



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE DESENVOLVIMENTO SUSTENTÁVEL DO SEMIÁRIDO  
UNIDADE ACADÊMICA DE TECNOLOGIA DO DESENVOLVIMENTO  
CURSO SUPERIOR DE TECNOLOGIA EM AGROECOLOGIA**

**MARCELO EDUARDO DOS SANTOS**

**IDENTIFICAÇÃO DE VARIEDADES CRIOLAS DE FEIJÃO-CAUPI A PARTIR DE  
IMAGENS DIGITAIS DE SEMENTES E TÉCNICAS DE  
INTELIGÊNCIA ARTIFICIAL**

**SUMÉ – PB  
2023**

**MARCELO EDUARDO DOS SANTOS**

**IDENTIFICAÇÃO DE VARIEDADES CRIOULAS DE FEIJÃO-CAUPI A PARTIR DE  
IMAGENS DIGITAIS DE SEMENTES E TÉCNICAS DE  
INTELIGÊNCIA ARTIFICIAL**

**Monografia apresentada ao Curso Superior de Tecnologia em Agroecologia do Centro de Desenvolvimento Sustentável do Semiárido da Universidade Federal de Campina Grande, como requisito parcial para obtenção do título de Tecnólogo em Agroecologia.**

**Orientador: Professor Dr. Rener Luciano de Souza Ferraz**

**SUMÉ – PB**

**2023**



S237i Santos, Marcelo Eduardo dos.

Identificação das variedades crioulas de feijão-caupi a partir de imagens digitais de sementes e técnicas de inteligência artificial. / Marcelo Eduardo dos Santos. - 2023.

27 f.

Orientador: Professor Dr. Rener Luciano de Souza Ferraz.

Monografia - Universidade Federal de Campina Grande; Centro de Desenvolvimento Sustentável do Semiárido; Curso Superior de Tecnologia em Agroecologia.

1. Tecnologia de sementes. 2. Feijão-caupi - sementes. 3. Imagens digitais de sementes. 4. Inteligência artificial - sementes. 5. Identificação de sementes - inteligência artificial. 6. Sementes crioulas - feijão-caupi. 7. Classificação fenotípica. 8. Aprendizagem de máquina. I. Ferraz, Rener Luciano de Souza. II. Título.

CDU: 631.53.01(043.1)

**Elaboração da Ficha Catalográfica:**

Johnny Rodrigues Barbosa  
Bibliotecário-Documentalista  
CRB-15/626

# **MARCELO EDUARDO DOS SANTOS**

## **IDENTIFICAÇÃO DE VARIEDADES CRIOULAS DE FEIJÃO-CAUPI A PARTIR DE IMAGENS DIGITAIS DE SEMENTES E TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL**

**Monografia apresentada ao Curso Superior de Tecnologia em Agroecologia do Centro de Desenvolvimento Sustentável do Semiárido da Universidade Federal de Campina Grande, como requisito parcial para obtenção do título de Tecnólogo em Agroecologia.**

### **BANCA EXAMINADORA:**

---

**Professor Dr. Rener Luciano de Souza Ferraz  
Orientador - UATEC/CDSA/UFCG**

---

**Professor M.e. Miguel Avelino Barbosa Neto  
Examinador Externo - CCA/UFPB**

---

**M.e. Wellerson Leite de Andrade  
Examinador Externo - CCA/UFPB**

---

**M.e. Semako Ibrahim Bonou  
Examinador Externo - UAEA/CTRN/UFCG**

**Trabalho aprovado em: 16 de fevereiro de 2023.**

**SUMÉ - PB**

## **AGRADECIMENTOS**

Quero primeiramente agradecer a Deus por todas as bênçãos concedidas a mim e por estar sempre guiando meus passos.

A minha mãe, Maria José por todo empenho, dedicação e incentivo, por todos aqueles momentos difíceis que passei ela nunca deixou de acreditar em mim. Tenho muita admiração pela senhora e orgulho por ser seu filho!

A meu pai, Edmilson José por ser aquela pessoa que sempre me ajudou nos momentos mais difíceis, estando sempre fazendo por mim o que fosse necessário para minha formação.

Aos meus irmãos, Carlos Henrique e Maria Isabela, por sempre estarem me ajudando e apoiando, obrigado pela palavra amiga, sincera, por me apoiarem em toda dificuldade da graduação, sempre contei com vocês.

Agradeço demais ao meu orientador, Professor Dr. Rener Luciano de Souza Ferraz, pela dedicação, incentivo, além de professor é também um amigo, uma pessoa sincera e de coração gigantesco. Sempre me ajudando e me estimulando a aprimorar meus conhecimentos durante a minha graduação.

Agradeço a Paulo, Durval, Edilson Pedro, trabalhadores terceirizados da UFCG, obrigado por sua ajuda durante o presente trabalho.

Ao Grupo do (PIBIC) por todo empenho e dedicação ao nosso projeto, reuniões e conhecimentos adquiridos.

Aos amigos que fizeram parte da minha graduação, pessoas que me mostraram ser verdadeiras e que eu tive o prazer de as conhecer, Joniedson Santos, Lucas Mayan, José Ilton, Gabriel Azevedo (mais que amigos verdadeiros irmãos), Fernanda Guenes, Rosana Lucena, Deyvid Mendes, José Hugo Simplicio, Franco Silva, Ana Clara, Mateus Procópio, Davi de Jesus França, professora Dr. Patrícia Da Silva Costa. Obrigado a cada um de vocês.

E a todos que me ajudaram na realização deste trabalho.

## RESUMO

O feijão-caupi é uma cultura de grande importância mundial, motivo pelo qual muitas variedades crioulas e cultivares melhoradas são exploradas. As sementes desses materiais possuem características intrínsecas que os distinguem. Nesse contexto, o objetivo do trabalho foi ajustar os modelos de aprendizagem de máquina para identificação de feijão-caupi a partir do processamento de imagens digitais de sementes utilizando-se de técnicas de inteligência artificial. Para tanto, imagens digitais de sementes de 6 variedades crioulas (VAR Bola-de-coco, VAR Paulistinha, VAR Sempre-verde, VAR Corujinha, VAR Pintado, VAR Rabo-de-tatú), foram obtidas e processadas utilizando-se dos vetorizadores InceptionV3, SqueezeNet, VGG16 e VGG19. Posteriormente, foram testados os algoritmos de aprendizado de Máquina K-Vizinhos Mais Próximos (KNN - number of nearest neighbors), Árvore de Decisão (Tree), Floresta Aleatória (RF - Random Forest), Aumento de Gradiente (GB - Gradient Boosting), Máquina de Suporte de Vetores (SVM - Support Vector Machines) e Rede Neural Artificial (MLP - Multi-Layer Perceptron). O melhor indicador de performance para identificação de feijão-caupi a partir do processamento das imagens digitais de sementes foi obtido utilizando o algoritmo de aprendizado de máquina Rede Neural Artificial.

**Palavras-chave:** *Vigna unguiculata* (L.) walp., classificação fenotípica, aprendizagem de máquina.

SANTOS, Marcelo Eduardo dos. **Identification of creole variety of cowpea from digital images of seeds and artificial intelligence techniques**. 2023. 25f. (Bachelor Thesis), Curso Superior de Tecnologia em Agroecologia, Centro de Desenvolvimento Sustentável do Semiárido, Universidade Federal de Campina Grande, Sumé – Paraíba – Brazil, 2022.

## **ABSTRACT**

Cowpea is a crop of great importance worldwide, which is why many landraces and improved cultivars are exploited. The seeds of these materials have intrinsic characteristics that distinguish them. Thus, the objective of this work was to adjust the machine learning models for cowpea identification from the processing of digital images of seeds using artificial intelligence techniques. For that, digital images of seeds of 6 landrace varieties and 10 cultivars were obtained and processed using the vectors InceptionV3, SqueezeNet, VGG16 and VGG19. Subsequently, the Machine learning algorithms K-Nearest Neighbors (KNN - number of nearest neighbors), Decision Tree (Tree), Random Forest (RF - Random Forest), Gradient Boosting (GB - Gradient Boosting), Support Vector Machines (SVM - Support Vector Machines) and Artificial Neural Network (MLP - Multi-Layer Perceptron). The best performance indicator for cowpea identification from digital seed image processing was obtained using the Artificial Neural Network machine learning algorithm.

**Keywords:** *Vigna unguiculata* (L.) Walp., phenotypic classification, machine learning.

## LISTA DE FIGURAS

<b>Figura 1</b> - Território Xukuru do Ororubá, de Pesqueira - PE.....	13
<b>Figura 2</b> - Localização da Comunidade Rural Fazenda Saco, cidade de Sumé - PB. ....	14
<b>Figura 3</b> - Localização da sala 03 do Ambiente de Professores do CDSA da UFCG. ....	15
<b>Figura 4</b> - Visão parcial da captura das imagens digitais das sementes das variedades crioulas e das cultivares de feijão-caupi.....	15
<b>Figura 5</b> - Fluxo de trabalho do processamento de imagens e ajuste de modelos de aprendizagem de máquina.....	16

## LISTA DE TABELAS

<b>Tabela 1</b> - Estatísticas de desempenho dos Embedder na etapa de modelagem. ...	18
<b>Tabela 2</b> - Estatísticas de desempenho das funções de ativação operando em diferentes Solvers.....	19
<b>Tabela 3</b> - Matriz de confusão para o desempenho do algoritmo Rede Neural, selecionado com a melhor função de ativação e o melhor solver. ....	20

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>9</b>
<b>2 OBJETIVOS.....</b>	<b>10</b>
<b>2.1 Objetivo Geral.....</b>	<b>10</b>
<b>2.2 Objetivos Específicos .....</b>	<b>10</b>
<b>3 REVISÃO DE LITERATURA .....</b>	<b>11</b>
<b>3.1 Identificação Tradicional de Feijão-caupi .....</b>	<b>11</b>
<b>3.2 Identificação de Plantas com Inteligência Artificial .....</b>	<b>12</b>
<b>4 MATERIAL E MÉTODOS .....</b>	<b>13</b>
<b>5 RESULTADOS E DISCUSSÃO .....</b>	<b>17</b>
<b>6 CONCLUSÃO .....</b>	<b>21</b>
<b>REFERÊNCIAS.....</b>	<b>22</b>

## 1 INTRODUÇÃO

A cultura do feijão-caupi (*Vigna unguiculata* (L.) Walp.), também conhecido como feijão-de-corda ou macassar, tem grande importância no mundo, principalmente em regiões áridas e semiáridas onde a espécie constitui uma das principais fontes nutricionais. Por esse motivo, muitos genótipos, variedades, linhagens e cultivares são exploradas nos agroecossistemas (MARTEY *et al.*, 2021; MARINHO *et al.*, 2021; NARAYANA; ANGAMUTHU, 2021; TAVARES *et al.*, 2021).

No Brasil a estimativa de produção de feijão caupi em 2022/23 é de 389 mil hectares na primeira Safra, já na segunda safra a estimativa é de 844,4 mil hectares plantados, 64,5 mil hectares plantados na terceira safra, o que corresponde às respectivas produtividades de 442 kg ha<sup>-1</sup> na primeira safra, 515 kg ha<sup>-1</sup> na segunda safra e 569 kg ha<sup>-1</sup> na terceira safra. O Nordeste é propício ao cultivo da espécie, uma vez que apresentam rusticidade elevada, especialmente em relação à demanda hídrica, adaptando-se bem as condições de menor disponibilidade de água no solo (CONAB, 2023). Na Paraíba, a produção foi de 32.800 toneladas, em uma área colhida de 76.500 ha, obtendo produtividade de 429 kg ha<sup>-1</sup> da safra 2019/20 (CONAB, 2020).

Tendo em vista a existência de grande diversidade genética da espécie, considerando desde variedades crioulas, até cultivares melhoradas, pode-se inferir a ocorrência de diferenças marcantes nas características das sementes desses materiais. De fato, conforme observado no Catálogo de cultivares de feijão-caupi da Embrapa Meio Norte, as sementes possuem variações expressivas nos aspectos de cor, forma, tamanho e massa, características que lhes confere identidade (EMBRAPA, 2021).

Pesquisas foram realizadas para comparações entre as características de sementes de variedades crioulas de feijão-caupi, chegando-se à conclusão de que as características (coloração, forma, peso e tamanho) avaliadas são bons indicadores para diferenciação dos materiais genéticos (MIQUELONI *et al.*, 2018; SILVA *et al.*, 2020). Com isso, é possível que sejam desenvolvidas ferramentas tecnológicas para identificação rápida e precisa das variedades dessa espécie a partir de características das sementes.

Com base no exposto, salienta-se que, com o avanço tecnológico, a agricultura tem incorporado novas ferramentas baseadas em computação para diversas

finalidades. Com isso, o setor agrícola passou a contar com o uso de inteligência artificial e aprendizagem de máquina para identificação e classificação de plantas a partir de suas características intrínsecas, o que tem ganhado destaque devido ao fato de se basear em análises não destrutivas das sementes e dos vegetais no campo (HATI; SINGH, 2021).

Técnicas de inteligência artificial e aprendizado de máquina já são conhecidas e aplicadas na região semiárida do Nordeste brasileiro com a finalidade de identificação de plantas (MENEZES NETO *et al.*, 2021). Contudo, ainda não foram relatadas pesquisas para identificação de feijão-caupi utilizando-se de processamento de imagens digitais das sementes e emprego de técnicas de inteligência artificial. Assim, novas pesquisas com essa finalidade podem introduzir desenvolvimento técnico-científico para a agricultura na região.

## **2 OBJETIVOS**

### **2.1 Objetivo Geral**

Ajustar modelos de aprendizagem de máquina para identificação das variedades crioulas de feijão-caupi a partir do processamento das imagens digitais de sementes utilizando-se de técnicas de inteligência artificial.

### **2.2 Objetivos Específicos**

Obter sementes de variedades crioulas de feijão-caupi cultivadas no Semiárido brasileiro.

Obter imagens digitais de sementes das variedades crioulas de feijão-caupi em dois ângulos e quatro posições diferentes.

Processar as imagens digitais de sementes e ajustes dos modelos de inteligência artificial para identificação de variedades crioulas de feijão-caupi.

Avaliar a performance dos modelos ajustados para identificação de variedades crioulas de feijão-caupi.

### 3 REVISÃO DE LITERATURA

O feijão-caupi é uma planta Dicotyledônea, da ordem fabales, família Fabaceae, subfamília Faboideae, tribo Phaseoleae, gênero vigna, subgênero vigna, secção catyang, espécie *Vigna unguiculata* (L.) Walp. O feijão caupi é uma leguminosa e faz parte da nutrição humana garantindo a energia necessária para o funcionamento do corpo (FREIRE FILHO *et al.*, 2011).

Atualmente, existem muitas variedades crioulas de feijão-caupi identificadas pelos agricultores familiares e lançadas pelos programas de melhoramento genético (GOMES *et al.*, 2021; MARINHO *et al.*, 2021; NARAYANA; ANGAMUTHU, 2021). Esses materiais são cultivados de forma experimental em diversos agroecossistemas e submetidos a variados sistemas de manejo, sobretudo para aumento de rendimento em condições de estresses bióticos e abióticos (SÁ *et al.*, 2021; TOYINBO *et al.*, 2021).

De fato, muitas pesquisas são desenvolvidas com feijão-caupi, por exemplo, utilizando doses de fósforo para homeostase iônica sob estresse salino (SÁ *et al.*, 2021), avaliando respostas da cultura à fertilização orgânica e mineral (SÁNCHEZ-NAVARRO *et al.*, 2021), respostas ecofisiológicas à deficiência hídrica (FERREIRA *et al.*, 2021) e biofortificação agronômica de genótipos (BARBOSA *et al.*, 2021; SILVA *et al.*, 2021). Contudo, o estado da arte não contempla um banco de dados de imagens digitais ou modelos de inteligência artificial para identificação e classificação de feijão-caupi a partir das características das sementes.

#### 3.1 Identificação Tradicional de Feijão-caupi

Em relação às sementes, para melhor identificação das variedades crioulas, foram levantadas características como a cor da semente - determinada em sementes recém-colhidas e secas, de acordo com as seguintes cores: branca com hilo marrom, branca com hilo preto, branco-vermelha, marrom-clara, marrom-escura, vermelha; cor do halo - determinada em sementes recém-colhidas e secas, de acordo com as seguintes cores: amarelo, marrom, vermelho; brilho da semente - determinado em sementes secas: opaco, intermediário, brilhante; peso de 100 sementes (g) - peso médio em gramas, obtido em uma amostragem de quatro repetições de 100 sementes a 13,5% de umidade; produtividade - medida em kg ha<sup>-1</sup> (MARINHO *et al.*, 2021).

Com base nas características das plantas, tradicionalmente, a identificação de variedades crioulas de feijão-caupi está sendo realizada a partir do levantamento de dados relativos aos caracteres fenológicos, morfológicos e agrônômicos, nos estádios de germinação, plântulas, floração, maturação, colheita e pós-colheita (MARINHO *et al.*, 2001).

Nesta perspectiva, os estudos realizados por Freire Filho *et al.* (1981) e Fonseca *et al.* (1986), reportam os principais caracteres a serem levantados para fins de fenotipagem dos genótipos, a saber: emergência de plântulas, cor do hipocótilo, floração média, cor da flor, porte da planta, pigmentação da haste principal, número de nós da haste principal, comprimento do folíolo central, largura do folíolo central, cor da vagem durante a maturação, número de vagens por planta e número de sementes por vagem.

De acordo com Oliveira *et al.* (2015), a identificação clássica das variedades crioulas abrange, primeiramente, classificação segundo o Regulamento Técnico do Feijão, Instrução Normativa Número 12 de 28 de fevereiro de 2008, instituído pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA) (BRASIL, 2008), adaptado por Freire Filho *et al.* (2005). Em complemento, também são utilizados os descritores recomendados pelo Biodiversity International (2007), anteriormente conhecido como International Board for Plant Genetic Resources (IBPGR), considerando a abrangência mundial do documento em relação aos descritores estabelecidos pelo Ato Número 4 de 19 de agosto de 2010, instituído pelo MAPA (BRASIL, 2010).

### **3.2 Identificação de Plantas com Inteligência Artificial**

A identificação de espécies por inteligência artificial é um processo de fundamental importância para suporte à agricultura de precisão (SUN *et al.*, 2021). Nos últimos anos, o aprendizado de máquina alcançou avanços significativos no reconhecimento de imagens digitais. Conseqüentemente, essa tecnologia se torna cada vez mais popular e constitui um ramo importante da agricultura inteligente com aplicação na identificação de espécies de plantas de interesse econômico, social e ambiental (XIONG *et al.*, 2021).

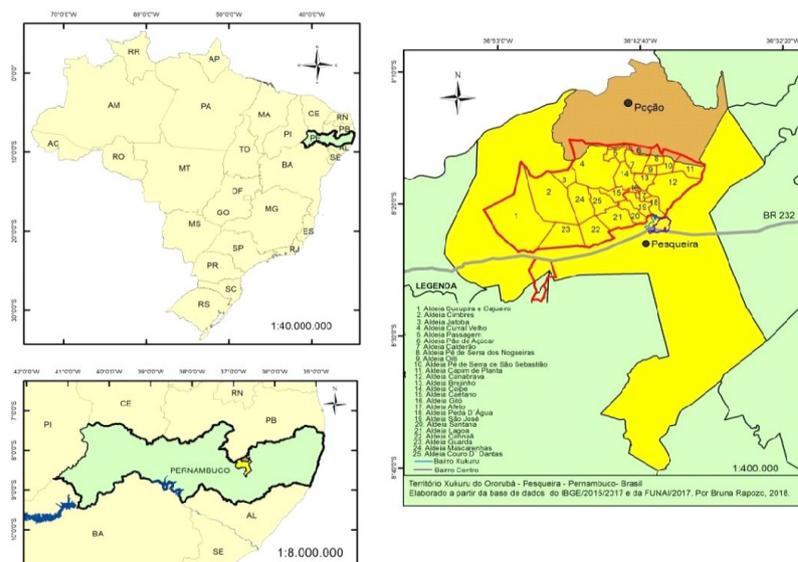
A tecnologia de identificação utilizando-se de aprendizagem de máquina tem sido utilizada pela comunidade científica para relacionar marcadores morfológicos,

fisiológicos e moleculares às características de imagens digitais de plantas submetidas a estresses abióticos (SOLTABAYEVA *et al.*, 2021); para detecção de doenças em folhas de plantas (SUJATHA *et al.*, 2021); e reconhecimento e identificação de espécies (HATI; SINGH, 2021). Apesar da importância da cultura do feijão-caupi e da inteligência artificial para identificação de plantas no Nordeste do Brasil (MENEZES NETO *et al.*, 2021), ainda não foram realizadas pesquisas para identificação de variedades crioulas dessa espécie a partir de processamento de imagens digitais de sementes.

#### 4 MATERIAL E MÉTODOS

As sementes das variedades crioulas de feijão-caupi foram obtidas de um Banco de Sementes Comunitário do Território Indígena Xukuru do Ororubá, na cidade de Pesqueira-PE (Figura 1).

**Figura 1** - Território Xukuru do Ororubá, de Pesqueira - PE.



**Fonte:** Rapozo e Oliveira (2018). Sumé, PB, 2022.

Nesta localidade foram obtidas sementes das variedades crioulas: VAR Sempre-verde, VAR Paulistinha, VAR Bola-de-coco, VAR Corujinha e VAR Pintado, colhidas na safra de 2021 e cedidas pelo Agricultor Adelson Xukuru. Também foram obtidas sementes da Comunidade Rural Fazenda Saco, na cidade de Sumé-PB, nas coordenadas 7°37'11"S 36°49'37"W. Nesta localidade foram obtidas sementes da variedade crioula Rabo-de-tatú, colhidas na safra de 2021 e cedidas pelo Agricultor

Edilson Pedro Xavier (Figura 2).

**Figura 2** - Localização da Comunidade Rural Fazenda Saco, cidade de Sumé - PB.



**Fonte:** Google Earth. Sumé, PB, 2022.

As sementes das variedades crioulas de feijão-caupi foram transportadas para a sala 03 do Ambiente de Professores do Centro de Desenvolvimento Sustentável do Semiárido (CDSA) da Universidade Federal de Campina Grande (UFCG), localizado no município de Sumé – PB, nas coordenadas de Latitude 7° 40' 18" S; Longitude 36° 52' 54" W e altitude de 518 m acima do nível do mar. O clima local, segundo a classificação de Köppen-Geiger, é do tipo Bsh (semiárido quente), com temperatura média anual de 26 °C e precipitação pluviométrica média anual de 600 mm (VITAL *et al.*, 2020) (Figura 3).

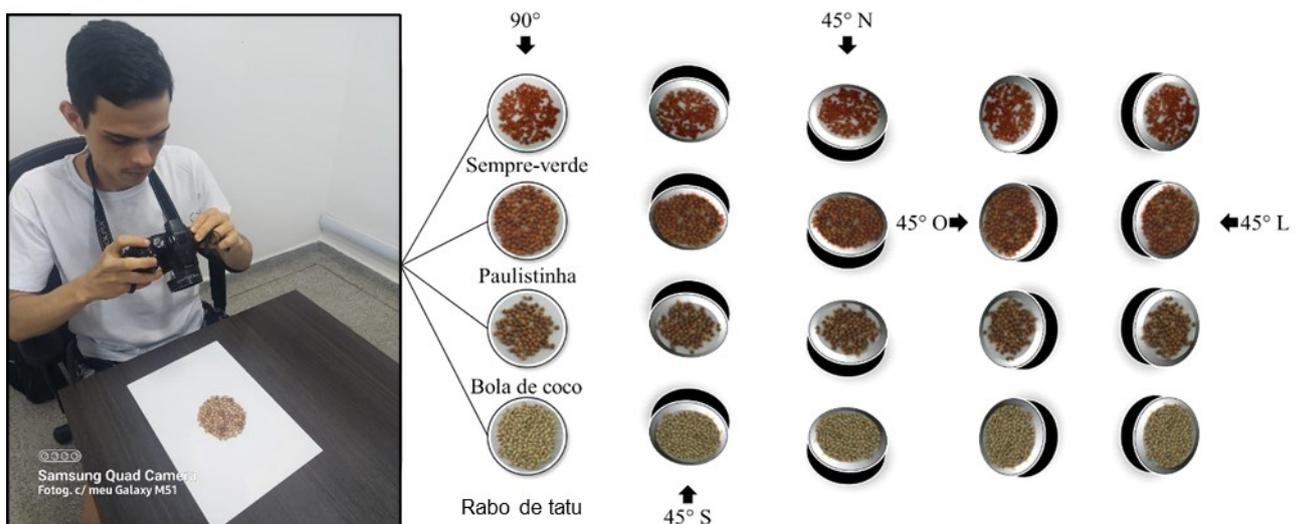
**Figura 3** - Localização da sala 03 do Ambiente de Professores do CDSA da UFCG.



Fonte: Wikipedia e Google Maps. Sumé, PB, 2022.

Foram obtidas imagens de 6 variedades crioulas usados nesta pesquisa, o que representa 100% de imagens obtidas. Foram obtidas 125 imagens de cada variedade crioula (amostras de 30 g de sementes), sendo 25 fotos nas seguintes posições: 25 fotos no ângulo de 90 graus, 25 fotos no ângulo de 45 graus na direção Norte, 25 fotos no ângulo de 45 graus na direção Sul, 25 fotos no ângulo de 45 graus na direção Leste, e 25 fotos no ângulo de 45 graus na direção Oeste, todas a uma distância média de 30 cm (Figura 4).

**Figura 4** - Visão parcial da captura das imagens digitais das sementes das variedades crioulas e das cultivares de feijão-caupi.



Fonte: Acervo da equipe de pesquisa. Sumé, PB, 2022.

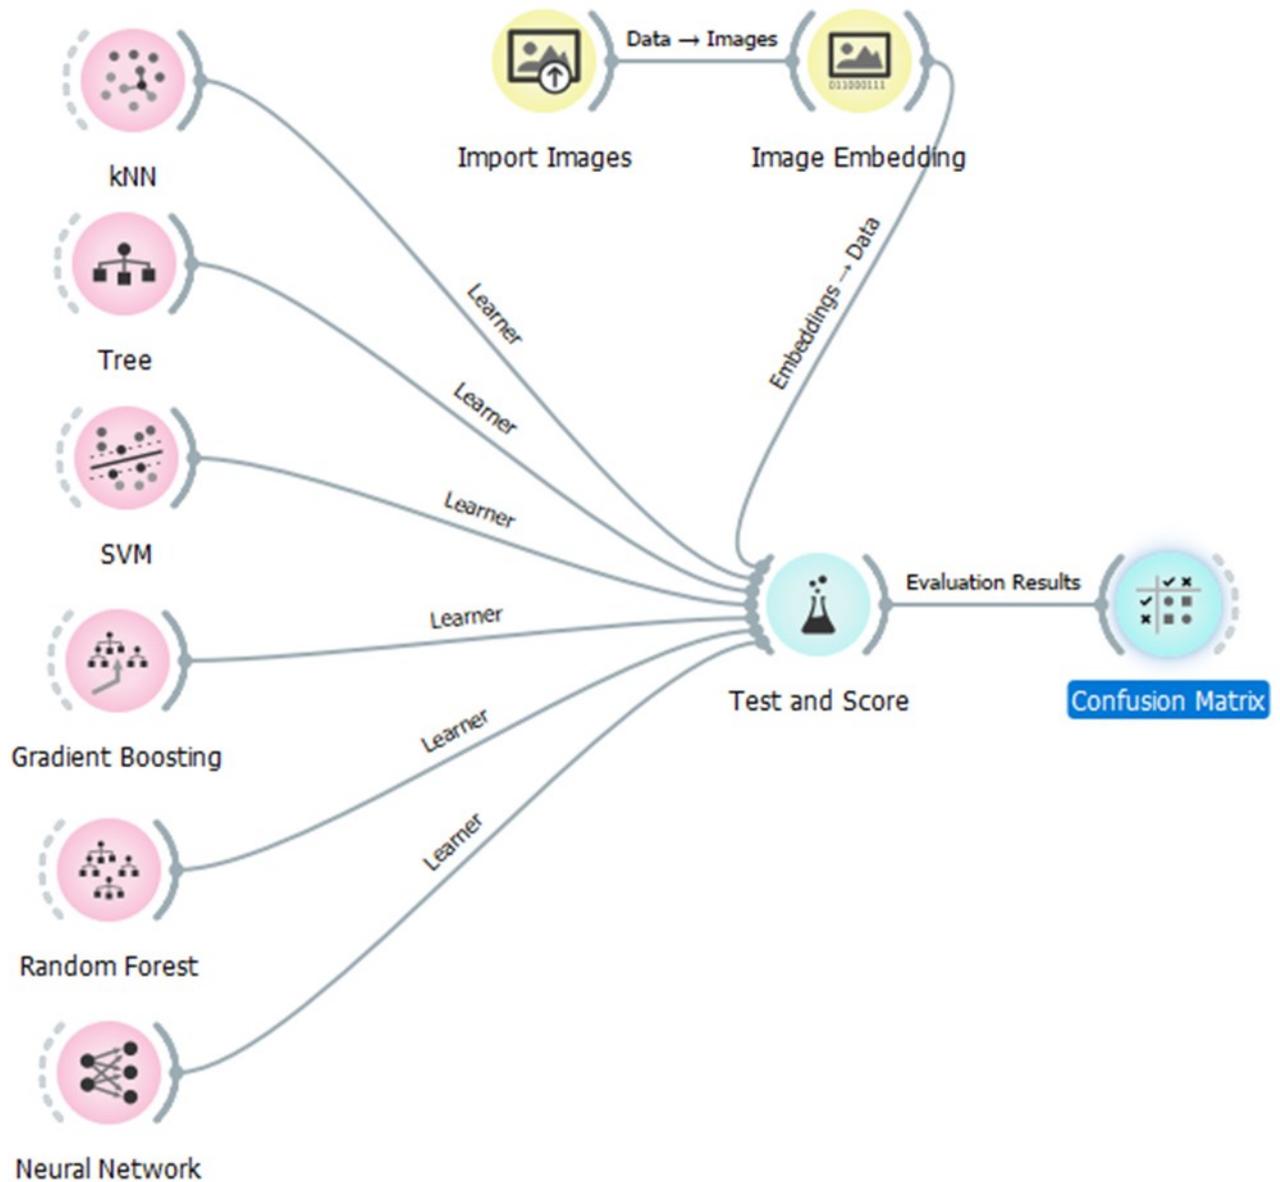
Para processamento das imagens foi utilizado o software *Orange Data Mining* v. 3.29.3. Inicialmente, das 125 imagens obtidas, 100 foram importadas utilizando-se do *widget* “Import Images” contido no *add-on* “Image Analytics”. Posteriormente, as imagens foram processadas e vetorizadas utilizando-se do *widget* “Image Embedding”. A vetorização das imagens foi realizada utilizando-se dos “Embedders” InceptionV3, SqueezeNet, VGG16 e VGG19 (GODEC *et al.*, 2019).

Para ajuste dos modelos e identificação das variedades crioulas de feijão-caupi, foram testados algoritmos de aprendizagem de máquina e suas respectivas variações até que melhores valores de performance foram obtidos para cada modelo, a saber: K-Vizinhos mais Próximos (KNN - Number of Nearest Neighbors), Arvore de Decisão (Tree), Floresta Aleatória (RF - Random Forest), Aumento de Gradiente (GB - Gradient Boosting), Máquina de Vetores de Suporte (SVM - Support Vector Machines) e Rede Neural Artificial (MLP - Multi-Layer Perceptron).

A performance dos modelos foi avaliada utilizando-se de diferentes métodos de amostragem do *Orange Data Mining*, a saber: validação cruzada (Cross-validation). Para validação dos modelos, foi utilizado o método teste em dados de teste (Test on test data) utilizando-se de vetores de 25 imagens das 125 obtidas inicialmente e que não foram utilizadas na etapa de ajuste dos modelos (Figura 5).

**Figura 5** - Fluxo de trabalho do processamento de imagens e ajuste de modelos de

aprendizagem de máquina.



**Fonte:** Elaboração da equipe de pesquisa, Sumé, PB, 2022.

Tanto para a avaliação da performance quanto para a validação, foram utilizadas estatísticas de desempenho. Para modelos de classificação foram utilizadas: a área sob a curva ROC de operação do receptor (Area under ROC), precisão da classificação (Classification accuracy), média harmônica ponderada de precisão e recall (F-1), precisão (Precision), recordação (Recall), especificidade (Specificity), perda de entropia cruzada (LogLoss), tempo de treinamento (Train time) e tempo de teste (Test time).

## 5 RESULTADOS E DISCUSSÃO

No processamento das imagens de sementes de feijão-caupi, verificou-se que, dentre os *Embedders* testados, ou seja, InceptionV3, SqueezeNet, VGG16 e VGG19, os que obtiveram melhor performance na etapa de modelagem foi o VGG16 com o algoritmo Rede Neural Artificial (Neural Network), com acurácia de 0,980, área abaixo da curva ROC de 0,999, tempo de teste de 6,331 s, tempo de treino de 23,149 s, F1 de 0,980 precisão de 0,981, recordação de 0,980 e especificidade de 0,997. Com vários parâmetros e diferenças mínimas em outros algoritmos que são trabalhados no *Orange Data Mining*, optou-se por escolher o embedder VGG16. (Tabela 1).

**Tabela 1.** Estatísticas de desempenho dos Embedder na etapa de modelagem.

Model	Estatísticas de desempenho								
	Embedder InceptionV3								
	Train time	Test time	AUC	CA	F1	Precision	Recall	LogLoss	Specificity
SVM	2,256	5,847	0,998	0,953	0,953	0,953	0,953	0,221	0,994
Neural Network	12,152	3,102	0,997	0,936	0,936	0,937	0,936	0,189	0,992
Knn	2,879	1,394	0,980	0,835	0,834	0,838	0,835	0,666	0,979
Gradient Boosting	1.400,534	1,939	0,971	0,764	0,768	0,786	0,764	0,705	0,970
Random Forest	3,533	1,661	0,892	0,617	0,615	0,622	0,617	2,101	0,951
Tree	59,572	0,001	0,700	0,449	0,451	0,455	0,449	17,621	0,930
	Embedder SqueezeNet								
SVM	8,984	2,255	0,998	0,954	0,954	0,955	0,954	0,226	0,994
Neural Network	5,739	1,227	0,995	0,921	0,921	0,921	0,921	0,267	0,990
kNN	1,186	1,088	0,982	0,829	0,828	0,837	0,829	0,705	0,978
Gradient Boosting	640,383	0,738	0,978	0,814	0,816	0,823	0,814	0,608	0,977
Random Forest	1,652	0,649	0,917	0,662	0,656	0,659	0,662	1,838	0,957
Tree	29,806	0,001	0,694	0,434	0,431	0,431	0,434	18,056	0,929
	Embedder VGG16								
Neural Network	23,149	6,331	0,999	0,980	0,980	0,981	0,980	0,068	0,997
SVM	39,956	11,252	0,998	0,935	0,936	0,941	0,935	0,239	0,992
Gradient Boosting	1.791,071	3,660	0,995	0,912	0,913	0,916	0,912	0,300	0,989
Random Forest	6,158	2,932	0,974	0,834	0,833	0,836	0,834	0,969	0,979
kNN	5,288	3,130	0,985	0,803	0,802	0,817	0,803	0,505	0,975
Tree	77,294	0,004	0,820	0,657	0,657	0,659	0,657	10,702	0,957

Embedder VGG19									
Neural Network	25,576	6,326	0,999	0,976	0,976	0,976	0,976	0,085	0,997
SVM	37,761	10,509	0,993	0,903	0,903	0,906	0,903	0,341	0,987
Gradient Boosting	1.542,859	3,374	0,993	0,899	0,900	0,902	0,899	0,340	0,987
kNN	5,387	3,488	0,986	0,836	0,836	0,845	0,836	0,516	0,979
Random Forest	6,219	3,068	0,962	0,800	0,800	0,801	0,800	1,143	0,975
Tree	71,453	0,007	0,807	0,642	0,640	0,643	0,642	11,256	0,955

IA: inteligência artificial; Train time: tempo de treinamento; Test time: tempo de teste; AUC: área sob a curva ROC de operação do receptor; CA: precisão da classificação; F1: média harmônica ponderada de precisão e recall; Precision: precisão; Recall: recordação; LogLoss: perda de entropia cruzada; Specificity: especificidade. Fonte: Elaboração da equipe de pesquisa, Sumé, PB, 2022.

O solver (L-BFGS-B) com a função de ativação (Relu) obtiveram os melhores resultados com acurácia de 1,00, área abaixo da curva ROC de 1,00, tempo de teste de 5,652 s, tempo de treino de 20,862 s, F1 de 1,00, precisão de 1,00, recordação de 1,00 e especificidade de 1,00 (Tabela 2).

**Tabela 2** - Estatísticas de desempenho das funções de ativação operando em diferentes Solvers.

Função de ativação	Estatísticas de desempenho								
	Solver L-BFGS-B								
	Train time	Test time	AUC	CA	F1	Precision	Recall	LogLoss	Specificity
Identidade	25,532	5,783	1,000	0,997	0,997	0,997	0,997	0,006	0,999
Logística	20,343	5,750	1,000	1,000	1,000	1,000	1,000	0,001	1,000
Tan hiperbólica	21,239	5,859	1,000	1,000	1,000	1,000	1,000	0,002	1,000
ReLU	20,862	5,652	1,000	1,000	1,000	1,000	1,000	0,000	1,000
Solver SGD									
Identidade	33,562	5,883	1,000	0,997	0,997	0,997	0,997	0,018	0,999
Logística	44,322	5,622	1,000	0,993	0,993	0,994	0,993	0,320	0,999
Tan hiperbólica	42,031	5,883	1,000	0,997	0,997	0,997	0,997	0,023	0,999
ReLU	42,267	5,756	1,000	1,000	1,000	1,000	1,000	0,012	1,000
Solver Adam									
Identidade	24,527	5,976	1,000	1,000	1,000	1,000	1,000	0,002	1,000
Logística	49,155	5,844	1,000	1,000	1,000	1,000	1,000	0,008	1,000
Tan hiperbólica	27,354	5,870	1,000	1,000	1,000	1,000	1,000	0,003	1,000
ReLU	23,065	5,880	1,000	1,000	1,000	1,000	1,000	0,001	1,000

IA: inteligência artificial; Train time: tempo de treinamento; Test time: tempo de teste; AUC: área sob a curva ROC de operação do receptor; CA: precisão da classificação; F1: média harmônica ponderada de precisão e recall; Precision: precisão; Recall: recordação; LogLoss: perda de entropia cruzada; Specificity: especificidade. Fonte: Elaboração da equipe de pesquisa, Sumé, PB, 2022.

Os resultados descritos na Tabela 3, foram obtidos com 100% de precisão, devido ao fato das sementes de variedades de feijão-caupi possuírem características próprias, desse modo o algoritmo tem a capacidade de identificar tais características por mínimos que sejam os traços, conforme informações da Embrapa (2021) no catálogo de cultivares de feijão-caupi.

**Tabela 3** - Matriz de confusão para o desempenho do algoritmo Rede Neural, selecionado com a melhor função de ativação e o melhor solver.

Cultivares		Valores preditos pelo modelo					$\Sigma$
		Bola de coco	de Corujinha	Paulistinha	Pintado	Rabo de tatu	
Valor real	Bola de coco	100	0	0	0	0	100
	Corujinha	0	100	0	0	0	100
	Paulistinha	0	0	100	0	0	100
	Pintado	0	0	0	100	0	100
	Rabo de tatu	0	0	0	0	100	100
	Sempre verde	0	0	0	0	0	100
	$\Sigma$	100	100	100	100	100	100

**Fonte:** Elaboração da equipe de pesquisa, Sumé, PB, 2022.

O algoritmo Rede Neural Artificial identificou todas as variedades de feijão-caupi corretamente, apresentando o máximo de desempenho, o que pode ser justificado pelo fato de a inteligência artificial conseguir distinguir as sementes de acordo com suas diferentes características, como a cor, forma, tamanho e massa, fato que também foi mencionado por Miquelone *et al.* (2018) e Silva *et al.* (2020).

De acordo com Pinheiro *et al.* (2021), o propósito do aprendizado de máquinas é alimentar um sistema de dados com experiências anteriores e dados estatísticos para que ela possa executar sua tarefa atribuída para resolver um problema específico. Neste contexto, tendo em vista a base de imagens de sementes de feijão-caupi utilizadas para treinamento dos modelos, o bom desempenho do algoritmo Rede Neural Artificial, está relacionado à capacidade de aprendizado de máquinas.

No que tange aos algoritmos aplicados na área agrícola, esta tecnologia melhorou o desenvolvimento no setor e melhorou o monitoramento, a colheita, o processamento e a comercialização em tempo real. Essas melhorias reforçam a

importância do algoritmo Rede Neural para a finalidade de classificação de imagens, isso porque ele apresenta camadas de entrada e de saída de informações preponderantes para simular as conexões neurais. Em síntese, a Rede Neural artificial consiste em um processo conhecido como aprendizagem (CINAR et al., 2020), denotando que isso foi possível a partir de imagens de sementes de feijão-caupi.

Face ao exposto, há de se considerar que as informações geradas nesta pesquisa são de fundamental importância para a inserção de tecnologia na agricultura, sobretudo no cultivo de feijão-caupi, pois, a agricultura assistida por computador oferece vantagens significativas em termos de redução de custos, obtenção de resultados rápidos, minimização erros, redução da carga de trabalho e aumento da segurança. Há um número significativo de estudos relacionados à classificação de sementes de milho e até mesmo grãos de poleo. A maioria dos estudos está focada em técnicas de imagem especiais, como imagens multiespectrais, hiperespectrais, infravermelho próximo e de fluorescência. Esses métodos de imaginação podem ser eficientes de acordo com as abordagens de classificação utilizadas (DÖNMEZ, 2022; MAHMOOD; CHOI; RYOUNG, 2023). A importância dos achados nesta pesquisa reside, também, no seu ineditismo, pois, não haviam aplicações desse tipo para feijão-caupi.

## **5 CONCLUSÃO**

O algoritmo de aprendizado de máquina Rede Neural Artificial teve o melhor

indicador de performance para identificação de feijão-caupi a partir do processamento das imagens digitais de sementes. Foi escolhido o algoritmo Rede Neural Artificial através da análise dos dados das tabelas acima descritas.

## REFERÊNCIAS

BARBOSA, E. P. A.; SODRÉ, D. N.; BRAUN, H.; VIEIRA, R. F. Seeds enriched with molybdenum improve cowpea yield in sub-humid tropical regions of Brazil. **Agronomy**

**Journal**, v. 113, p. 2044-2052, 2021.

BIOVERSITY INTERNATIONAL. Descritores para Feijão frade ou caupi (*Vigna unguiculata* (L.) Walp.). In: BETTENCOURT, E. (Ed.). **Bioversity International**. Roma-Itália, 2007.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Instrução Normativa nº 12 de 28 mar. 2008**. Diário Oficial da República Federativa do Brasil, Brasília, DF, 31 mar. 2008. p. 11-14, 2008.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Secretaria de Desenvolvimento Agropecuário e Cooperativismo. Serviço Nacional de Proteção de Cultivares**. Ato nº 4, de 19 de agosto de 2010. Diário Oficial da República Federativa do Brasil, Brasília, 2010. Seção 1, p. 6-7, 2010.

CINAR, A. C. Training feed-forward multi-layer perceptron neural network with a tree-seed algorithm. **Arabian Journal for Science and Engineering**, v. 45, p. 10915-10938, 2020.

CONAB. Companhia Nacional de Abastecimento. **Acompanhamento da safra brasileira grãos, v. 7 – safra 2019/20 – Décimo primeiro levantamento**. Brasília, p. 1-62, 2020.

CONAB. Companhia Nacional de Abastecimento. **Boletim de Monitoramento Agrícola**. Brasília, v. 12, 2023.

DÖNMEZ, E. Enhancing classification capacity of CNN models with deep feature selection and fusion: A case study on maize seed classification. **Data & Knowledge Engineering**, v. 141, p. e102075, 2022,

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Catálogo de cultivares de feijão caupi**. Embrapa Meio-Norte, 23p. 2021.

FERREIRA, D. P.; SOUSA, D. P.; NUNES, H. G. G. C.; PINTO, J. V. N.; FARIAS, V.

D. S.; COSTA, D. L. P.; MOURA, V. B.; TEIXEIRA, E.; SOUSA, A. M. L.; PINHEIRO, H. A.; SOUZA, P. J. O. P. Cowpea Ecophysiological Responses to Accumulated Water Deficiency during the Reproductive Phase in Northeastern Pará, Brazil. **Horticulturae**, v. 7, p. e116, 2021.

FONSECA, J. R.; SARTORATO, A.; RAVA, C. A.; COSTA, J. E. C.; FREIRE, M. S.; ANTUNES, I. F.; TEIXEIRA, M. G.; SILVA, J. G. **Características botânicas, agronômicas e fenológicas de cultivares regionais de feijão coletadas na região do Recôncavo Baiano**. (Boletim de Pesquisa, 4). Goiânia: EMBRAPA-CNPAP, p. 27, 1986.

FREIRE FILHO, F. R.; CARDOSO, M. J.; ARAÚJO, A. G.; SANTOS, A. A.; SILVA, P. H. S. **Características botânicas e agronômicas de cultivares de feijão macassar (*Vigna unguiculata* (L.) Walp)**. (Boletim de Pesquisa, 4). Teresina: EMBRAPA-UEPAE. p. 45, 1981.

FREIRE FILHO, F. R.; RIBEIRO, V. Q.; ROCHA, M. M.; SILVA, K. J. D.; NOGUEIRA, M. S. R.; RODRIGUES, E. V. **Feijão-caupi no Brasil: Produção, melhoramento genético, avanços e desafios**. Teresina: Embrapa Meio-Norte, 1. ed. 84p. 2011.

FREIRE FILHO, F. R.; ROCHA, M. M.; RIBEIRO, V. Q.; LOPES, A. C. A. Adaptabilidade e estabilidade produtiva de feijão-caupi. **Ciência Rural**, v. 35, p. 24-30, 2005.

GODEC, P.; PANČUR, M.; ILENIČ, N.; ČOPAR, A.; STRAŽAR, M.; ERJAVEC, A.; PRETNAR, A.; DEMŠAR, J.; STARIČ, A.; TOPLAK, M.; ŽAGAR, L.; HARTMAN, J.; WANG, H.; BELLAZZI, R.; PETROVIČ, U.; GARAGNA, S.; ZUCCOTTI, M.; PARK, D.; SHAULSKY, G.; ZUPAN, B. Democratized image analytics by visual programming through integration of deep models and small-scale machine learning. **Nat Commun**, v. 10, p. e4551, 2019.

GOMES, A. M. F.; DRAPER, D.; NHANTUMBO, N.; MASSINGA, R.; RAMALHO, J. C.; MARQUES, I.; RIBEIRO-BARROS, A. I. Diversity of Cowpea [*Vigna unguiculata* (L.) Walp] Landraces in Mozambique: New Opportunities for Crop Improvement and

Future Breeding Programs. **Agronomy**, v. 11, p. e991, 2021.

HATI, A. J.; SINGH, R. R. Artificial Intelligence in Smart Farms: Plant Phenotyping for Species Recognition and Health Condition Identification Using Deep Learning. **AI**, v. 2, p. 274-289, 2021.

MAHMOOD, T.; CHOI, J.; RYOUNG, P. K. Artificial intelligence-based classification of pollen grains using attention-guided pollen features aggregation network. **Journal of King Saud University - Computer and Information Sciences**, v. 35, p. 740-756, 2023.

MARINHO, J. T. S.; LESSA, L. S.; COSTA, C. R. Agronomic performance of cowpea genotypes in southwestern Brazilian Amazon. **Pesquisa Agropecuária Brasileira**, v. 56, p. e02046, 2021.

MARTEY, E.; ETWIRE, P. M.; ADOGOBA, D. S.; TENGEY, T. K. Farmers' preferences for climate-smart cowpea varieties: implications for crop breeding programmes. **Climate and Development**, v. 14, p. 105-120, 2021.

MENEZES NETO, E. J.; LIMA, D. G.; FEITOSA, I. S.; GOMES, S. M.; JACOB, M. C. M. Plant Identification Using Artificial Intelligence: Innovative Strategies for Teaching Food Biodiversity. In: JACOB, M. C. M.; ALBUQUERQUE, U. P. (Eds.). **Local Food Plants of Brazil**. Springer, 2021.

MIQUELONI, D. P.; SANTOS, V. B.; LIMA, S. R.; MESQUITA, D. N.; FURTADO, S. S. F. Descrição e discriminação de variedades crioulas de feijão-caupi na Amazônia Ocidental brasileira. **Acta Iguazu**, v. 7, p. 49-61, 2018.

NARAYANA, M.; ANGAMUTHU, M. Cowpea. In: PRATAP, A.; GUPTA, S. (Eds.). **The Beans and the Peas: From Orphan to Mainstream Crops**. Cambridge: Woodhead Publishing, 2021.

OLIVEIRA, E.; MATTAR, E. P. L.; ARAÚJO, M. L.; JESUS, J. C. S.; NAGY, A. C. G.; SANTOS, V. B. Descrição de cultivares locais de feijão-caupi coletados na microrregião Cruzeiro do Sul, Acre, Brasil. **Acta Amazonica**, v. 45, p. 243-254, 2015.

PINHEIRO, R. M.; GADOTTI, G. I.; MONTYEIRO, R. C. M.; BERNARDY, R. Inteligência artificial na agricultura com aplicabilidade no setor sementeiro. **Diversitas Journal**, v. 6, p. 2996-3012, 2021.

SÁ, F. V. S.; SILVA, I. E.; FERREIRA NETO, M.; LIMA, Y. B.; PAIVA, E. P.; GHEYI, H. R. Phosphorus doses alter the ionic homeostasis of cowpea irrigated with saline water. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 25, p. 372-379, 2021.

SÁNCHEZ-NAVARRO, V.; ZORNOZA, R.; FAZ, A.; FERNÁNDEZ, J. A. Cowpea Crop Response to Mineral and Organic Fertilization in SE Spain. **Processes**, v. 9, p. 822, 2021.

SILVA, N. V.; LINHARES, P. C. F.; SOUSA, R. P.; ASSIS, J. P.; CARDOSO, E. A.; PEREIRA, J. O.; MARTINS, W. R.; ALVES, L. S.; SANTOS, M. F. A.; NOGUEIRA, G. S. L. R.; FARIAS, J. R. S. Biometry of Seeds of Caupi Beans Cream Varieties Cultivated in Northeast Brazil. **Journal of Agricultural Science**, v. 12, p. 239-244, 2020.

SILVA, V. M.; NARDELI, A. J.; MENDES, N. A. C.; ROCHA, M. M.; WILSON, L.; YOUNG, S. D.; BROADLEY, M. R.; WHITE, P. J.; REIS, A. R. Agronomic biofortification of cowpea with zinc: Variation in primary metabolism responses and grain nutritional quality among 29 diverse genotypes. **Plant Physiology and Biochemistry**, v. 162, p. 378-387, 2021.

SOLTABAYEVA, A.; ONGALTAY, A.; OMONDI, J. O.; SRIVASTAVA, S. Morphological, Physiological and Molecular Markers for Salt-Stressed Plants. **Plants**, v. 10, p. e243, 2021.

SUJATHA, R.; CHATTERJEE, J. M.; JHANJHI, N.; BROHI, S. N. Performance of deep learning vs machine learning in plant leaf disease detection. **Microprocessors and Microsystems**, v. 80, p. e103615, 2021.

SUN, Q.; XIA, X.; CHAI, X. Machine Vision Based Phenotype Recognition of Plant and

Animal. In: Chinese Academy of Sciences (Eds). **China's e-Science: Blue Book 2020**. Singapore: Springer, 2021.

TAVARES, D. S.; FERNANDES, T. E. K.; RITA, Y. L.; ROCHA, D. C.; SANT'ANNA-SANTOS, B. F.; GOMES, M. P. Germinative metabolism and seedling growth of cowpea (*Vigna unguiculata*) under salt and osmotic stress. **South African Journal of Botany**, v. 139, p. 399-408, 2021.

TOYINBO, J. O.; FATOKUN, C.; BOUKAR, O.; FAKOREDE, M. A. B. Genetic variability and trait association under thrips (*Megalurothrips sjostedti* Trybom) infestation in cowpea (*Vigna unguiculata* [L.] Walp.). **Euphytica**, v. 217, p. e110, 2021.

VITAL, A. F. M.; SOUZA, T.; SILVA, L. J. R.; SANTOS, R. V.; SILVA, S. I. A.; NASCIMENTO, G. S.; SANTOS, D. Biomass production and macronutrient content in *Pennisetum glaucum* (L.) R. Brown as affected by organic fertilization and irrigation. **Revista Brasileira de Ciências Agrárias**, v. 15, p. e8576, 2020.

XIONG, J.; YU, D.; LIU, S.; SHU, L.; WANG, X.; LIU, Z. A Review of Plant Phenotypic Image Recognition Technology Based on Deep Learning. **Electronics**, v. 10, p. e81, 2021.