

# CARACTERIZAÇÃO DE PANC, ORIENTADO POR APRENDIZAGEM PROFUNDA

João Arthur Almeida Gomes<sup>1</sup>

Davi Torres Araújo<sup>2</sup>

Matheus Felipe Gomes da Silva<sup>3</sup>

Frederico Barbosa Muniz<sup>4</sup>

Thissiany Beatriz Almeida<sup>5</sup>

## RESUMO

Este estudo tem como objetivo caracterizar plantas alimentícias não convencionais (PANC) utilizando aprendizado profundo para promover sua aceitação na dieta brasileira. Um dos focos principais é 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 foi treinada com Redes Neurais Convolucionais (CNN), obtendo acurácia entre 91,16% e 99,91% na classificação. O aplicativo facilita a identificação das PANC e oferece receitas e orientações de uso. O projeto Osiris busca ter impacto social e ambiental, promovendo a preservação da biodiversidade e incentivando práticas agrícolas sustentáveis. Ao valorizar produtos locais, também pode criar oportunidades econômicas e reduzir a dependência de alimentos importados. A pesquisa destaca a importância de aumentar o volume de dados para melhorar a eficácia do modelo de IA e sugere a inclusão de mais espécies de PANC. A participação de especialistas é essencial para aprimorar a caracterização das plantas. O projeto reforça a importância das PANC na alimentação e a necessidade de conscientizar a população sobre seus benefícios. O aplicativo desenvolvido oferece uma plataforma acessível para promover uma dieta mais diversificada e saudável. O projeto Osiris inova ao transformar a percepção das PANC e fortalece a conexão entre as pessoas e o meio ambiente.

**PALAVRAS-CHAVES:** PANC; Inteligência Artificial; Alimentação.

## ABSTRACT

*This study aims to characterize unconventional food plants (PANC) using deep learning to promote their acceptance in the Brazilian diet. One key focus is developing a mobile app that employs Artificial Intelligence (AI) to identify and characterize these plants. The project collected 1,354 images of three PANC species: yam, ora-pro-nobis, and hibiscus. The AI, trained using Convolutional Neural Networks (CNN), achieved high classification accuracy between 91.16% and 99.91%. This demonstrates the model's effectiveness in identifying PANC despite genetic variability. The app not only aids PANC identification but also provides recipes and advice on incorporating them into daily meals. The Osiris project has potential social and environmental impacts, promoting biodiversity preservation and more sustainable agriculture. It also supports local products, creating economic opportunities and reducing reliance on imports. The research highlights the importance of data volume in AI effectiveness and suggests expanding the image*

<sup>1</sup> Estudante da Fatec de Registro

<sup>2</sup> Estudante da Fatec de Registro

<sup>3</sup> Estudante da Fatec de Registro

<sup>4</sup> Mestre em Computação Aplicada à Informática Biomédica pela Universidade de São Paulo (USP), Docente da Fatec de Registro

<sup>5</sup> Mestre em Ciência da Computação pela Universidade Tecnológica Federal do Paraná (UTFPR), Docente na Fatec de Registro

*database to include more PANC species. Participation from botanists and researchers is vital for improving the plant characterization process. The project underscores the nutritional relevance of PANC and the need to raise awareness of their benefits. The developed app offers an accessible platform for the public to learn about and use these plants, fostering a more diverse and healthy diet. Ultimately, the Osiris project is an innovative initiative with the potential to change the perception and consumption of PANC, strengthening the connection between people and the environment.*

**KEYWORDS:** PANC; Artificial Intelligence; Nutrition.

## 1. 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 (Organização das Nações Unidas). O ODS 2 busca acabar com a fome, alcançar a segurança alimentar e melhorar a nutrição, promovendo a agricultura sustentável. O termo PANC foi utilizado pela primeira vez por Valdely Ferreira Kinupp no ano de 2007, para referir-se a plantas alimentícias não convencionais (Casemiro, 2021). Essas são frutos, hortaliças 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, 2019). Normalmente as percebemos de forma menos nítida do que os animais, ou nem as percebemos (Simonetti, 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. Este fenômeno inclui os aspectos estéticos e biológicos das plantas, e a ideia de que elas sejam seres inferiores aos animais, portanto, não merecedoras de atenção equivalente. (WANDERSEE, 1999)


O projeto aborda o estudo de três PANC: o hibisco, o inhame e a ora-pro-nóbis. O inhame (Figura 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, 2020). A ora-pro-nóbis (Figura 1b), uma planta resistente e de fácil cultivo, é consumida na

alimentação e utilizada na medicina, destacando-se pelo seu alto valor nutricional (Almeida, 2014). Por fim, hibisco (Figura 1c), segundo Maciel (2012), possui sementes e flores utilizadas na produção de bebidas e alimentos, além de ser regulamentada pela Anvisa para consumo em chás e como fonte de proteína.

Figura 1 – Imagem das PANC



(a)



(b)



(c)

Fonte: Elaborado pelo autor (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.

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. Um estudo realizado por Pinto (2021) propôs a classificação qualitativa de imagens de batata-doce brazlândia roxa. Batista (2023) focou na identificação de feijão-caupi através do processamento de imagens de sementes. Marques (2019) abordou a eliminação de plantas daninhas com visão computacional e IA. Embora todos utilizem técnicas de aprendizado de máquina, este projeto diferencia-se por buscar uma solução prática para a identificação das PANC, que ainda carecem de maior conhecimento e valorização pela população.

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.

## **2. PROCEDIMENTOS METODOLÓGICOS**

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 240GB, placa de vídeo Radeon RX 570 Series 4GB 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, 2019). A construção dessa 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 as 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 (Equação 1) 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 da seguinte forma:

Equação 1 - Função Softmax

$$s(x_i) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}}$$

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 acesse através do aplicativo móvel. O processo percorrido pela imagem fornecida para o sistema, até o resultado proveniente da análise pode ser descrito pela Figura 2, 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.

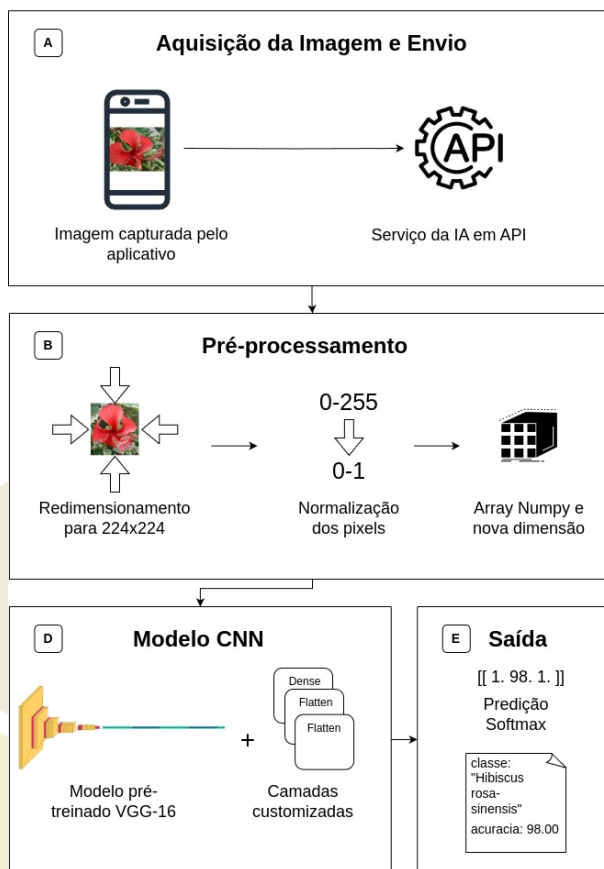
b) O Pré-processamento submete a imagem a uma série de transformações necessárias para prepará-la para a rede neural. A primeira sendo o redimensionamento, onde a imagem é redimensionada para 224x224 pixels, que é o tamanho esperado pelo modelo da CNN que será utilizado para a classificação. Em seguida, ocorre a normalização dos pixels, onde os valores deles 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) 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) 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.

Figura 2 – Fluxograma do processo de caracterização



Fonte: Elaborado pelo autor (2024)

## 2.1. Aplicação Móvel

O uso da aplicação móvel visa essencialmente disponibilizar um meio para que seja viável que a população tenha acesso a 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.

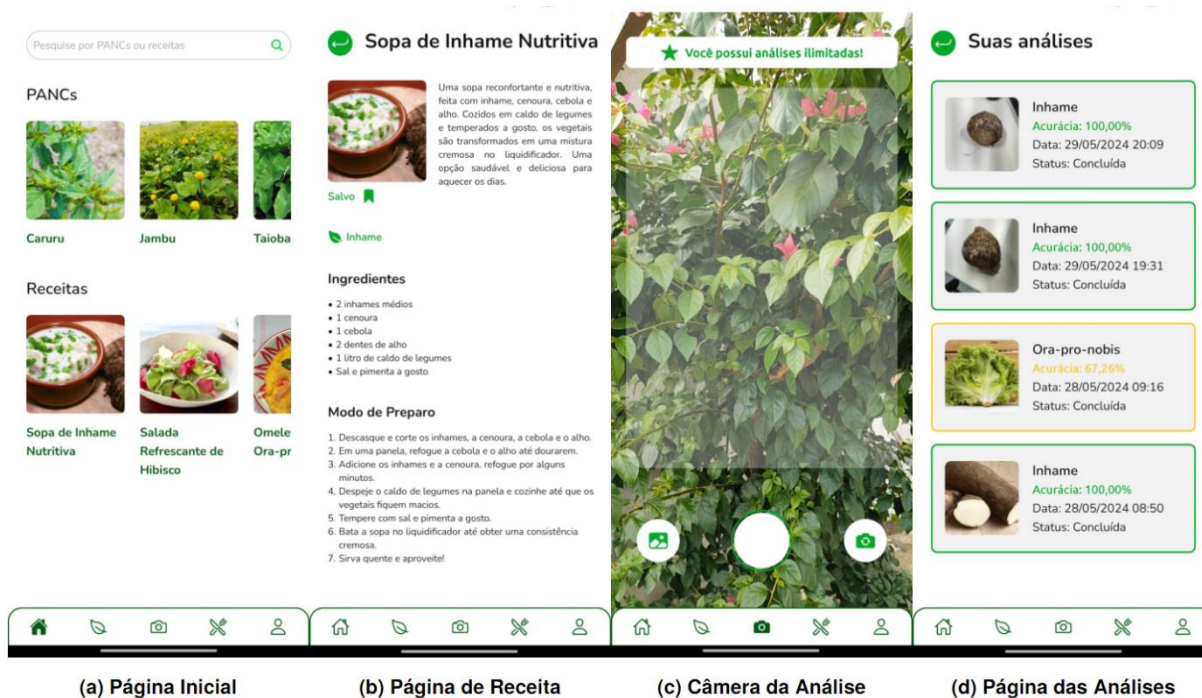
Ao acessar o aplicativo, o usuário será redirecionado para a tela de início (Figura 3a) a qual contém dois carrosséis, referentes as PANC e receitas recomendadas. Essa interface pretende recepcionar o usuário ao aplicativo e fornecer atalhos às outras seções do sistema. Ao utilizar a barra de busca na 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 3b), 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.

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 (Figura 3c), 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 3d), as quais são compostas pela data de realização, acurácia e a classe predita.

Figura 3 – Telas do Aplicativo Móvel





(a) Página Inicial

(b) Página de Receita

(c) Câmera da Análise

(d) Página das Análises


Fonte: Elaborado pelo autor (2024)

O treinamento foi realizado utilizando variações entre o número de épocas e a quantidade de dados utilizada, no caso a quantidade de imagens. Foram utilizadas três variações de épocas, sendo elas 20, 40 e 80 épocas de treinamento. Em paralelo, para cada quantidades de épocas, foram realizados os treinos com três porções diferentes da base de dados. Inicialmente utilizou-se um terço da base de dados, subseqüentemente foram usadas as bases com dois terços de imagens e a base completa.

### 3. RESULTADOS E DISCUSSÃO

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: Elaborado pelo autor (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 bem em relação a base de treinamento, porém pode vir a apresentar dificuldades em relação a precisão quando

se trata de novos dados.

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 que atinja um comportamento esperado de um modelo treinado corretamente. As duas melhores acurácias apresentadas para o uso constante da IA, dentro do aplicativo móvel, foram treinadas com apenas 20 épocas, sendo as 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%.

#### 4. CONSIDERAÇÕES FINAIS

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, com mais imagens, além a diversificação das espécies das PANC, 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 BIBLIOGRÁFICAS

ALMEIDA, Martha Elisa Ferreira de et al. **Caracterização química das hortaliças não-convencionais conhecidas como ora-pro-nóbis**. 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)?”**. Universidade Federal do Rio Grande do Sul (UFRGS) 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. 10

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**. Universidade Federal do Rio Grande do Sul (UFRGS), 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.

THÖNES, Johannes. **Microservices**. IEEE Software, v. 32, n. 1, p. 116, 2015. DOI: 10.1109/MS.2015.11.

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