 10 ANOS DE PANC (PLANTAS ALIMENTÍCIAS NÃO CONVENCIONAIS)–ANÁLISE E TENDÊNCIAS SOBRE O TEMA.

Alimentos: Ciência, Tecnologia e Meio Ambiente, v. 2, n. 3, p. 44–93, 2021.

DAMO, Andreisa *et al.* O Levantamento florístico de plantas alimentícias não convencionais (PANC) em uma agrofloresta no sul do Brasil. **Cadernos de Agroecologia**, v. 15, n. 2, 2020.

ISLAM, Shazzadul *et al.* Bird species classification from an image using VGG-16 network. *In: PROCEEDINGS of the 7th international conference on computer and communications management. [S. l.: s. n.]*, 2019.

LARA, Maria Clara Bandeira *et al.* Elaboração, aceitabilidade e avaliação da composição nutricional de uma receita de bolinho de taioba, uma panc (planta alimentícia não convencional). **Brazilian Journal of Development**, v. 5, n. 11, p. 24099–24109, 2019.

LIBERALESSO, Andréia Maria. O futuro da alimentação está nas plantas alimentícias não convencionais (PANC)?, 2019.

MACIEL, Mônica Jachetti *et al.* Avaliação do extrato alcoólico de hibisco (*Hibiscus sabdariffa* L.) como fator de proteção antibacteriana e antioxidante. **Revista do instituto adolfo lutz**, v. 71, n. 3, p. 462–470, 2012.

MARQUES JUNIOR, Luiz Carlos. Classificação de plantas daninhas em banco de imagens utilizando redes neurais convolucionais. Universidade Estadual Paulista (Unesp), 2019.

PINTO, Bruna. Classificação de batatas-doces através de técnicas de inteligência artificial, 2021.

SIMONETTI, Mariana Grisa; SIMONETTI, Kerli Tatiane Grisa; FARIÑA, Luciana Oliveira de. Biodiversidade como sustentabilidade: possibilidade de mercados para plantas alimentícias não convencionais (PANC). **Brazilian Journal of Development**, v. 7, n. 4, p. 35330–35348, 2021.

WANDERSEE, James H; SCHUSSLER, Elisabeth E. Preventing plant blindness. **The American biology teacher**, JSTOR, v. 61, n. 2, p. 82–86, 1999.