



XII Congresso Brasileiro de Agroinformática

11 a 14 de Novembro de 2019

ANAIS

INDAIATUBA
Novembro de 2019

ANAIS DO XII CONGRESSO BRASILEIRO DE AGROINFORMATICA

ORGANIZADORES

MARIA FERNANDA MOURA

JAYME GARCIA ARNAL BARBEDO

ALAINÉ MARGARETE GUIMARÃES

VALTER CASTELHANO DE OLIVEIRA

FATEC/EMBRAPA/UEPG-PPGCA

11 A 14 DE NOVEMBRO DE 2019

Ficha Catalográfica

Congresso Brasileiro de Agroinformática (11.: 2019: Indaiatuba, SP)

C749 Anais eletrônicos do XII Congresso Brasileiro de Agroinformática. 11 a 14 de novembro de 2019. Indaiatuba, SP; Universidade Estadual de Ponta Grossa/ Maria Fernanda Moura et al. (Org.). Ponta Grossa: SBIAGRO, 2019.

ISBN: 978-65-00-10242-0

1. Agroinformática. 2. Agricultura digital. 3. Internet das coisas. I. Moura, Maria Fernanda (Org.). II. Barbedo, Jayme Garcia Arnal (Org.). III. Guimarães, Alaine Margarete (Org.). IV. Oliveira, Valter Castelhana de (Org.). V. SBIAgro. VI. T.

CDD: 004.22





Detecção de Folíolos do Guaranazeiro Atacados pelo Tripes Utilizando CNNs Pré-Treinadas

*Richardson Allan Ferreira de Souza*¹, *Marcos Filipe Alves Salame*²

¹Bolsista de Iniciação Científica FAPEAM, Embrapa Amazônia Ocidental
Manaus, Amazonas, Brasil, rafds.snf@uea.edu.br

²Analista de Tecnologia da Informação, Embrapa Amazônia Ocidental
Manaus, Amazonas, Brasil, marcos.salame@embrapa.br

RESUMO

O cultivo do guaranazeiro tem grande importância socioeconômica na Região Amazônica, sendo fonte de renda para pequenos agricultores rurais. O ataque do Tripes (*Pseudophilotrips adisi*) tem interferido no sistema de agricultura familiar prejudicando a produção de grãos e limitando a exploração comercial do guaraná. Com isso, abordagens computacionais para identificar automaticamente os danos causados pelo Tripes podem auxiliar no seu controle, entre outras aplicações. Este trabalho utilizou Redes Neurais Convolucionais pré-treinadas como extratores de características, através da técnica de *Transfer Learning*, para avaliar os classificadores *Support Vector Machine* e *Multilayer Perceptron* na tarefa de reconhecer danos em folíolos jovens do guaranazeiro atacados pelo Tripes com base em imagens obtidas de *smartphones*. Embora a base de imagens seja pequena e desbalanceada, nenhuma avaliação obteve um índice kappa abaixo de 0.8. No melhor cenário foi possível atingir um índice kappa de 0,9436 e uma acurácia balanceada de 0,9609 com o classificador *Support Vector Machine*.

PALAVRAS-CHAVE: *Transfer learning*, Tripes, Guaraná.

ABSTRACT

Guarana crops has a great socioeconomic importance in the Amazon Region, being a source of income for small rural farmers. The attack of the Thrips (*Pseudophilotrips adisi*) interferes in the family farming system, damaging the production of grains and limiting the commercial exploration of guarana. Based on this, computational approaches to automatically identify the damage caused by the thrips can help in its control, among other applications. This work uses features extracted from pre-trained Convolutional Neural Networks through the Transfer Learning technique to evaluate the Support Vector Machine and Multilayer Perceptron classifiers for the recognition of damage in young guarana leaflets caused by the Thrips attack based on

images obtained from smartphones. Although the images base be small and unbalanced, no assessment had a Cohen's Kappa rating below 0,8. In the best scenario it was possible to achieve a Cohen's Kappa of 0,9436 and a balance accuracy of 0,9609 with the Support Vector Machine classifier.

KEYWORDS: Transfer learning, Thrips, Guarana.

INTRODUÇÃO

A cultura do guaraná vem assumindo importância cada vez maior no cenário econômico e social do país, especialmente na Região Amazônica. A importância econômica é evidenciada pelo crescimento da demanda de sementes pelas indústrias de bebidas para atender o promissor mercado de refrigerantes, em nível nacional e internacional. Considerando também as outras formas de utilização, o guaranzeiro representa fonte de renda para inúmeros produtores rurais da Região Amazônica, sendo indiscutível sua importância socioeconômica, contando com cerca de 2.500 produtores, com área cultivada média de 2 hectares/produtor (SANTOS, 2018; SENRA; GARCIA; TAVARES, 2008).

Proposto por (SAHA; EKBAL, 2013)

A ocorrência da praga Tripes, *Pseudophilothrips adisi* (zur Strassen), tem interferido de forma direta e indireta na produtividade, limitando a exploração comercial do guaraná em sistemas de agricultura familiar. Em relação aos danos diretos, ao se alimentarem do conteúdo celular das estruturas jovens das plantas de guaranzeiro, pequenas pontuações são formadas de onde sugam a seiva causando alterações morfológicas e de desenvolvimento. Alternativas de controle mais seguras para o homem e para o ambiente têm sido o principal alvo das pesquisas desenvolvidas na Embrapa (FONTES; TAVARES, 2018; TAVARES; GARCIA, 2009; TAVARES; GARCIA; NASCIMENTO-FILHO, 2007).

A literatura apresenta diversos trabalhos que buscam aplicar técnicas de Aprendizado de Máquina (*Machine Learning* ou ML), Visão Computacional (*Computer Vision* ou CV) e Aprendizagem Profunda (*Deep Learning* ou DL) no reconhecimento de injúrias e doenças que acometem diversos tipos de cultivos. O reconhecimento de imagem oferece uma tecnologia econômica e escalonável para utilização na agricultura e a DL está rapidamente se tornando a técnica padrão para classificação de imagens. Contudo, abordagens tradicionais necessitam de uma etapa orientada a extrair características mais representativas de cada imagem (BARBEDO, 2019; MOHANTY; HUGHES; SALATHÉ, 2016).

A técnica de *transfer learning* pode ser aplicada ao se utilizar uma Rede Neural Convolucional (*Convolutional Neural Networks* ou CNNs) pré-treinada como extrator de características para um classificador qualquer. Em razão de seus bons resultados, as CNNs estão liderando o estado da arte em tarefas de visão computacional (RAMCHARAN et al., 2017; NETO et al., 2018).

Com base nesse cenário, foram utilizadas arquiteturas de redes convolucionais por meio de *transfer learning*, para extrair características de imagens digitais obtidas de *smartphones* e

avaliar os classificadores *Support Vector Machine* (SVM) e *Multilayer Perceptron* (MLP) na identificação dos danos em folíolos jovens do guaranazeiro atacados pelo Tripes.

A estrutura do artigo está organizada como segue. A seção Material e Métodos descreve a coleta das imagens para compor a base de dados, a estratégia usada para elaborar o *dataset*, o uso de CNNs pré-treinadas como extratores de características e demais técnicas empregadas. A seção Resultados e Discussão expõem os resultados alcançados com um comparativo entre os classificadores. Por fim, a seção Conclusões resume os resultados obtidos e fornece perspectiva de trabalhos futuros (SENRA; GARCIA; TAVARES, 2008).

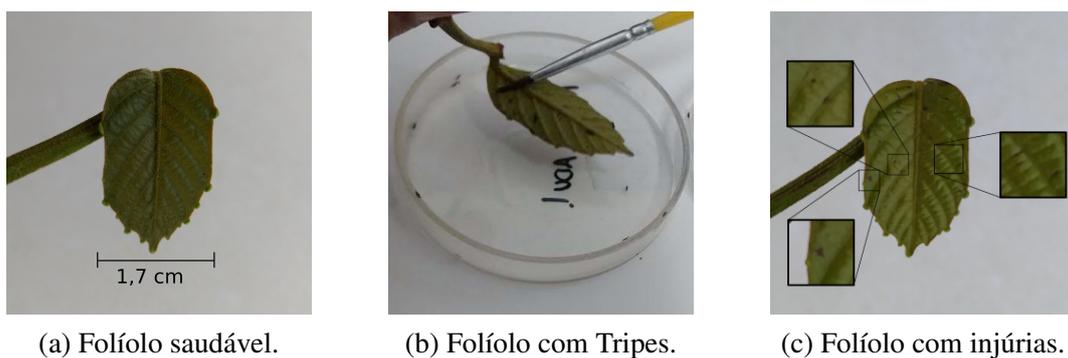
MATERIAL E MÉTODOS

Os experimentos foram realizados na Embrapa Amazônia Ocidental, situada à Rodovia AM-010, Km 29, Manaus, AM. Os indivíduos de *P. adisi* adultos e folhas jovens foram obtidos de plantas de guaranazeiro cultivadas nas áreas do Banco Ativo de Germoplasma (BAG) da Embrapa Amazônia Ocidental.

Aquisição das imagens

Para isolar os danos causados pelo Tripes de outros eventos, folíolos de até 1,7 centímetro, do cultivar BRS-Maués, foram isolados em placas de Petri com até dez exemplares de *P. adisi* adultos e monitorados por um período de 27 horas como mostra a Figura 1a e 1b. Na Figura 1c pode-se observar as injúrias provocadas pelo ataque do Tripes na parte adaxial do folíolo após esse período.

Figura 1: Processo para estimular o aparecimento de injúrias provocadas pelo Tripes.



As imagens foram obtidas pela câmera digital de um *smatphone* da Motorola Moto G5 XT1672 com as funções de HDR e Flash desativadas tendo apenas a luz natural durante a coleta das imagens. Um papel cartão de cor branca e, posteriormente, outro de cor preta foram colocados a uma distância de 10 a 20 centímetro do folíolo, que ajudou na redução dos ruídos de fundo. A Figura 2 mostra uma aplicação que foi desenvolvida com o framework Ionic v3, o plugin de câmera nativo cordova-plugin-camera e uma biblioteca chamada angular-cropperjs

v0.1.5. Essa aplicação permitiu reduzir a área de interesse, redimensionar as imagens para 1872 x 1872 pixels e gerar variações através da rotação e inversão da mesma em tempo de captura.

Figura 2: Aplicação para auxiliar na captura e padronização das imagens.



Conjunto de dados

Para compor o conjunto de dados (*dataset*), 26 imagens foram manualmente selecionadas, dimensionadas para 512 x 512 e subdivididas em 6240 regiões de interesse de 32 x 32 pixels. Como pode ser observado na Figura 3, as regiões que apresentavam pequenas pontuações, evidenciando o ataque, foram separadas para compor a base positiva e as que não apresentavam nenhum tipo de injúria, ver Figura 4, foram separadas para base negativa chegando ao número de 520 amostras da classe positiva e 3.123 amostras da classe negativa.

Figura 3: Exemplos de amostras positivas.

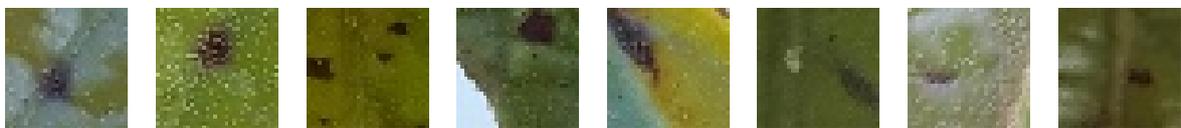
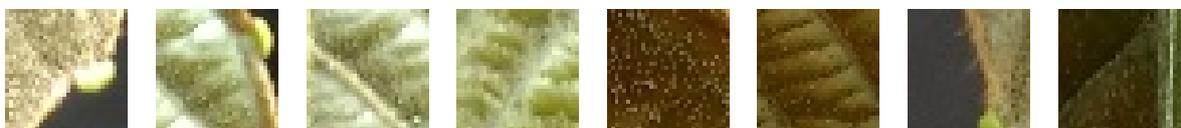


Figura 4: Exemplos de amostras negativas.



Por fim, como mostra a Tabela 1, as imagens foram aleatoriamente separadas uma vez em um conjunto de treino com 70% e de teste com 30% do total.

Tabela 1: Separação das amostras para treino e teste.

Conjunto	Amostras Positivas	Amostras Negativas	Total
Treino	373	2177	2550
Teste	147	946	1093

Extrator de Características

Uma CNN pré-treinada pode ser usada como extrator de características removendo a última camada totalmente conectada da rede e utilizando a nova saída para obter o vetor de característica que representa a imagem de entrada. Essa técnica conhecida como *transfer learning* também pode ser aplicada reaproveitando redes já treinadas com uma grande base de dados para resolver problemas em bases menores ajustando seus pesos.

Nesse artigo, foram utilizadas as arquiteturas canônicas VGG16, Densenet201, Resnet50 e Xception presentes no framework Keras com os pesos treinados pelo desafio da ImageNet (DENG et al., 2009).

Figura 5: Extração de característica com a arquitetura VGG16.

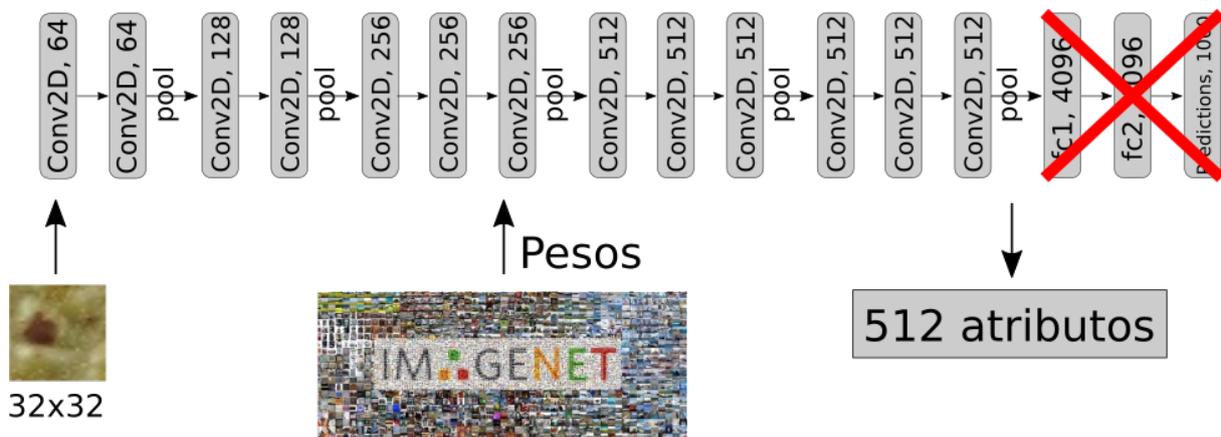


Tabela 2: Quantidade de atributos obtidos e o tamanho da entrada utilizado em cada arquitetura.

Extratores	Entrada	Quantidade de Atributos
VGG16	32 x 32 x 3	512
Resnet50	32 x 32 x 3	2048
Densenet201	32 x 32 x 3	1920
Xception	71 x 71 x 3	2048

Classificadores

Para implementar os classificadores SVM e MLP foi utilizada a linguagem de programação e definido um conjunto de hiper-parâmetros, ver Tabela 3, para método *GridSearchCV* disponível na biblioteca *scikit-learn*.

Tabela 3: Conjunto de hiper-parâmetros utilizados para os algoritmos SVM e MLP.

Algoritmo	Hiper-parâmetro	Valor
SVM	kernel	linear, rbf
	gamma	0.1 , 0.01 , 0.001
	C	1, 10, 100, 1000
MLP	hidden_layer_sizes	<i>Geometric Pyramid Rule</i>
	learning_rate_init	0.1 , 0.01 , 0.001
	activation	relu
	solver	sgd, adam

O hiper-parâmetro *hidden_layer_sizes* encontrado no classificador MLP indica o número de neurônios na camada oculta e para estimar essa quantidade de neurônios foi utilizada a Regra da Pirâmide Geométrica (*Geometric Pyramid Rule*) proposta por Masters (1993). Onde, para uma camada oculta com n entradas e m saídas, a camada oculta terá $\sqrt{n \times m}$ neurônios. Também foram estimadas a quantidade de neurônios para duas e três camadas ocultas sendo obtidas, respectivamente, por:

- $r = \sqrt[3]{\frac{n}{m}}$, $m \times r^2$ neurônios na primeira camada e $m \times r$ neurônios na segunda camada.
- $r = \sqrt[4]{\frac{n}{m}}$, $m \times r^3$ neurônios na primeira camada, $m \times r^2$ neurônios na segunda camada e $m \times r$ neurônios na terceira camada.

Os classificadores foram treinados com cada vetor de características descritos na subseção anterior utilizando o serviço em nuvem *Google Colaboratory (Colab)*, totalizando oito treinamentos.

Métricas de avaliação

Para avaliar a capacidade de generalização dos classificadores, as medidas de acurácia balanceada, precisão, sensibilidade, *f1 score* e índice Kappa de Cohen foram utilizadas, que de acordo com (PEDREGOSA et al., 2011):

- Acurácia Balanceada (*Balanced Accuracy* ou BA): Indicada em problemas classificação binária e multiclasse para lidar com conjuntos de dados desbalanceados. Baseada em uma Matriz de Confusão a acurácia balanceada é dada por $\frac{1}{2} \left(\frac{TP}{P} + \frac{TN}{N} \right)$;
- Precisão (*Precision*): É a relação $tp/(tp + fp)$, em que tp é o número de positivos verdadeiros e o número de falsos positivos. A precisão é intuitivamente a capacidade do classificador de não rotular como positiva uma amostra que é negativa;

- Sensitividade (*Recall*): É a relação $tp/(tp + fn)$ onde tp é o número de positivos verdadeiros e fn o número de falsos negativos. O *Recall* é intuitivamente a capacidade do classificador de encontrar todas as amostras positivas;
- F1-Score: Pode ser interpretado como uma média ponderada da Precisão e da Sensitividade dada pela Equação 1:

$$F1 = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (1)$$

- Índice Kappa de Cohen (*Cohen's Kappa*): É um método estatístico para avaliar o nível de concordância ou reprodutibilidade entre dois conjuntos de dados e é definido pela Equação 2:

$$\frac{(p_o - p_e)}{(1 - p_e)} \quad (2)$$

RESULTADOS E DISCUSSÃO

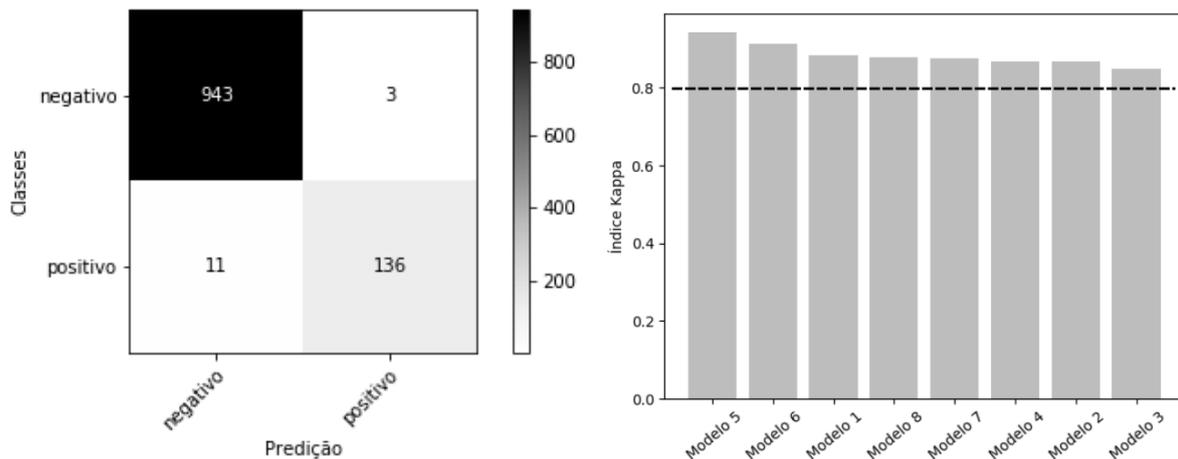
Após encontrar a melhor configuração durante o treinamento, cada modelo foi avaliado com as amostras de teste descritas na seção Conjunto de dados. A Tabela 4 mostra os resultados alcançados na avaliação dos oito modelos, comparando os valores de precisão, sensibilidade, *f1 score* e acurácia balanceada de cada um, tanto para classe negativo quanto para a classe positivo.

Tabela 4: Resultado da Precisão, Sensitividade, F1 Score e Acurácia Balanceada de cada modelo.

Modelo	Classe	Precisão	Sensitividade	F1 Score	BA
1 (SVM/VGG16)	Negativo	0,98	0,99	0,98	0,9358
	Positivo	0,92	0,88	0,90	
2 (MLP/VGG16)	Negativo	0,98	0,99	0,98	0,9251
	Positivo	0,91	0,86	0,89	
3 (SVM/Resnet50)	Negativo	0,98	0,99	0,98	0,9143
	Positivo	0,90	0,84	0,87	
4 (MLP/Resnet50)	Negativo	0,98	0,99	0,98	0,9141
	Positivo	0,94	0,84	0,88	
5 (SVM/Densenet201)	Negativo	0,99	1,00	0,99	0,9609
	Positivo	0,98	0,93	0,95	
6 (MLP/Densenet201)	Negativo	0,98	0,99	0,99	0,9429
	Positivo	0,96	0,89	0,93	
7 (SVM/Xception)	Negativo	0,98	0,99	0,98	0,9319
	Positivo	0,91	0,88	0,89	
8 (MLP/Xception)	Negativo	0,98	0,98	0,98	0,9462
	Positivo	0,88	0,91	0,90	

Como pode ser visto na Tabela 4, o modelo 5 não só teve uma acurácia balanceada de 0,9609 como também foi o modelo que mais identificou amostras da classe positivo, alcançando uma sensibilidade de 0,93. A Figura 6a é apresentada a Matriz de Confusão com os valores resultantes da classificação do modelo 5, onde as linhas equivalem a classe verdadeira e as colunas as classes previstas pelo modelo.

Figura 6: .



(a) Matriz de Confusão do Modelo 5.

(b) Índice Kappa de todos os modelos.

É possível observar na Figura 6a a alta densidade de valores nas células mais escuras. Demonstrando a classificação correta de muitas amostras do conjunto de teste, que mesmo desbalanceado apresentou bons resultados ao identificar a classe positivo com poucos elementos.

Na Figura 6b é possível observar que todos os modelos atingiram um desempenho de classificação pelo índice kappa acima de 0,8 que em Landis e Koch (1977) é rotulado como excelente. O modelo 5 destaca-se dos demais por ter alcançado um índice kappa de 0,9436.

CONCLUSÕES

Por meio deste trabalho, verificou-se que o emprego de CNNs pré-treinadas como extratores de características pode contribuir na tarefa de construir vetores mais representativos para o problema. Da mesma forma, analisar regiões de interesse ao invés de considerar todo o folheto, ajudou a elaborar um *dataset* com maior quantidade de variações e mais inerente ao problema de identificação dos danos causados pelo Tripes. Como trabalho futuro pretende-se aumentar a base de amostras positivas fazendo uma base de dados mais equilibrada e gerar modelos que possam ser avaliados em um cenário de uso real. Uma base de imagens mais robusta permitirá avaliar outras técnicas de *Deep Learning* como fine-tuning.

AGRADECIMENTOS

Ao pesquisador Adauto Mauricio Tavares pelas informações técnicas referentes ao tripses e guaraná; à Julliane da Silva Fontes pelo auxílio nos experimentos e à Fundação de Amparo à Pesquisa do Estado do Amazonas pela disponibilização da bolsa de iniciação científica.

REFERÊNCIAS

- BARBEDO, J. G. A. Plant disease identification from individual lesions and spots using deep learning. *Biosystems Engineering*, Elsevier, v. 180, p. 96–107, 2019.
- DENG, J. et al. ImageNet: A Large-Scale Hierarchical Image Database. In: *CVPR09*. [S.l.: s.n.], 2009.
- FONTES, J. d. S.; TAVARES, A. Aspectos da biologia da linhagem sexuada do tripses-do-guaranazeiro (*pseudophilothrips adisi*, zur strassen)(thysanoptera: Phlaeothripidae). In: IN: JORNADA DE INICIAÇÃO CIENTÍFICA DA EMBRAPA AMAZÔNIA OCIDENTAL, 14., 2017. *Embrapa Amazônia Ocidental-Artigo em anais de congresso*. [S.l.], 2018.
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. *biometrics*, JSTOR, p. 159–174, 1977.
- MASTERS, T. *Practical Neural Network Recipes in C++*. [S.l.]: Acad. Press, 1993.
- MOHANTY, S. P.; HUGHES, D. P.; SALATHÉ, M. Using deep learning for image-based plant disease detection. *Frontiers in plant science*, Frontiers, v. 7, p. 1419, 2016.
- NETO, H. da S. et al. Transfer learning for facial emotion recognition. 2018.
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011.
- RAMCHARAN, A. et al. Deep learning for image-based cassava disease detection. *Frontiers in plant science*, Frontiers, v. 8, p. 1852, 2017.
- SAHA, S.; EKBAL, A. Combining multiple classifiers using vote based classifier ensemble technique for named entity recognition. *Data & Knowledge Engineering*, Elsevier, v. 85, p. 15–39, 2013.
- SANTOS, L. Sistema mecanizado de processamento pós-colheita de guaraná: nova tecnologia para o agronegócio e a agricultura familiar. *Embrapa Amazônia Ocidental-Capítulo em livro científico*, In: MACHADO, MWK (Org.). *A engenharia de produção na contemporaneidade*, 2018.
- SENRA, T.; GARCIA, M.; TAVARES, A. Comportamento e controle de tripses do guaranazeiro, *liothrips adisi* (thysanoptera: Phlaeothripidae). In: IN: SEMINÁRIO DE PÓS-GRADUAÇÃO NA EMBRAPA AMAZÔNIA OCIDENTAL, 2008, MANAUS. *Embrapa Amazônia Ocidental-Artigo em anais de congresso*. [S.l.], 2008.

TAVARES, A.; GARCIA, M. Tripes do guaranazeiro: *Liothrips adisi* zur strassen, 1977 (thysanoptera: Phlaeothripidae, phlaeothripinae). *Embrapa Amazônia Ocidental-Documentos*, Manaus: Embrapa Amazônia Ocidental, 2009., 2009.

TAVARES, A. M. T.; GARCIA, M. V. B.; NASCIMENTO-FILHO, F. *Tripes do guaranazeiro: estado atual e perspectivas*. [S.l.]: Embrapa Amazônia Ocidental, 2007.