



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

JONIEDSON MARCOS DOS SANTOS

**INTELIGÊNCIA ARTIFICIAL PARA FENOTIPAGEM DE GENÓTIPOS
PROMISSORES DE FEIJÃO-CAUPI POR IMAGENS DIGITAIS EM
DIFERENTES ESTÁDIOS FENOLÓGICOS**

**SUMÉ - PB
2023**

JONIEDSON MARCOS DOS SANTOS

**INTELIGÊNCIA ARTIFICIAL PARA FENOTIPAGEM DE GENÓTIPOS
PROMISSORES DE FEIJÃO-CAUPI POR IMAGENS DIGITAIS EM
DIFERENTES ESTÁDIOS FENOLÓGICOS**

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, Joniedson Marcos dos.

Inteligência artificial para fenotipagem de genótipos promissores de feijão-caupi por imagens digitais em diferentes estádios fenológicos. / Joniedson Marcos dos Santos. - 2023.

26 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. Feijão-caupi. 2. Inteligência artificial. 3. Imagens digitais. 4. Fenotipagem - genótipos. 5. Estádios fenológicos - feijão-caupi. 6. Rede neural artificial. 7. Aprendizagem de máquina. 8. Algoritmos de inteligência artificial. I. Ferraz, Rener Luciano de Souza. II. Título.

CDU: 581.8(043.1)

Elaboração da Ficha Catalográfica:

Johnny Rodrigues Barbosa
Bibliotecário-Documentalista
CRB-15/626

JONIEDSON MARCOS DOS SANTOS

**INTELIGÊNCIA ARTIFICIAL PARA FENOTIPAGEM DE GENÓTIPOS
PROMISSORES DE FEIJÃO-CAUPI POR IMAGENS DIGITAIS EM
DIFERENTES ESTÁDIOS FENOLÓGICOS**

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 Me. Igor Eneas Cavalcante
Examinador Externo I - CCA/UFPB**

**Me. Semako Ibrahim Bonou
Examinador Externo II - UAEA/CTRN/UFCG**

**Professora Dra. Patrícia da Silva Costa
Examinadora Externa III - FAPESQ-PB**

Trabalho aprovado em: 16 de fevereiro de 2023

SUMÉ-PB

AGRADECIMENTOS

Quero primeiramente agradecer a Deus por todas as bênçãos concedidas a mim.

À minha mãe, Maria Dapaz dos Santos, ao meu pai, José Luciano dos santos.

Agradeço ao meu orientador, Professor Rener Luciano de Souza Ferraz, pela dedicação, incentivo, além de professor é também um amigo.

Aos meus companheiros de curso Franco Vanderley Souto da Silva, Marcelo Eduardo dos Santos, José Ilton Perreira Alves, Gabriel de Azevedo Batista, Lucas Mayan Morreira da Silva, Davi de Jesus, Ana Clara Perreira, Maria Islane, Maria Iasmim, Rosana Lucena e Maria Fernanda Guenes da Silva uma pessoa muito especial na minha graduação amiga que o projeto me deu.

RESUMO

O feijão-caupi é uma cultura de grande importância mundial, motivo pelo qual muitas cultivares melhoradas são exploradas. As plantas dessas cultivares possuem características intrínsecas que as distinguem. Nesse contexto, objetivou-se avaliar algoritmos de inteligência artificial para ajuste de modelos de fenotipagem de cultivares de feijão-caupi por imagens digitais em diferentes estádios fenológicos. Para tanto, imagens digitais obtidas nos estádios V1, V2, V3 e V4 de nove cultivares foram 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). A performance dos modelos foi testada utilizando-se do método de validação cruzada (Cross-validation). O algoritmo de aprendizado de máquina Rede Neural Artificial tem melhor performance para fenotipagem não destrutiva de cultivares melhoradas de feijão-caupi por imagens digitais em diferentes estádios fenológicos na fase vegetativa.

Palavras-chave: *Vigna unguiculata*; classificação fenotípica; aprendizagem de máquina.

SANTOS, Joniedson Marcos dos. **Artificial intelligence for phenotyping of promising cowbean genotypes by digital images at different phenological stages**. 2023. 26f. (Course Completion Work - Monograph), Curso Superior de Tecnologia em Agroecologia, Centro de Desenvolvimento Sustentável do Semiárido, Universidade Federal de Campina Grande, Sumé – Paraíba – Brasil, 2023.

ABSTRACT

Cowpea is a crop of great importance worldwide, which is why many improved cultivars are exploited. The plants of these cultivars have intrinsic characteristics that distinguish them. In this context, the objective was to evaluate artificial intelligence algorithms to fit cowpea cultivar phenotyping models by digital images at different phenological stages. For this purpose, digital images obtained at stages V1, V2, V3 and V4 of nine cultivars were processed using the vectors InceptionV3, SqueezeNet, VGG16 and VGG19. Subsequently, the k-nearest neighbors (KNN - number of nearest neighbors), decision tree (Tree), random forest (RF - Random Forest), gradient boost (GB - Gradient Boosting), vector support machine (SVM - Support Vector Machines) and artificial neural network (MLP - Multi-Layer Perceptron). The performance of the models was tested using the cross-validation method. The Artificial Neural Network machine learning algorithm has better performance for non-destructive phenotyping of cowpea cultivars improved by digital images at different phenological stages in the vegetative phase.

Keywords: *Vigna unguiculata*; phenotypic classification; machine learning.

LISTA DE FIGURAS

- Figura 1** - Localização da Fazenda Experimental do CDSA, com destaque para a área onde foi realizado o cultivo das cultivares de feijão-caupi. _____ 14
- Figura 2** - Manejo de irrigação utilizando-se do método de irrigação localizada. Fonte: Acervo da equipe de pesquisa. _____ 16
- Figura 3** - Coleta do solo (A), instalação do sistema de irrigação (B), demarcação das parcelas para semeadura (C), emergência das plântulas (D), obtenção de fotos (E) e visão parcial da área experimental (F) _____ 17
- Figura 4** - Resumo do fluxo de trabalho do processamento de imagens e ajuste de modelos de aprendizagem de máquina para fenotipagem de cultivares de feijão-caupi nos estádios fenológicos. _____ 19

LISTA DE TABELAS

Tabela 1 - Estatísticas de desempenho dos Embedder na etapa de modelagem para fenotipagem de feijão-caupi nos estádios fenológicos. Sumé, PB, 2022. _____	20
Tabela 2 - Matriz de confusão para a performance da Rede Neural Artificial com a função de ativação Logistic e solver Adam para fenotipagem de feijão-caupi no estádio fenológico V1. Sumé, PB, 2022. _____	21
Tabela 3 - Matriz de confusão para a performance da Rede Neural Artificial com a função de ativação ReLu e solver L-BFGS-B para fenotipagem de feijão-caupi no estádio fenológico V2. Sumé, PB, 2022. _____	22
Tabela 4 . Matriz de confusão para a performance da Rede Neural Artificial com a função de ativação Tan Hiperbólica e solver L-BFGS-B para fenotipagem de feijão-caupi no estádio fenológico V3. Sumé, PB, 2022. _____	23
Tabela 5 - Matriz de confusão para a performance da Rede Neural Artificial com a função de ativação Logistic e solver Adam para fenotipagem de feijão-caupi no estádio fenológico V4. Sumé, PB, 2022. _____	24

SUMÁRIO

1	INTRODUÇÃO.....	13
2	OBJETIVOS.....	11
2.1	OBJETIVO GERAL.....	11
2.2	OBJETIVOS ESPECÍFICOS.....	11
3	REVISÃO DE LITERATURA.....	12
4	MATERIAL E MÉTODOS.....	14
5	RESULTADOS E DISCUSSÃO.....	20
6	CONCLUSÃO.....	26
	REFERÊNCIAS.....	27

1 INTRODUÇÃO

Mudanças climáticas globais provocam alterações da distribuição espaço temporal das precipitações pluviométricas, isso ocasiona déficit de água nos agroecossistemas e redução de crescimento e produtividade das culturas, fato que evidencia a necessidade de cultivo de genótipos melhorados geneticamente para adaptação aos ambientes de cultivo, por exemplo, cultivares de feijão-caupi (*Vigna unguiculata* (L.) Walp.) com atributos de interesse aos agricultores (MARTEY *et al.*, 2021).

O feijão-caupi desempenha importante papel nutricional, pois, é utilizado para alimentação humana, forragem animal e adubo verde, além de contribuir para o desenvolvimento econômico, social e ambiental, principalmente em regiões áridas e semiáridas. Nessas regiões, limitações hídricas no continuum solo-planta-atmosfera

provocam reduções da germinação, do crescimento e estabelecimento das plantas no campo e isso reduz a produção de grãos do feijão-caupi (TAVARES *et al.*, 2021).

Em decorrência das condições edafoclimáticas proeminentes das regiões áridas e semiáridas, genótipos de feijão-caupi promissores para cultivo nessas regiões vêm sendo desenvolvidos pelos programas de melhoramento genético (MARINHO; LESSA; COSTA, 2021; NARAYANA; ANGAMUTHU, 2021). A grande diversidade de genótipos melhorados evidencia a necessidade de desenvolvimento de ferramentas tecnológicas para facilitar a identificação das plantas de cada genótipo no campo em diferentes estádios fenológicos.

A necessidade supra mencionada lança luz ao emprego de técnicas avançadas de fenotipagem para formulação e análise quantitativa de características complexas das plantas. Nessa perspectiva, as técnicas baseadas em visão computacional para aprendizado de máquina a partir de inteligência artificial constituem um avanço tecnológico para a agricultura, notadamente, devido ao fato de realizarem fenotipagem de plantas em larga escala e de forma não destrutiva a partir de imagens digitais (HATI; SINGH, 2021).

Com base no exposto, o emprego de técnicas de inteligência artificial para aprendizado de máquina introduz uma alternativa tecnológica promissora para evolução dos agroecossistemas em regiões áridas e semiáridas, por exemplo no Nordeste do Brasil (MENEZES NETO *et al.*, 2021), onde há necessidade de identificação fenotípica genótipos de feijão-caupi ecoadaptados e promissores para elevado rendimento de grãos.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Avaliar algoritmos de inteligência artificial para ajuste de modelos de fenotipagem e identificação de genótipos promissores de feijão-caupi por imagens digitais em diferentes estádios fenológicos.

2.2 OBJETIVOS ESPECÍFICOS

Obtenção de sementes dos genótipos de feijão-caupi melhorados e promissores para cultivo nos agroecossistemas do semiárido brasileiro.

Realizar o cultivo de campo dos genótipos de feijão-caupi melhorados e promissores para cultivo nos agroecossistemas do semiárido brasileiro.

Obtenção de imagens digitais de diversas plantas em cada estágio fenológico dos genótipos promissores de feijão-caupi.

Processar imagens digitais, treinar algoritmos de inteligência artificial para ajuste de modelos de fenotipagem e identificação dos genótipos promissores de feijão-caupi.

Avaliar a performance dos modelos ajustados para fenotipagem e identificação dos genótipos promissores de feijão-caupi.

3 REVISÃO DE LITERATURA

Atualmente, existem muitos genótipos de feijão-caupi lançados como cultivares pelos programas de melhoramento genético da cultura (GOMES *et al.*, 2021; MARINHO; LESSA; COSTA, 2021; NARAYANA; ANGAMUTHU, 2021). Esses genótipos 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 agrônômica 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 fenotipagem, identificação e classificação de genótipos de feijão-caupi.

Tradicionalmente, a fenotipagem de genótipos de feijão-caupi é 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; LESSA; COSTA, 2021). 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, corda vagem durante a maturação, número de vagens por planta e número de sementes por vagem.

De acordo com Oliveira *et al.* (2015), a fenotipagem clássica dos genótipos 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).

A fenotipagem por inteligência artificial é um processo de fundamental importância para o melhoramento genéticos de plantas e suporte à agricultura de precisão (SUN; XIA; CHAI, 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 fenotipagem de plantas de interesse econômico, social e ambiental (XIONG *et al.*, 2021).

A tecnologia de fenotipagem 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 fenotipagem e identificação de genótipos dessa espécie.

4 MATERIAL E MÉTODOS

Sementes das cultivares melhoradas de feijão-caupi foram obtidas do banco de germoplasma do Instituto Agrônomo de Pernambuco (IPA). Foram utilizados os genótipos da Subclasse Comercial Branco rugoso (BRS Novaera), Subclasse Comercial Branco liso (BRS Guariba, BRS Potengi e BRS Cauamé), Subclasse Comercial Cores – Mulato (BRS Pajeú, BRS Miranda, BRS Pingo-de-Ouro e IPA 206), Subclasse comercial Preto-Brilhoso (BRS Tapahium).

O cultivo de feijão-caupi foi realizado no Campo Experimental 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 (Figura 1).

Figura 1 - Localização da Fazenda Experimental do CDSA, com destaque para a área onde foi realizado o cultivo das cultivares de feijão-caupi.



Fonte: Google Maps. Sumé, PB, 2022.

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). Durante o cultivo, dados meteorológicos foram coletados de uma estação agrometeorológica automática instalada próximo da área, cujos resultados médios diários estão descritos a seguir: precipitação total 2,31 mm; temperatura máxima 31,22 °C; temperatura média 24,95 °C; temperatura mínima 19,63 °C; umidade relativa do ar 73,05%; umidade relativa do ar mínima 70,39%; e velocidade do vento 1,91 m s⁻¹.

Antes do início do cultivo, foram realizadas amostras de solo representativas da área,

na profundidade de 20 cm, para determinação das propriedades físico-químicas do solo. As amostras foram analisadas de acordo com os métodos do IITA (1979), de Black (1965), Olsen *et al.* (1954) e Okalebo, Gathua e Woomer (1993), cujos resultados físicos foram: granulometria – areia 68,12%, silte 26,46% e argila 5,42%; classificação textural franco arenoso; densidade do solo 1,27 g cm⁻³; densidade de partículas 2,69 g cm⁻³; porosidade 52,79%; umidade – natural 0,40%, 0,33 atm 14,51% e 15,00 atm 5,86%; e água disponível 8,65.

Os resultados químicos foram: cálcio 7,75 meq 100 g⁻¹ de solo; magnésio 5,85 meq 100 g⁻¹ de solo; sódio 0,38 meq 100 g⁻¹ de solo; potássio 0,68 meq 100 g⁻¹ de solo; enxofre 14,66 meq 100 g⁻¹ de solo; hidrogênio 0,00 meq 100 g⁻¹ de solo; alumínio 0,00 meq 100 g⁻¹ de solo; T 14,66 meq 100 g⁻¹ de solo; carbonato de cálcio qualitativo – ausência; carbono orgânico 0,78%; matéria orgânica 1,34%; nitrogênio 0,08%; fósforo assimilável meq 3,28 100 g⁻¹ de solo; pH H₂O (1:2,5) 7,81; pH KCl (1:2,5) – não quantificado; condutividade elétrica (suspensão Solo-Água) 0,49 mmhos cm⁻¹; pH (extrato de saturação) 7,75; condutividade elétrica (extrato de saturação) 0,70 mmhos cm⁻¹; cloreto 3,75 meq L⁻¹; carbonato 0,00 meq L⁻¹; bicarbonato 2,10 meq L⁻¹; sulfato – ausência; cálcio 2,25 meq L⁻¹; magnésio 3,87 meq L⁻¹; potássio 0,56 meq L⁻¹; sódio 3,39 meq L⁻¹; saturação 33,33%; relação de adsorção de sódio 1,94; PSI 2,59; salinidade – não salino; e classe do solo – normal. Com base nos resultados, foi realizada adubação de cobertura para a cultura do feijão-caupi, conforme descrito por Sá *et al.* (2021).

Para cada cultivar melhorada, foram implantadas cinco parcelas, cada uma formada por três linhas de 2,0 m de comprimento, espaçadas de 0,5 m, com área da parcela de 5 m² e total de 25 m². A semeadura foi realizada utilizando-se de uma semente por cova, sendo espaçadas em 0,5 m entre linhas x 0,1 m entre plantas, resultado em uma densidade de 12 plantas por metro quadrado.

O manejo de irrigação foi realizado diariamente com base no monitoramento climático, por meio de dados obtidos da estação agrometeorológica. A evapotranspiração de referência (ET_o) foi calculada pelo método de Penman-Monteith – FAO (ALLEN *et al.*, 1998) e a evapotranspiração da cultura (ET_c) calculada com base no coeficiente da cultura (K_c) em cada estágio fenológico (MENDONÇA *et al.*, 2015). A reposição da água evapotranspirada foi realizada utilizando-se do método de irrigação localizada e um sistema de irrigação tipo gotejamento (Figura 2).

Figura 2 - Manejo de irrigação utilizando-se do método de irrigação localizada. Fonte: Acervo da equipe de pesquisa.



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

O manejo de plantas espontâneas foi realizado semanalmente por método mecânico utilizando-se de enxadas e arranquio manual nas proximidades das plantas. Para o controle de insetos praga, foi utilizado o óleo e extrato vegetal de nim (*Azadirachta indica* A. Juss), conforme recomendação de Silva *et al.* (2011) para a cultura do feijão-caupi.

Foram obtidas imagens digitais (n = 125) das plantas de cada genótipo de feijão-caupi nos estádios fenológicos descritos por Mendonça *et al.* (2015), a saber: (V1) segundo nó do ramo principal com folíolos completamente abertos; (V2) terceiro nó do ramo principal com folíolos completamente abertos; (V3) quarto nó do ramo principal com folíolos completamente abertos; e (V4) quinto nó do ramo principal com folíolos completamente abertos (Figura 3).

Figura 3 - Coleta do solo (A), instalação do sistema de irrigação (B), demarcação das parcelas para semeadura (C), emergência das plântulas (D), obtenção de fotos (E) e visão parcial da área experimental (F).



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

As imagens foram obtidas utilizando-se de câmera digital da marca Nikon, modelo COOLPIX P530 V1.0, configurada para ISO de 400 e resolução de 16 MB e dimensões da imagem de 4608 x 3456 de comprimento e largura, respectivamente e 300 DPI (*Dots Per Inch* ou pontos por polegadas). As imagens foram capturadas no modo RGB de 8 bits e salvas no formato .jpeg. Das 125 imagens, 25 foram obtidas na posição relativa ao ângulo de 90° em relação ao solo, 25 na posição relativa ao ângulo de 45° na direção Norte, 25 na posição relativa ao ângulo de 45° na direção Sul, 25 na posição relativa ao ângulo de 45° na direção Leste e 25 na posição relativa ao ângulo de 45° na direção Oeste, todas a 1 m de distância.

Para processamento das imagens foi utilizado *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 de fenotipagem dos genótipos 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 testada utilizando-se o método de amostragem do *Orange Data Mining* validação cruzada (Cross-validation).

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) (Figura 4).

5 RESULTADOS E DISCUSSÃO

Na Tabela 1 é possível observar o resumo das estatísticas de desempenho dos Embedders, algoritmos de inteligência artificial, função de ativação e solver na etapa de ajuste de modelos para fenotipagem de feijão-caupi por imagens digitais nos estádios fenológicos V1, V2, V3 e V4. Nos estádios V1, V2 e V3, verificou-se que o *Embedder* VGG16 e o algoritmo Rede Neural Artificial obtiveram melhor performance. Melhorias no desempenho dos modelos foram possíveis utilizando a função de ativação logística operando com o solver Adam nos estádios V1 e V4, função de ativação ReLu operando com solver L-BFGS-B para o estádio V2 e função de ativação Tan hiperbólica operando com o solver L-BFGS-B para o estádio V3.

Tabela 1 - Estatísticas de desempenho dos Embedder na etapa de modelagem para fenotipagem de feijão-caupi nos estádios fenológicos. Sumé, PB, 2022.

Modelos de IA	Train time	Test time	AUC	CA	F1	Precision	Recall	LogLoss	Specificity
Estádio fenológico V1 - Embedder VGG 16, Logistic, Adam									
Neural Network	97,823	6,512	0,999	0,986	0,986	0,986	0,986	0,071	0,998
Estádio fenológico V2 – Embedder VGG 16, ReLu, L-BFGS-B									
Neural Network	22,813	5,880	0,999	0,995	0,995	0,996	0,995	0,017	0,999
Estádio fenológico V3 – Embedder VGG 16, Tan hiperbólica, L-BFGS-B									
Neural Network	22,197	5,220	0,999	0,995	0,995	0,995	0,995	0,032	0,999
Estádio fenológico V4 – Embedder VGG 19, Logistic, Adam									
Neural Network	71,367	7,499	1,000	0,997	0,997	0,997	0,997	0,022	0,999

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.

Verificou-se que, no estádio fenológico V1, a Rede Neural Artificial classificou corretamente 100% das amostras de imagens das cultivares BRS Cauamé e IPA 206, enquanto para a cultivar BRS Miranda a taxa de acerto foi de 99%, para as cultivares BRS Pingo de ouro, BRS Grariba, BRS Novaera e BRS Pajeú a taxa de classificação correta foi de 98% e, por fim, a taxa de acerto foi de 97% para BRS Potengi (Tabela 2).

Tabela 2 - Matriz de confusão para a performance da Rede Neural Artificial com a função de ativação Logistic e solver Adam para fenotipagem de feijão-caupi no estágio fenológico V1. Sumé, PB, 2022.

		Valores preditos pelo modelo									
Cultivares	BRS	BRS	BRS	BRS	BRS	BRS	BRS	BRS	IPA	Σ	
	Cauamé	Guariba	Miranda	Novaera	Pajeú	Pingo de ouro	Pontegi	Tapaihum	206		
BRS Cauamé	100	0	0	0	0	0	0	0	0	100	
BRS Guariba	1	98	0	0	0	0	0	0	1	100	
BRS Miranda	0	0	99	0	0	0	1	0	0	100	
BRS Novaera	0	0	0	98	0	1	1	0	0	100	
BRS Pajeú	0	0	2	0	98	0	0	0	0	100	
BRS Pingo de ouro	0	0	1	0	0	91	1	0	0	93	
BRS Potengi	2	1	0	0	0	0	93	0	0	96	
BRS Tapaihum	0	0	0	0	0	0	0	76	0	76	
IPA 206	0	0	0	0	0	0	0	0	100	100	
Σ	103	99	102	98	98	92	96	76	101	865	

Fonte: Elaboração da equipe de pesquisa.

No estágio fenológico V2, o modelo de Rede Neural Artificial teve taxa de 100% de acerto na predição do fenótipo das cultivares BRS Cauamé, BRS Guariba, BRS Miranda, BRS Novaera, BRS Pajeú, BRS Tapaihum e IPA 206, enquanto que para as cultivares BRS Potengi e BRS Pingo de ouro a taxa de acerto foi de 98% (Tabela 3).

Tabela 3 - Matriz de confusão para a performance da Rede Neural Artificial com a função de ativação ReLu e solver L-BFGS-B para fenotipagem de feijão-caupi no estágio fenológico V2. Sumé, PB, 2022.

		Valores preditos pelo modelo									
Cultivares	BRS	BRS	BRS	BRS	BRS	BRS	BRS	BRS	BRS	IPA	Σ
	Cauamé	Guariba	Miranda	Novaera	Pajeú	Pingo de ouro	Pontegi	Tapaihum	206		
BRS Cauamé	60	0	0	0	0	0	0	0	0	0	60
BRS Guariba	0	40	0	0	0	0	0	0	0	0	40
BRS Miranda	0	0	40	0	0	0	0	0	0	0	40
BRS Novaera	0	0	0	40	0	0	0	0	0	0	40
BRS Pajeú	0	0	0	0	80	0	0	0	0	0	80
BRS Pingo de ouro	0	0	0	0	0	55	1	0	0	0	56
BRS Potengi	0	0	1	0	0	0	59	0	0	0	60
BRS Tapaihum	0	0	0	0	0	0	0	60	0	0	60
IPA 206	0	0	0	0	0	0	0	0	0	60	60
Σ	60	40	41	40	80	55	60	60	60	60	496

Fonte: Elaboração da equipe de pesquisa.

Verificou-se que, no estágio fenológico V3, a Rede Neural Artificial classificou corretamente 100% das amostras de imagens de folhas das cultivares BRS Cauamé, IPA 206, BRS Miranda, BRS Pajeú, BRS Novaera, BRS Guariba e BRS Potengi, enquanto que para as cultivares, BRS Pingo de ouro e BRS Tapaihum a taxa de classificação correta foi de 98% (Tabela 4).

Tabela 4 - Matriz de confusão para a performance da Rede Neural Artificial com a função de ativação Tan Hiperbólica e solver L-BFGS-B para fenotipagem de feijão-caupi no estágio fenológico V3. Sumé, PB, 2022.

		Valores preditos pelo modelo									
Cultivares	BRS	BRS	BRS	BRS	BRS	BRS	BRS	BRS	BRS	IPA	Σ
	Cauamé	Guariba	Miranda	Novaera	Pajeú	Pingo de ouro	Pontegi	Tapaihum	206		
BRS Cauamé	60	0	0	0	0	0	0	0	0	0	60
BRS Guariba	0	40	0	0	0	0	0	0	0	0	40
BRS Miranda	0	0	40	0	0	0	0	0	0	0	40
BRS Novaera	0	0	0	40	0	0	0	0	0	0	40
BRS Pajeú	0	0	0	0	14	0	0	0	0	0	14
BRS Pingo de ouro	0	0	0	0	0	59	0	0	0	1	60
BRS Potengi	0	0	0	0	0	0	59	0	0	0	59
BRS Tapaihum	0	0	1	0	0	0	0	59	0	0	60
IPA 206	0	0	0	0	0	0	0	0	0	60	60
Σ	60	40	41	40	14	59	59	59	59	61	433

Fonte: Elaboração da equipe de pesquisa.

No estágio fenológico V4, é possível observar na Tabela 5 que a Rede Neural Artificial teve taxa de acerto de 100% para as cultivares de feijão-caupi estudadas, exceto para a cultivar BRS Potengi que em que a taxa de classificação correta foi de 98%.

Tabela 5 - Matriz de confusão para a performance da Rede Neural Artificial com a função de ativação Logistic e solver Adam para fenotipagem de feijão-caupi no estádio fenológico V4. Sumé, PB, 2022.

		Valores preditos pelo modelo									
Cultivares		BRS	BRS	BRS	BRS	BRS	BRS	BRS	BRS	IPA	Σ
		Cauamé	Guariba	Miranda	Novaera	Pajeú	Pingo de ouro	Pontegi	Tapaihum	206	
Valores reais	BRS Cauamé	37	0	0	0	0	0	0	0	0	37
	BRS Guariba	0	60	0	0	0	0	0	0	0	60
	BRS Miranda	0	0	60	0	0	0	0	0	0	60
	BRS Novaera	0	0	0	60	0	0	0	0	0	60
	BRS Pajeú	0	0	0	0	20	0	0	0	0	20
	BRS Pingo de ouro	0	0	0	0	0	40	0	0	0	40
	BRS Potengi	0	1	0	0	0	0	39	0	0	40
	BRS Tapaihum	0	0	0	0	0	0	0	20	0	20
	IPA 206	0	0	0	0	0	0	0	0	40	40
	Σ	37	61	60	60	20	40	39	20	40	377

Fonte: Elaboração da equipe de pesquisa.

A classificação de imagens de feijão-caupi com alta precisão por meio de uma rede neural artificial pode ser explicada por uma combinação de fatores técnicos (MIQUELONE *et al.*, 2018; SILVA *et al.*, 2020). Alguns desses fatores incluem o uso de um grande conjunto de dados para treinamento da rede neural, a aplicação de técnicas avançadas de processamento de imagem, como convoluções e *pooling*, a escolha adequada da arquitetura da rede neural, a utilização de técnicas de regularização e a seleção cuidadosa dos dados de treinamento.

No entanto, vale ressaltar que a acurácia da classificação não é garantida somente pela utilização desses fatores técnicos. É necessário considerar também outros aspectos, como a qualidade dos dados de treinamento e a capacidade da rede neural de generalizar para novos dados que não foram incluídos no conjunto de treinamento (DÖNMEZ, 2022).

A questão da interpretabilidade dos resultados também é importante, especialmente em aplicações práticas em que é necessário entender como a rede neural chegou a uma

determinada classificação. Nesse sentido, a interpretabilidade é um desafio em redes neurais profundas, pois o processo de aprendizado é feito por meio da análise de padrões complexos em várias camadas da rede neural (MAHMOOD; CHOI; RYOUNG, 2023).

Em resumo, a classificação de imagens de feijão-caupi com alta acurácia por meio de uma rede neural artificial é um resultado promissor, mas deve ser avaliada com cuidado em relação a diversos fatores técnicos, qualidade dos dados, capacidade de generalização e interpretabilidade dos resultados (SILVA *et al.*, 2020).

6 CONCLUSÃO

O algoritmo de aprendizado de máquina Rede Neural Artificial tem melhor performance para fenotipagem não destrutiva de cultivares melhoradas de feijão-caupi por imagens digitais em diferentes estádios fenológicos na fase vegetativa.

REFERÊNCIAS

ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. **Crop evapotranspiration: guidelines for computing crop water requirements**. Roma: FAO, 1998. 300p. (Irrigation and Drainage Paper, 56).

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.

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

BLACK, C. A. **Methods of soil analysis**. Part 1. Physical and mineralogical properties, including statistics of measurement and sampling, 9.1. Madison: American Society of Agronomy, 1965. 770p.

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.

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.

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.

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. 116, 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, 1986. p. 27.

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, 1981. p. 45.

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. 4551, 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. 991, 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.

IITA - INTERNATIONAL INSTITUTE OF TROPICAL AGRICULTURE. **Selected methods for soil and plant analysis**. Ibadan: IITA Manual Services, 1979. 57p.

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.

MENDONÇA, C. A.; BARROSO NETO, A. M.; BERTINI, C. H. C. M.; AMORIM, M. Q.; ARAÚJO, L. B. R. Caracterização fenológica associada a graus-dia em genótipos de feijão-caupi para produção de grãos verdes. **Enciclopédia Biosfera**, v. 11, p. 485-493, 2015.

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**. Woodhead Publishing, 2021.

OKALEBO, J. R.; GATHUA, K. W.; WOOPER, P. L. **Laboratory methods of plant and soil analysis: a working manual**. Nairobi: Tropical Soil Biology and Fertility Programme, 1993. 88p.

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.

OLSEN, S. R.; COLE, C. V.; WATANABLE, F. S.; DEAN, L. A. **Estimation of available phosphorous in soils by extraction with Sodium bicarbonate**. Washington: United State Department of Agriculture, 1954. 22p.

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, D. C. O.; ALVES, J. M. A.; ALBUQUERQUE, J. A. A.; LIMA, A. C. S.; VELOSO, M. E. S.; SILVA, L. S. Controle de insetos-praga do feijão-caupi na savana de Roraima. **Revista Agro@ambiente On-line**, v. 5, p. 212-219, 2011.

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. 243, 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**. Springer, Singapore. 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, 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.