



ISSN: 2230-9926

Available online at <http://www.journalijdr.com>

IJDR

International Journal of Development Research

Vol. 11, Issue, 05, pp. 47378-47384, May, 2021

<https://doi.org/10.37118/ijdr.22009.05.2021>



RESEARCH ARTICLE

OPEN ACCESS

APLICAÇÃO DE APRENDIZADO DE MÁQUINA PROFUNDO PARA DETECÇÃO POR IMAGENS DE DOENÇAS EM FRUTOS DO CACAUEIRO

Maria Eliana da Silva Holanda, Edson Magalhaes da Costa, Dhian Kelson Leite de Oliveira, Paulo Victor Cunha Lima, Esley Teixeira do Espirito Santo, Luiz Henrique Dias Ramos, Lucas Henrique Martins Soares, Ramon Campelo Ramos, Joaquim dos Santos Costa, Isadora Mendes dos Santos, Jakelyne Machado Lima Silva, Gilberto Nerino de Souza Júnior e Marcus de Barros Braga*

Universidade Federal Rural da Amazônia, Campus Paragominas, Pará, Brasil

ARTICLE INFO

Article History:

Received 10th February, 2021

Received in revised form

20th March, 2021

Accepted 14th April, 2021

Published online 30th May, 2021

Key Words:

Cocoa, Black Pod Rot, Pod Borer, Machine Learning, Data Augmentation, Convolutional Neural Networks.

*Corresponding author:

Marcus de Barros Braga

ABSTRACT

The state of Pará is the largest cocoa producer in Brazil, with 51% of national production, involving 26 thousand producers, generating 64 thousand direct and 225 thousand indirect jobs. However, diseases that affect this culture are responsible for high losses in yield. This study presents an approach based on deep learning to identify diseases that affect the cocoa culture. A public database with 4,389 fruit images was used, covering the diseases black pod rot and pod borer. The experiments using the techniques of data augmentation and convolutional neural networks (CNN) indicate an average accuracy of 95% in the images' classification. In this way, the present work aims to contribute effectively proposing a tool that can help in the improvement of the cocoa production chain in the state of Pará.

Copyright © 2021, Maria Eliana da Silva Holanda et al. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Citation: Maria Eliana da Silva Holanda, Edson Magalhaes da Costa, Dhian Kelson Leite de Oliveira, Paulo Victor Cunha Lima, Esley Teixeira do Espirito Santo, Luiz Henrique Dias Ramos, Lucas Henrique Martins Soares, Ramon Campelo Ramos, Joaquim dos Santos Costa, Isadora Mendes dos Santos, Jakelyne Machado Lima Silva, Gilberto Nerino de Souza Júnior e Marcus de Barros Braga. "Aplicação de aprendizado de máquina profundo para detecção por imagens de doenças em frutos do cacau", *International Journal of Development Research*, 11, (05), 47378-47384.

INTRODUCTION

O cacau (*Theobroma cacao*) é uma planta umbrófila de porte arbóreo, nativa da região Amazônica, que pode ser encontrada em plantações comerciais em seis estados brasileiros. É uma espécie que exige nutrientes e água, além de solos de média a alta fertilidade e com boas características físicas (Alves Júnior, 2013). Em condições silvestres, o cacau é encontrado no extrato inferior das florestas, em clareiras e beirando os rios, onde existem condições de temperatura e umidade elevadas, típicas de regiões tropicais. A maioria das plantações comerciais estão entre as latitudes 20^o N e 20^o S. O cacau é uma planta cauliflora, ou seja, as flores surgem em almofadas florais no tronco ou nos ramos lenhosos, em uma gema desenvolvida no lugar da axila de uma antiga folha. Anualmente, um cacau adulto pode produzir até mais de 100.000 flores, das quais menos de 5% são fertilizadas e apenas 0,1% se transformam em frutos. As flores não polinizadas caem no período de 48 horas.

Os botões florais iniciam a abertura à tarde, completando o processo na manhã seguinte, nas primeiras horas. Quando as flores, depois de polinizadas, são realmente fertilizadas, permanecem fixadas no pedúnculo para formar o fruto (Bartley, 2005; Muller & Valle, 2012). O fruto do cacau é alongado e sulcado, sustentado por um pedúnculo lenhoso, e apresenta uma casca (conhecida como pericarpo carnoso) composta de três partes: Epicarpo - é a parte externa fina e com pigmentação que varia do verde ao roxo e do amarelo ao laranja, à medida que amadurece e dependendo da variedade; Mesocarpo - é a parte mediana, espessa; e Endocarpo - é a fina camada interna que protege as amêndoas. O período compreendido entre a polinização e o amadurecimento do fruto varia de 140 a 205 dias, com uma média de 167 dias. O índice de frutos (número de frutos necessários para obter 1 kg de cacau comercial) é, em geral, de 15 a 31 frutos. A amêndoa de cacau é ovoide e achatada, com 2 a 3 cm de comprimento. É recoberta por uma polpa mucilaginosa (gelatinosa) de coloração branca, de sabor adocicado e ácido, utilizada na fabricação de geleia, vinho, licor, vinagre e suco. O embrião é formado por três partes: a gêmula, a radícula e o caulículo, cujas cores podem variar do branco

ao violeta. A amêndoa seca é comercializada para a fabricação de chocolate, fármacos e cosméticos. Com relação ao ciclo de vida, o cacauero apresenta características de perenidade, podendo ultrapassar os cem anos e, dependendo do manejo, ter desenvolvimento vegetativo com potenciais para boa produtividade (SENAR, 2018; MTCAB, 2013; MAPA, 2014; Valle, 2012). A amêndoa de cacau é o principal produto comercializado, após fermentação e secagem, para fabricação de chocolate, nas diversas formas. Das amêndoas extrai-se também a manteiga, muito utilizada na indústria farmacológica e na fabricação de cosméticos. A polpa que envolve as sementes é rica em açúcares, sendo utilizada na fabricação de geleia, vinho, licor, vinagre e suco (MAPA, 2020).

Na atualidade, o Brasil ocupa o sétimo lugar na produção mundial do cacau, sendo o estado do Pará o maior produtor de cacau do Brasil, com 51% da produção nacional. No estado, a cultura do cacau envolve 26 mil produtores, gerando 64 mil empregos diretos e 225 mil indiretos e movimentando cerca de R\$ 1,1 bilhão (Menezes, 2020; Brito, 2020). Contudo, as doenças que acometem essa cultura são responsáveis por elevadas perdas na produção. O primeiro passo para a redução nos danos provocados pelas doenças no cacauero e seus frutos, é o conhecimento dos diferentes aspectos envolvidos. As pragas ou doenças representam um grande problema na agricultura cacauera. Elas causam impactos diretos na qualidade e produtividade das lavouras, cujas perdas variam de acordo com a cultura e severidade do ataque. Segundo estimativas, ano após ano, o mundo perde entre 20% e 40% dos rendimentos dos cultivos devido aos danos causados por pragas e doenças, enquanto que no Brasil, o valor das perdas anuais, pode chegar em R\$ 55 bilhões. Dentre as doenças fúngicas, as que mais atingem o cacauero no Brasil são a vassoura de bruxa (*Moniliophthora perniciosa*), a podridão parda (*Phytophthora spp.*) e o mal do feijão (*Ceratocystis cacaofunesta*). Lavouras cacaueras também são afetadas por diversos tipos de insetos que interferem na qualidade e na produtividade dos insumos do cacau e dificultam a produção dessa cultura. Um exemplo deste tipo de praga é a broca da vagem (*Conopomorpha cramerella*). Existem também outras doenças de grande importância, como mal rosado (*Erythricium salmonicolor*), podridão de raízes (*Rosellinia sp.*), antracnose (*Colletotrichum gloeosporioides*) e morte súbita (*Verticillium dahliae*) (Tezza, 2021; Oliveira & Luz, 2005; Freitas & Mendes, 2005). Imagens de algumas doenças que acometem o cacau são mostradas na Figura 1.



Figura 1. Exemplos de doenças do cacau. Vassoura de bruxa (esquerda), podridão parda (centro) e broca da vagem (direita).

A podridão parda, se atingir o cultivo de cacau e não for controlada, pode provocar perdas acima de 30% na produção. A infecção pode ser observada em qualquer local e fase de desenvolvimento do fruto. O controle cultural dessas doenças é feito com colheitas frequentes, remoção de frutos infectados, eliminação de casqueiros, poda e drenagem do solo, redução de sombreamento (Tezza, 2021). A doença conhecida como broca da vagem é comum no sul e sudeste asiático e Oceania. Há registros também em Papua Nova Guiné e Samoa (Grahame, 2017). A proliferação desta doença acontece por meio do contato das vagens e folhas com outra vegetação nas quais o transmissor possa estar alojado.

Os ovos destes insetos são muito pequenos, difíceis de se ver a olho nu e as larvas ou vermes vão para a fase pupal dentro das orelhas, para depois se tornarem adultas, se tornando borboletas (Orihuela Pasquel, 2018). O aprendizado de máquina (*machine learning*) é um campo da inteligência computacional que se preocupa com a construção de programas de computador que melhoram

automaticamente com a experiência. Nos últimos dez anos, muitas aplicações bem-sucedidas de aprendizado de máquina foram desenvolvidas, desde programas de mineração de dados, que aprendem a detectar transações fraudulentas com cartões de crédito, sistemas de filtragem de informação que aprendem as preferências de leitura dos usuários, até veículos autônomos, que aprendem a dirigir em rodovias sem a participação de um motorista (Mitchel, 1997; Lecun et al., 2015; Zhu et al., 2018). Um tipo particular de aprendizado de máquina, chamado de aprendizado profundo (*deep learning*, em inglês), permite que modelos computacionais compostos por múltiplas camadas de processamento aprendam representações de dados com múltiplos níveis de abstração. Estes métodos melhoraram drasticamente o que existia de mais avançado em termos de reconhecimento de fala, reconhecimento de imagens e reconhecimento de texto, bem como estabeleceram uma nova fronteira em outros domínios, como descoberta de novas drogas e genômica (Kamilaris & Prenafeta-Boldú, 2018). Com estas novas oportunidades de uso de ciência de dados no domínio multidisciplinar das agrotecnologias, o aprendizado profundo tem sido amplamente estudado e aplicado em diversos segmentos das ciências agrárias. Estas aplicações que podem ajudar os produtores nas lavouras e um bom exemplo são aquelas capazes de identificar e classificar visualmente doenças e pragas que assolam a agricultura. Dentre as muitas técnicas de aprendizado profundo, as redes neurais convolucionais, do inglês *convolutional neural networks (CNN)*, provavelmente, são o modelo mais utilizado. As CNN, como são conhecidas, são uma classe especial de redes neurais artificiais, método bioinspirado, que simula o funcionamento de um conjunto massivo de neurônios para processar paralelamente e rapidamente uma tarefa (Ponti & Costa, 2017).

As redes neurais convolucionais são modelos de aprendizado baseados nas diversas áreas do córtex visual e nas relações destas com regiões específicas do campo de visão. Tais regiões, chamadas de campos receptivos, são responsáveis pela ativação de diferentes neurônios, apresentando um nível de sobreposição entre os campos receptivos de neurônios próximos. Este comportamento cerebral motivou a criação de diferentes sistemas para extração de características específicas a partir dos dados (Oliveira et al., 2018). Uma CNN é composta por diversas camadas que utilizam a operação de convolução para realizar a extração de características das imagens (Goodfellow, 2016; Bengio & Courville, 2016). Esta operação é realizada a partir de uma janela de dados deslizante, chamada de filtro convolutivo, que percorre toda a entrada da rede e opera de forma análoga à sobreposição dos campos receptivos.

O modelo pode conter diversos filtros, cujos valores são ajustados durante o processo de treinamento para a obtenção de características distintas a partir da entrada. Ao final, estas características extraídas se tornam entradas de um algoritmo de aprendizado aplicado à classificação ou regressão, de acordo com o tipo de problema. É comum entre as camadas convolutivas a realização de outras operações para a redução do espaço de características. A mais usual é a camada de subamostragem, ou *pooling*. Outras operações podem ser incluídas também, como normalização e *zeropadding* (Karpathy, 2021). Ao final das camadas convolutivas, toma lugar a operação de *flattening*, ou achatamento, onde a matriz com as características extraídas é colocada na forma de um vetor e assim pode passar para o último estágio, o da rede neural totalmente conectada. Nesta última etapa, normalmente se usa uma ou mais camadas de neurônios totalmente conectados a todas as funções de ativação das camadas anteriores (daí o termo *fully-connected*), de forma análoga às camadas das redes neurais tradicionais, também chamadas de *multilayer perceptron* (Lecun, 2015; Bengio & Hinton, 2015). Uma típica arquitetura de Rede Neural Convolucional é mostrada na Figura 2. Baba et al. (2020), utiliza técnicas de processamento de imagens e aprendizado profundo na cacauicultura. Os autores desenvolveram um sistema de plataforma móvel capaz de classificar os frutos do cacau em três grupos: frutos em condições normais; cacau em condição de ataque de doença e cacau em condição de ataque de pragas. Outras aplicações computacionais semelhantes podem ser encontradas em (Baba, et al. 2019; Baba et al., 2020; Tan et al. 2018).

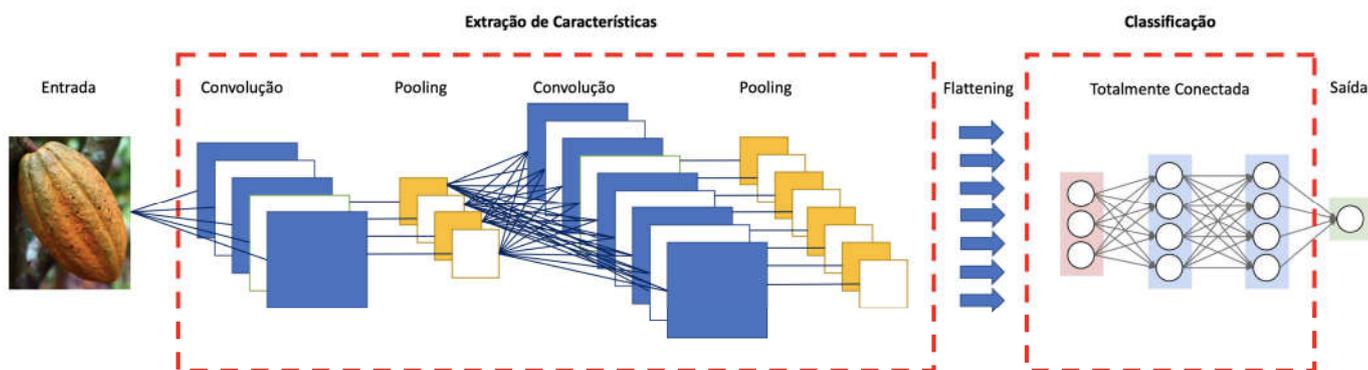


Figura 2. Exemplo de uma Rede Neural Convucional

Tabela 1. Conjunto de Dados Originais (Pagaduan, 2021)

Cacau Saudável	Cacau com Podridão Parda	Cacau com Broca da Vagem	Total de Imagens
3.344	943	103	4.390

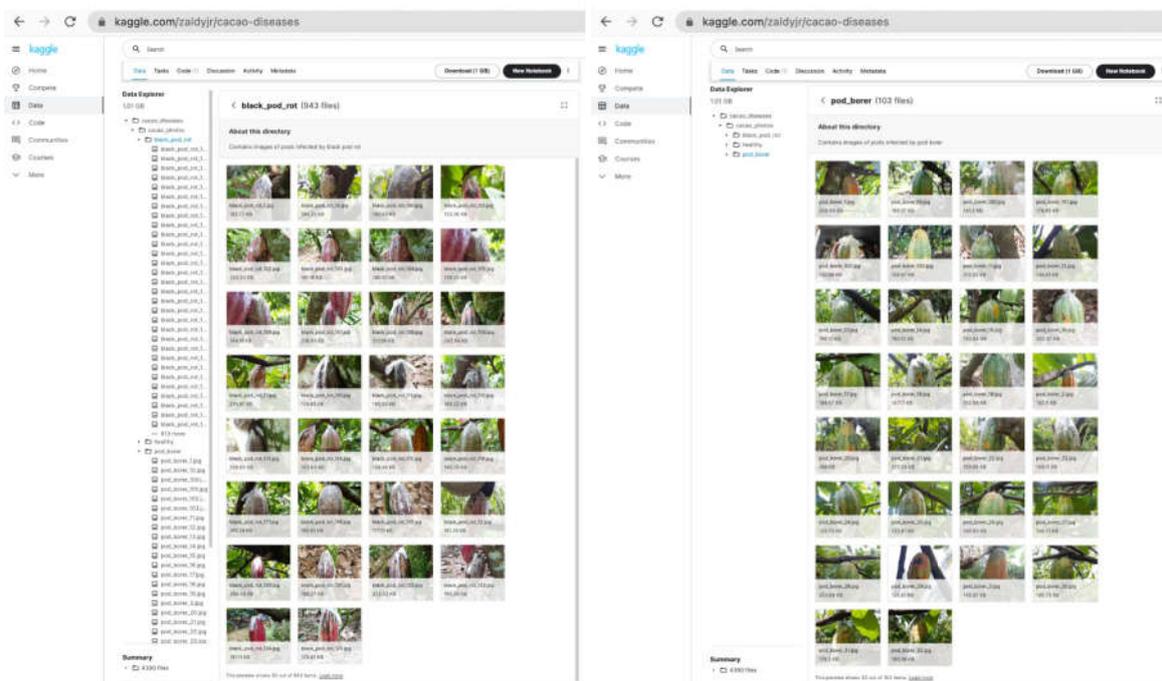


Figura 3. Conjunto de imagens de cacau com podridão parda (esquerda) e com broca da vagem (direita)

Identificar o surgimento de doenças na lavoura em estágio inicial é extremamente importante para que o produtor possa fazer as devidas intervenções em tempo hábil e assim evitar perdas na safra. Felizmente, as principais doenças que acometem a cultura do cacau têm a característica de se destacarem visualmente, o que permite que sejam detectadas através de técnicas de reconhecimento de imagem, também conhecidas como técnicas de visão computacional. Este estudo aplicou técnicas de visão computacional, baseadas em aprendizado de máquina profundo, para classificar imagens de frutos do cacau em três categorias: frutos saudáveis, frutos com podridão parda e frutos com broca da vagem. Os resultados são mostrados e a eficiência do modelo proposto discutida.

MATERIAIS E MÉTODOS

O conjunto de dados utilizado foi obtido no sítio público da internet KAGGLE, coletado dia 31/03/2021 e disponibilizado por Pagaduan (2021). O diretório contém imagens de diferentes doenças do cacau, coletadas em fazendas na cidade de Davao, nas Filipinas (Figura 3). O autor disponibilizou 4.390 imagens de tamanho 1080x1080, distribuídas conforme descrito na Tabela 1.

É comum em aplicações de aprendizado de máquina que se divida o conjunto de dados, ficando uma parte para treinamento, outra para validação e outra para teste do modelo. Neste estudo, duas abordagens de divisão do conjunto de dados foram usadas. Na primeira, foram destinadas 70% das imagens para treinamento do modelo (3.073 imagens), 15% para validação (658 imagens) e 15% para teste (658 imagens). Na segunda abordagem, utilizou-se a técnica conhecida como validação cruzada para se treinar, validar e testar o modelo neural. Este recurso pode ser usado quando se deseja evitar o sobreajuste (*overfitting*), que pode ocorrer quando a rede neural fica muito especializada nos dados do treinamento, o que compromete sua eficácia ao se usar os dados de teste. A ideia é dividir os dados de entrada em K subconjuntos de dados (também chamados de K -folds). Passa-se então a treinar o modelo de Aprendizado de Máquina em todos os subconjuntos, exceto um ($K-1$) e depois se avalia o modelo no subconjunto que não foi usado para o treinamento. Esse processo é repetido K vezes, com um subconjunto diferente reservado para avaliação (e excluído do treinamento) a cada vez. Os dados de imagem disponibilizados por Pagaduan (2021) possuem uma característica particular, o número de imagens por classe não é uniforme. A quantidade de imagens de frutos com broca da vagem é bem menor do que o das outras classes. Este detalhe pode

interferir no resultado do treinamento de modelos de aprendizado de máquina, pois eles dependem de um número considerável de amostras (exemplos) para fazer as correlações matemáticas e extrair as características necessárias ao processo de classificação de imagens. Diante disto, treinamos primeiramente a CNN com o número de imagens originais e em seguida, utilizamos uma técnica conhecida como *data augmentation*, ou aumento de dados, para gerar automaticamente mais imagens da classe Broca da Vagem. De posse das novas imagens geradas para a classe, a CNN foi novamente treinada e submetida aos dados de teste e validação. A Figura 4 mostra um trecho do código em Python usado para o aumento de dados. Outro pré-processamento realizado foi a transformação da dimensão das imagens. O formato original das imagens de cacau utilizadas é de 1080x1080 e, para serem submetidos à CNN para a

extração de características, precisaram estar no formato 150x150. Para o conjunto de dados escolhido, cinco diferentes cenários de arquiteturas de a CNN foram testados na busca pela configuração ideal. Estes cenários estão descritos na Tabela 2. O diagrama geral descrevendo visualmente a arquitetura da CNN proposta neste estudo é apresentado na Figura 5. A aplicação computacional foi desenvolvida com a linguagem de programação *Python* (v.3.9.2), utilizando o ambiente de desenvolvimento integrado *Spyder* (v.4.1.3), mostrado na Figura 6. Para as implementações de aprendizado profundo foi utilizada a biblioteca *Keras*, que executa a biblioteca *TensorFlow* em modo subjacente. O modelo neural foi processado em um hardware com processador Intel i7-7700HQ, 2.80-3.80 GHz, cache 4 MB, 4 núcleos, 8 threads, RAM 16 GB.

```

gerador_treinamento = ImageDataGenerator(rotation_range = 7,
                                          horizontal_flip = True,
                                          shear_range = 0.2,
                                          height_shift_range = 0.07,
                                          zoom_range = 0.2)

gerador_validacao = ImageDataGenerator()

base_treinamento = gerador_treinamento.flow(X_train, y_train, batch_size = batch_size)

base_validacao = gerador_validacao.flow(X_val, y_val, batch_size = batch_size)

# run training model
inicio_aux = time.time()
history = model.fit(base_treinamento, epochs=100, steps_per_epoch=X_train.shape[0] // batch_size,
                  validation_data=base_validacao, validation_steps = X_val.shape[0] // batch_size)
fim = time.time()
Functions.printTime("Training", inicio_aux, fim)

#print(len(base_treinamento))

# Plota o histórico da acurácia
plt.plot(history.history['accuracy'])
plt.plot(history.history['val_accuracy'])
plt.title('Learning curve')
plt.ylabel('accuracy')
plt.xlabel('epoch')
plt.legend(['train', 'test'], loc='lower right')
plt.savefig('accuracy_DA_30epocas.png', dpi=600)
plt.show()

```

Figura 4. Trecho do código em Python com o aumento de dados e o treinamento da CNN

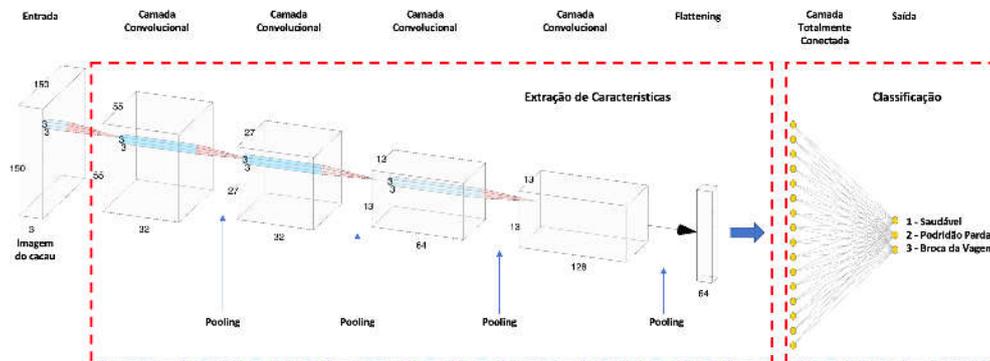


Figura 5. Arquitetura da CNN utilizada

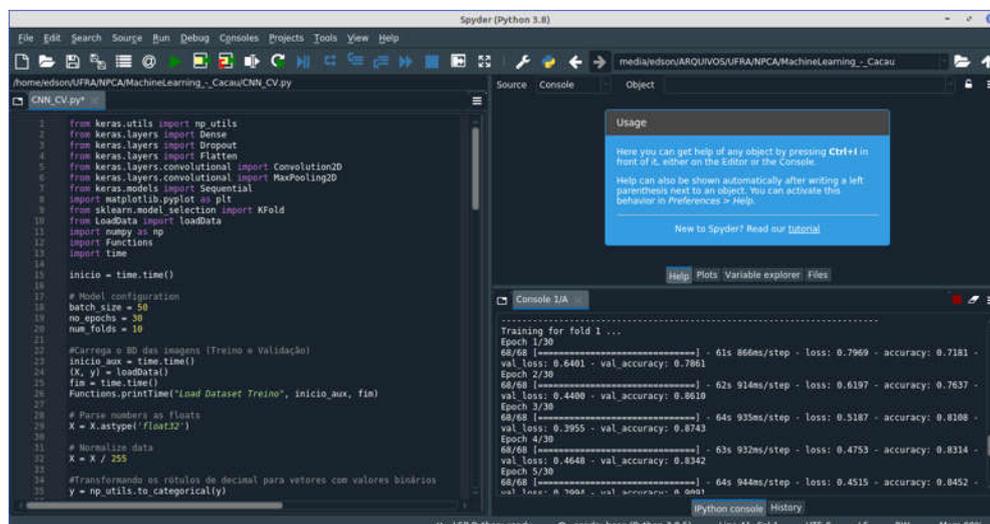


Figura 6. Ambiente de desenvolvimento integrado *Spyder*, utilizado para a construção do modelo computacional.

Tabela 2. Configurações Utilizadas nas Redes CNN nos 5 Cenários.

Parâmetro da CNN	Cenário 1	Cenário 2	Cenário 3	Cenário 4	Cenário 5
Conjunto de Dados	70% treino 15% validação 15% teste	70% treino 15% validação 15% teste	85% treino e validação 15% teste k=10	70% treino 15% validação 15% teste	85% treino e validação 15% teste k=10
Validação Cruzada	Não	Não	Sim	Não	Sim
Aumento de Dados	Não	Não	Não	Sim	Sim
Camada de Entrada	1 neurônio imagem RGB 3 canais 150x150 color				
Camada Convolutacional	32 neurônios filtros conv. 3x3 Ativação ReLU				
Camada Pooling	2x2	2x2	2x2	2x2	2x2
Camada Convolutacional	32 neurônios filtros conv. 3x3 Ativação ReLU				
Camada Pooling	2x2	2x2	2x2	2x2	2x2
Camada Convolutacional	64 neurônios filtros conv. 3x3 Ativação ReLU				
Camada Pooling	2x2	2x2	2x2	2x2	2x2
Camada Convolutacional	128 neurônios filtros conv. 3x3 Ativação ReLU				
Camada Pooling	2x2	2x2	2x2	2x2	2x2
Camada Flattening	64	64	64	64	64
Camada (MLP) Fully-Connected	64 neurônios Ativação ReLU				
Camada Dropout	50% chances				
Camada de Saída	3 neurônios Ativação Sigmoide				
Função de Perda	Categorical Cross Entropy				
Otimizador	RMS Prop				
Medida de Avaliação	Accuracy	Accuracy	Accuracy	Accuracy	Accuracy
Épocas de Treinamento	30	100	30	100	100
Tamanho do Lote	50	100	100	50	32

RESULTADOS E DISCUSSÃO

O primeiro cenário testado foi o padrão, com configurações típicas da rede neural para este tipo de problema de classificação. A curva de aprendizado e a matriz de confusão do cenário 1 são mostrados na Figura 7. Neste cenário, a CNN obteve uma acurácia de 0,92 (92%) e a função de perda (*loss function*) chegou a 0.08. Importante salientar que, em modelos de aprendizado de máquina, o ideal é que se tenha uma acurácia mais próxima de 1 e que a função de perda diminua até que seu valor chegue o mais próximo de zero. Na matriz de confusão do modelo, pode-se observar que a CNN classificou erroneamente 11 imagens da classe broca da vagem. Como neste cenário 1 o número de épocas foi de 30, passou-se para o cenário dois, com 100 épocas para avaliar se o treinamento com mais épocas iria melhorar a performance.

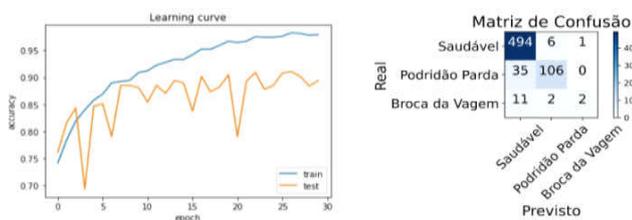


Figura 7. Acurácia e Matriz de Confusão para a CNN do cenário 1

A CNN com os parâmetros do cenário 2 obteve uma acurácia de 91% e a função de perda chegou a 0.09. Deste modo, observamos que o aumento de épocas não melhorou a performance da rede. É possível observar isso no gráfico com a curva de aprendizado, onde a acurácia de teste estabiliza-se por volta de 25 épocas. Todavia, neste cenário, a classe broca da vagem foi classificada com um pouco menos de erros, o que pode ser atestado na matriz de confusão (7 erros).

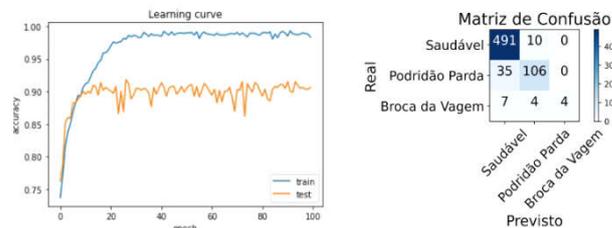


Figura 8. Acurácia e Matriz de Confusão para a CNN do cenário 2.

Na CNN com os parâmetros do cenário 3 foi utilizada a técnica de validação cruzada para treinamento, validação e teste dos dados. Com isso, foi obtida uma acurácia média de 91,77% e a função de perda, em média, chegou a 0.44. Observe-se que neste caso, os resultados são médios, pois a operação foi realizada com 10 conjuntos ($K\text{-fold} = 10$).

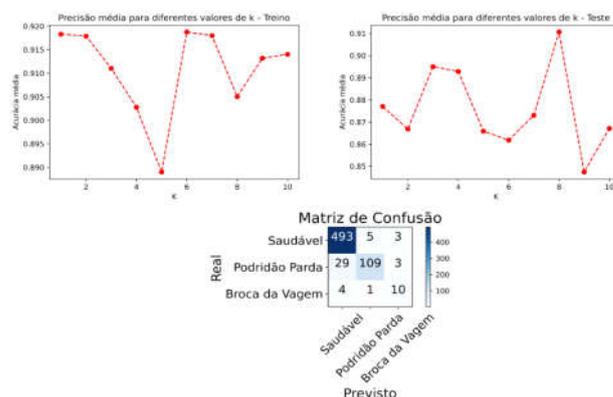


Figura 9. Acurácia Média de Treino e de Teste e Matriz de Confusão para a CNN do cenário 3

Percebe-se que, para o conjunto de dados escolhido, o emprego da validação cruzada não melhorou a performance geral da rede. Nota-se que os resultados médios de desempenho da CNN neste cenário não obtiveram melhoria de acurácia e a função de perda acabou piorando (subindo). As curvas de aprendizado médio para treino e teste e a matriz de confusão do cenário 3 são mostrados na Figura 9.

Foi testada a técnica de *data augmentation* na CNN do cenário 4, onde se obteve uma acurácia de 95% e a função de perda chegou a 0.05. De fato, o aumento de imagens da classe broca da vagem melhorou significativamente o desempenho da rede neural. Fica notório na Figura 10 que a curva de aprendizado de teste ficou acima dos cenários anteriores e o número de classificações erradas de broca da vagem também diminuiu.

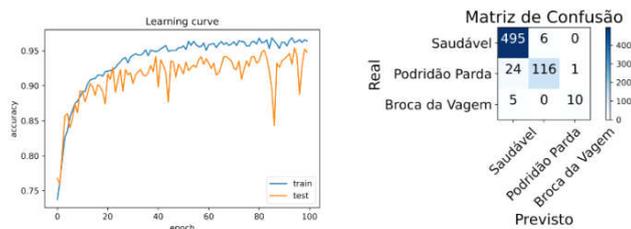


Figura 10. Acurácia e Matriz de Confusão para a CNN do cenário 4

Na última configuração testada para este conjunto de dados, na CNN do cenário 5, foram experimentadas simultaneamente as técnicas de *data augmentation* e de *cross validation*. Como resultado, foi obtida uma acurácia média de 92,13% e a função de perda chegou a 0.32. Pode-se notar que, assim como no cenário 3, onde se usou a validação cruzada, a acurácia não foi incrementada significativamente e a função de perda acabou em um valor acima dos outros cenários que não usaram a técnica. Todavia, a matriz de confusão mostra que o número de erros de classificação em imagens de broca da vagem foi o menor de todos os cenários, apenas 2. Isso se deve, assim como ocorreu no cenário 4, ao uso da técnica de aumento de dados. As curvas de aprendizado médio para treino e teste do cenário 5, bem como a matriz de confusão, são mostrados na Figura 11.

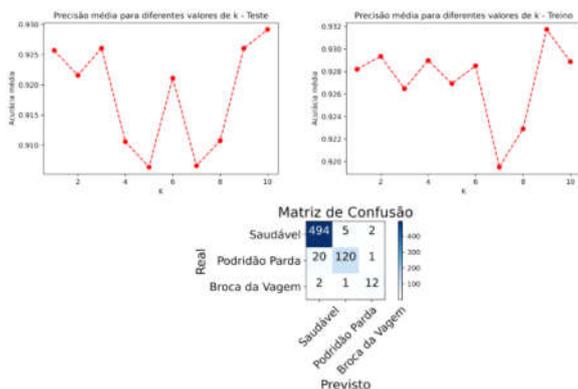


Figura 11. Acurácia Média de Treino e de Teste e Matriz de Confusão para a CNN do cenário 5.

CONCLUSÃO

Neste trabalho foi proposto um modelo computacional para fazer classificação a partir de imagens de doenças no fruto do cacauero. O modelo baseou-se na técnica de Aprendizado de Máquina Profundo e foi aplicado em um banco de imagens públicas. Para o conjunto de dados escolhido e testado, a Rede Neural Convocional obteve alta taxa de acerto devido ao emprego da técnica de aumento de dados. O modelo proposto mostrou-se eficiente e mais, pode ser aplicado a problemas de outras naturezas, outros tipos de imagens, de culturas e áreas das ciências agrárias. Um próximo passo a ser dado é a aplicação da mesma abordagem de Inteligência Artificial para

imagens do cacau brasileiro produzido no estado do Pará, bem como para mais doenças que acometem essa importante cadeia produtiva. Nesse contexto, entende-se que a implementação deste tipo de ferramenta de agro tecnologia pode agregar otimização de recursos financeiros, permitindo o aumento da rentabilidade do produtor e a viabilidade dos cultivos além de permitir a redução do impacto nas lavouras através da identificação automatizada de doenças.

AGRADECIMENTOS

Os autores agradecem à Universidade Federal Rural da Amazônia (UFRA), através da Pró-Reitoria de Pesquisa e Desenvolvimento Tecnológico (PROPED), pelo financiamento deste estudo. Este trabalho contou com concessão de bolsa de Iniciação Científica (Edital 12/2020 – PROPED/UFRA. Convênio Nº 003/2019 – UFRA/FAPESPA).

REFERÊNCIAS

- Alves Júnior, M. 2013. A Cultura do Cacau no Território da Transamazônica e Xingu: Um Enfoque as Pesquisas Realizadas no Município de Medicilândia-Pa. Revista EDUCamazônia - Educação Sociedade e Meio Ambiente, LAPESAM/GISREA/UFAM/CNPq/EDUA. Ano 6, vol X, Número 1, Jan-Jun, 2013. Pág. 126-142.
- Baba, Basri, Tamin, Rosmawati, Amirullah, Indrabayu, Areni, Intan, A. Karim, Harli. 2020. MOBILE IMAGE PROCESSING APPLICATION FOR CACAO'S FRUITS PEST AND DISEASE ATTACK USING DEEP LEARNING ALGORITHM. ICIC Express Letters. 14. 1025-1032. 10.24507/icicel.14.10.1025.
- Baba, Basri, Harli, Amirullah, Indrabayu, Areni, Intan, Tamin, Rosmawati. 2019. Image Processing System for Early Detection of Cocoa Fruit Pest Attack. Journal of Physics: Conference Series. 1244. 012003. 10.1088/1742-6596/1244/1/012003.
- BASRI et al. 2020. Mobile Image Processing Application For Cacao's Fruits Pest And Disease Attack Using Deep Learning Algorithm. Icic Express Letters, Vol.14, No.10, 2020.
- Bartley, B. G. D. 2005. The genetic diversity of cacao and its utilization. CABI Publishing. Wallingford, UK. 341p. 17. <https://doi.org/10.1079/9780851996196.0000>.
- Brito, D. 2020. Brasil quer ganhar posições na produção mundial de cacau e chocolate. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/noticias/brasil-quer-retomar-protagonismo-no-cenario-global-de-cacau-e-chocolate>.
- Freitas, V., Mendes, M. 2005. Espécies de fungos exóticas para a cultura do cacau. Embrapa Recursos Genéticos e Biotecnologia. Comunicado técnico, 124, Ministério da Agricultura, Pecuária e Abastecimento. Brasília, DF Brasília, DF, Set 2005.
- Goodfellow, I., Bengio, Y., Courville, A. 2016. Deep Learning. MIT Press 2016, <http://www.deeplearningbook.org>.
- Grahame, J. 2017. Broca da vagem do cacau 175. Disponível em: https://www.pestnet.org/fact_sheets/cocoa_pod_borer_175.htm. Acesso em: 24 abr. 2021.
- Kamilaris, Andreas & Prenafeta Boldú, Francesc. 2018. Deep Learning in Agriculture: A Survey. Computers and Electronics in Agriculture. 147. 10.1016/j.compag.2018.02.016. KARPATY, A. 2021. Stanford university cs231n: Convolutional neural networks for visual recognition, <http://cs231n.stanford.edu/>.
- Lecun, Y.; Bengio, Y. & Hinton, G. 2015. Deep Learning, 436, NATURE, Vol. 521.
- Mapa. 2014. Implantação do cacauero em sistemas agroflorestais. Ministério da Agricultura, Pecuária e Abastecimento. Brasília, DF. 2014. Mapa/Ceplac. 76 p. Disponível em: http://www.ceplac.gov.br/paginas/publicacoes/paginas/cartilhas_tecnicas/cartilhas/CT_18.pdf.
- Mapa. 2020. Cartilha de boas práticas na lavoura cacauera no estado do Pará. Ministério da Agricultura, Pecuária e Abastecimento, Secretaria de Inovação, Desenvolvimento Rural e Irrigação,

- Comissão Executiva do Plano da Lavoura Cacaueira. – Belém: Mapa/CEPLAC, 2020. 64 p.
- Menezes, 2020. Cacau paraense rompe fronteiras com qualidade e aumento da produção. Agência Pará. Governo do Pará. Disponível em: <https://agenciapara.com.br/noticia/20613/>.
- Mitchel, T.M. 1997. Machine Learning. McGraw-Hill International Editions.
- Müller, M. W.; Valle, R. R. 2012. Ecofisiologia do cultivo do cacau. In: VALLE, R.R. Ciência Tecnologia e Manejo do Cacau. Brasília-DF. CEPLAC/CEPEC/SEFINS. 688p.
- MTCAB - Manual Técnico do Cacau para a Amazônia Brasileira. 2013. Parque Verde, Belém. 2013. 235 p.
- Oliveira, M. L.; Luz, E.D.M.N. 2005. Identificação e manejo das principais doenças do cacau no Brasil. Ilhéus, CEPLAC/CEPEC/SEFIT. 132p.
- Oliveira, Renata, Alves, Errison, Malqui, Carlos. 2017. Redes Neurais Convolucionais Aplicadas à Preensão Robótica. 10.21528/CBIC2017-97. PAGADUAN, 2021. CacaoDiseases. Imagesofcacaowithdiseases. Disponível em: <https://www.kaggle.com/zaldyjr/cacao-diseases>.
- Pagaduan, 2021. CacaoDiseases. Images of cacao with diseases. Disponível em: <https://www.kaggle.com/zaldyjr/cacao-diseases>.
- Ponti, M.A. & Costa, G.B.P. 2017. Como funciona o Deep Learning. Tópicos em Gerenciamento de Dados e Informações 2017. SBC, 1a ed. ISBN 978-85-7669-400-7.
- SENAR. 2018. Cacau: produção, manejo e colheita / Serviço Nacional de Aprendizagem Rural – Brasília: SENAR, 2018. 145 p; il. 21 cm Coleção Senar, 215. ISBN: 978-85-7664-197-1.
- Tan, Daniel Stanley & Leong, Robert Neil & Laguna, Ann Franchesca & Ngo, Courtney & Lao, Angelyn & Amalin, Divina & Alwindia, Dionisio. 2018. AuToDiDAC: Automated Tool for Disease Detection and Assessment for Cacao Black Pod Rot. CropProtection. 103. 98-102. 10.1016/j.cropro.2017.09.017.
- Tezza, G. 2021. Principais doenças do cultivo de cacau e seu controle cultural. Manejebem. Disponível em: <https://www.manejebem.com.br/publicacao/novidades/principais-doencas-docultivo-de-cacau-e-seu-controle-cultural>.
- Valle, R. R. 2012. Ciência, tecnologia e manejo do cacau. Brasília, DF: Ceplac/Cepec/Sefis. 2012. 2ª edição. 688 p.
- Zhu, N.Y. et al. 2018. Deep Learning for Smart Agriculture: Concepts, Tools, Applications and Opportunities. Int J Agric& Biol Eng. Vol. 11, N 4.
