

Anais do Encontro Regional de Computação e Sistemas de Informação

Resumos e Artigos Completos

VI ENCOSIS AMAZÔNIA CONECTADA



REALIZAÇÃO



APOIO



VI Encontro Regional de Computação e Sistemas de Informação, ENCOSIS 2017, Manaus, Amazonas, Brasil, Maio 25-27, 2017

ISSN 2238-5096

Uma Abordagem Comparativa de Algoritmos de Aprendizado Supervisionado para Classificação dos Cultivares da Planta *Paullinia cupana*

Alex de Lima Sousa¹, Marcos Filipe Alves Salame¹

¹ Núcleo de Tecnologia da Informação – Embrapa Amazônia Ocidental
Caixa Postal 319 – 69.010-970 – Manaus – AM – Brasil

allexlima@unn.edu.br, marcos.salame@embrapa.br

Abstract. *The guarana's plant (Paullinia cupana) has been studied by Embrapa Amazônia Ocidental since the end of the 70's, resulting in the development and availability of 19 cultivars resistant to the main pests and diseases. However, the distinction between these specimens is still restricted to manual and technical procedures which are subject to human error. Thus we sought to identify the best methods of supervised learning for the context of the classification of these cultivars from images of their leaves. Among techniques used as Decision Trees, Support Vector Machines and Convolutional Neural Networks, this last one obtained better performance reaching 89.6% accuracy.*

Resumo. *O guaranazeiro (Paullinia cupana) vem sendo estudado pela Embrapa Amazônia Ocidental desde o final da década de 70, resultando no desenvolvimento e disponibilização de 19 cultivares resistentes as principais pragas e doenças. Contudo, a distinção dentre esses espécimes ainda é restrita a procedimentos manuais e técnicos, sujeitos à falha humana. Dessa forma, buscou-se identificar os melhores métodos de aprendizado supervisionado para o contexto de classificação desses cultivares a partir de imagens de suas folhas. Das técnicas utilizadas como Árvores de Decisão, Máquinas de Vetores de Suporte e Redes Neurais Convolucionais, essa última obteve melhor performance alcançando 89,6% de acurácia.*

1. Introdução

Compondo a rica vegetação amazônica, o fruto do guaranazeiro (*Paullinia cupana* var. *sorbilis*), o guaraná, é amplamente utilizado como um dos principais insumos para diversas indústrias de bebidas e cosméticos [Tavares et al. 2005]. Entretanto, a proliferação de doenças e pragas regionais incitou a baixa produtividade na amazônia estimulando, dessa forma, a emigração de boa parte da produção para a Bahia, compreendida por deter os maiores índices de produção do guaraná no Brasil [IBGE 2015].

A Empresa Brasileira de Pesquisa Agropecuária (Embrapa), por sua vez, objetivando a expansão da produtividade agrícola do guaraná na amazônia, deu início ao seu programa de melhoramento genético do guaranazeiro, pela unidade Amazônia Ocidental, em Manaus-AM. Esse programa motivou diversas pesquisas e desde a década de 70, variedades de guaranazeiros melhorados a partir da alteração ou introdução de novas características genéticas (*i.e.*, cultivares) resistentes às principais impedâncias de plantio e produção vêm sendo estudadas, desenvolvidas e disponibilizadas [Tricaud et al. 2016].

Com 19 cultivares já registrados no Ministério da Agricultura, Pecuária e Abastecimento, a Embrapa detém o maior banco genético de guaranazeiros [Tricaud et al. 2016]. Todavia, o processo de distinção desses espécimes ainda é sujeito a manuais técnicos [MAPA 2010], extensos e passíveis à falha humana, motivando esta abordagem com agentes computacionais inteligentes, visando explorar algumas das principais técnicas de aprendizado supervisionado de máquinas, um campo da inteligência computacional que investiga métodos capazes de identificar padrões e conceitos a partir de dados amostrais.

Elegeu-se, então, três técnicas para serem aplicadas e analisadas no contexto de classificação dos espécimes de guaranazeiros através de amostras foliares. Assim, modelos clássicos de classificação como árvores de decisão e máquinas de vetores de suporte (em inglês, *Support Vector Machines* – SVM) foram estabelecidos para serem comparados com algumas arquiteturas de redes neurais convolucionais (em inglês, *Convolutional Neural Networks* – CNN).

As árvores de decisão compreendem um método poderoso e abundantemente empregado em problemas de classificação, principalmente, devido a capacidade de representar seu aprendizado através de regras que podem ser expressas em linguagem natural. O poder de generalização e modelagem topológica, dessa técnica, permite que novos itens desfrutem de boas chances de uma predição correta. Ademais, as árvores de decisão são estruturas não lineares formadas por a) nodos que representam os atributos de um conjunto de dados; b) linhas que interligam dois nodos a partir do valor de um atributo do nó de origem; e c) folhas (nodos sem ramificações) representando as classes do conjunto de treinamento [Salame 2015, Shiba et al. 2005].

Na construção da árvore, o algoritmo que a implementa avalia e relaciona a distribuição das classes de modo a particionar, recursivamente, os dados de treino até que cada nó disponha de ramos que o conduzam a uma única classe, através de atributos do *dataset*. Como resultado, a estrutura gerada é compactada e utilizada para classificar novos casos [Shiba et al. 2005].

Outra técnica clássica de classificação implementada nesta abordagem foi o SVM, um método baseado na teoria do aprendizado estatístico e que deteve considerável destaque nos últimos anos por possuir resultados semelhantes ou melhores que outros sistemas de classificação, como as redes neurais artificiais [Haykin 2001, Arafat et al. 2016].

As máquinas de vetores de suporte possuem eficiência para análise e processamento de grandes volumes de dados, além da capacidade de categorizar dados em diversas classes [Araújo et al. 2015]. Esse método também possui boa fundamentação teórica na literatura e seu objetivo é encontrar hiperplanos adequados a fim de dividir os subconjuntos dos dados de treinamento [Arafat et al. 2016].

Muitos processos de classificação de imagens necessitam, para uma melhor generalização e acurácia, que os dados a serem processados tenham suas características primitivas extraídas e descritas a fim de simplificar o modelo de entrada, repassando ao classificador apenas informações relevantes. Dessa forma, a extração de características constitui a primeira etapa do processo de classificação ou identificação de objetos em diversas abordagens relacionadas à visão computacional, na literatura [Venkatesh and Owens 1990].

Algumas características consideradas primitivas podem ser bordas de luminância,

linhas ou cores de uma imagem. Existem diversos descritores visuais responsáveis por realizar a operação de extração e otimização dessas características e, dentre os métodos mais populares, pode-se destacar o SIFT (do inglês, *Scale Invariant Feature Transform*), SURF (do inglês, *Speed Up Robust Features*) e o HOG (do inglês, *Histogram of Oriented Gradients* – HOG) [Yi et al. 2013]. Esse último foi estabelecido para ser aplicado nesta abordagem, em conjunto com os métodos clássicos de classificação, em consequência de sua disponibilidade e integração às ferramentas de implementação utilizadas.

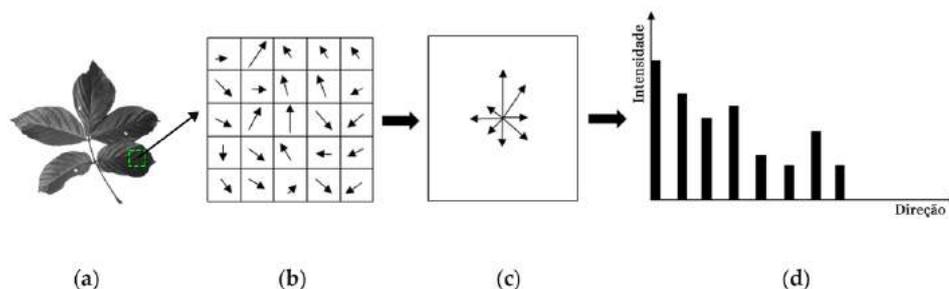


Figura 1. Demonstração do processo de extração de características pelo método HOG: a) Imagem de entrada (e.g., uma folha do BRS-Amazonas); b) mapa de gradientes de parte da imagem; c) orientação de gradientes acumulados; e d) histograma final. Adaptado de [Nguyen and Park 2016]

Conforme ilustra a Figura 1, a extração de características a partir do método HOG ocorre com a definição de um bloco que percorre a imagem. Nesse bloco, a frequência do histograma é calculada a fim de localizar a variação de intensidade dos *pixels* ao longo das direções x e y . Em seguida, essa variação é computada e quantificada de forma que, ao fim do processo, obtém-se um histograma orientado aos gradientes calculados na imagem [Nguyen and Park 2016, Araújo et al. 2015].

Ambas as técnicas clássicas de classificação mencionadas até então, serão testadas com e sem a utilização do descritor de características HOG, método introduzido na literatura por [Dalal and Triggs 2005] e proposto inicialmente para o problema de detecção de pedestres, embora também possa ser utilizado para classificação de espécies vegetais, conforme é apresentado na Seção 2.

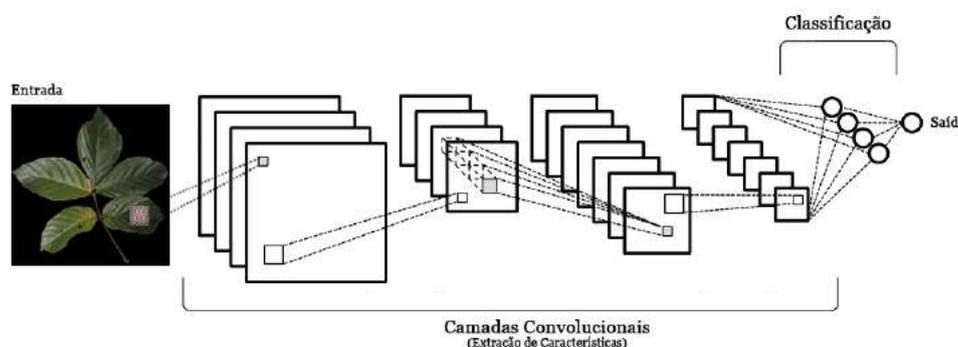


Figura 2. Ilustração dos processos de classificação de cultivares de guaraná através da arquitetura LeNet, um modelo de Rede Neural Artificial Convolutacional. Adaptado de [Dvorak and Menze 2015].

As redes neurais convolucionais, compreendendo a terceira técnica avaliada neste

trabalho, dispensam o emprego de descritores de características, como o HOG, devido às suas camadas convolucionais responsáveis por tal função, conforme ilustra a Figura 2. As CNNs são consideradas uma variação das redes neurais artificiais convencionais e constituem o estado da arte, no campo da visão computacional e aprendizado de máquinas [Gu et al. 2015, Vargas et al. 2016].

Dessa forma, espera-se avaliar o melhor procedimento computacional de modo a definir um método eficaz que possa ser empregado para auxiliar pesquisadores, agricultores e técnicos agrônomos durante o processo de identificação dos cultivares de guaranazeiros, no futuro. Não obstante, visa-se explicar alguns mecanismos técnicos utilizados e relacionados ao aprendizado de máquina e visão computacional presentes neste escrito.

O texto deste artigo está organizado da seguinte forma: a Seção 2 apresenta os Trabalhos Relacionados; a Seção 3 busca explicar a preparação dos classificadores e do *dataset* utilizado; a Seção 4, por sua vez, discute sobre os resultados alcançados enquanto que a Seção 5 traz algumas considerações sobre os feitos realizados longo do projeto.

2. Trabalhos Relacionados

Na literatura, a classificação de espécimes vegetais através de folhas é estudada em diversos trabalhos a partir de diferentes metodologias, visto a importância dessa abordagem para profissionais e pesquisadores agrônômicos e da área de computação aplicada.

Em [Rocha et al. 2010], há um comparativo entre quatro classificadores, dentre os quais o SVM e as Árvores de Decisão, a fim de determinar a melhor técnica para classificação de 15 diferentes frutas e vegetais, a partir de imagens com resolução de 640×480 *pixels* no formato RGB, com 8-bits por canal e com fundo extraído para enfatizar apenas o alvo de treinamento. Nesse trabalho, a técnica SVM supera as árvores de decisão e as outras técnicas atingindo uma taxa de erro de apenas 5%.

Em [Arafat et al. 2016] e [Araújo et al. 2015], o classificador SVM, combinado com o descritor HOG, é utilizado para classificar imagens de folhas dos *datasets Flavia* e *Pl@ntView*, respectivamente. Ambas, bases de imagens vegetais disponíveis para a comunidade acadêmica. No primeiro trabalho, os autores obtiveram uma acurácia de 95% enquanto o segundo alcançou apenas 88.4%.

Em [He and Tian 2016] e [Reyes et al. 2015], redes neurais convolucionais são aplicadas à tarefa de classificação de folhas de diferentes bases de dados. As acurácias obtidas em cada trabalho são de 64.1% e aproximadamente 58%, respectivamente. Ambos os trabalhos utilizaram o *dataset Pl@ntView*, mas apenas o segundo utilizou uma rede pré-treinada com *dataset ImageNet*.

3. Material e Métodos

Por ser uma planta de origem Amazônica [Tavares et al. 2005], ainda é comum a ausência de imagens das folhas de cultivares de guaranazeiros da Embrapa em *datasets* públicos que disponibilizam seus dados para pesquisas na área de aprendizado de máquinas e visão computacional, como o *Pl@ntView*, *Flavia dataset* e *ImageNet*.

Dessa forma, foi essencial o desenvolvimento de um *dataset* próprio, com imagens de alguns dos principais cultivares de guaranazeiros desenvolvidos pela Embrapa. Assim, vinte amostras foliares dos espécimes BRS-Amazonas e BRS-Cereçaporanga

(dez de cada), ambos já resistentes às principais doenças que atacam o guaraná [Nascimento Filho et al. 1999, Nascimento Filho et al. 2007], foram coletadas e fotografadas em 28 de Março de 2017.

As imagens foram capturadas com uma resolução de 6000×4000 *pixels* por um sensor *Nikon D7100* em dois ângulos diferentes, totalizando 40 imagens no total, sendo 20 por cultivar. Em seguida, as fotos foram submetidas a um pré-processamento digital onde foram redimensionadas para 1000×1000 *pixels*, tiveram seus fundos subtraídos e as folhas foram centralizadas na imagem. Já tratadas, as amostras gráficas passaram por um processo de *data augmentation* a fim de expandir o *dataset* em 45 vezes seu volume inicial. A Figura 3 apresenta algumas amostras geradas a partir desse procedimento.



Figura 3. Amostras do *dataset* após pré-processamento e *data augmentation*. Na primeira linha, variedades do cultivar BRS-Amazonas e, na linha b), do BRS-Cereçaporanga.

Como resultado da técnica de *data augmentation*, o *dataset* desenvolvido teve seu volume ampliado para 1800 imagens, sendo 900 para cada cultivar/classe. O emprego desse procedimento teve certa relevância, visto que a planta do guaraná é arbustiva e, na época em que a coleta foi realizada no campo de guaranazeiros da Embrapa, em Manaus, as plantações não possuíam abundante quantidade de folhas compostas, sem anomalias fenotípicas e em fase adulta, o que inviabilizava a coleta de muitas amostras sem prejudicar os guaranazeiros.

Com a base de imagens já definida e devidamente pré-processada, optou-se por redimensionar todas as amostras do *dataset* para 224×224 *pixels*. Essa preocupação visa diminuir o tempo de treinamento e preservar apenas as características mais importantes nas imagens, que são invariantes até certos tamanhos. Esse processo é observado, também, em trabalhos como os de [Krizhevsky et al. 2012], [Simonyan and Zisserman 2014] e [Reyes et al. 2015].

Quanto aos classificadores clássicos, as árvores de decisão foram implementadas a partir do algoritmo CART (*Classification And Regression Tree*) e as máquinas de vetores de suporte foram utilizadas com dois diferentes *kernels*, um linear e outro RBF (*Radial Basis Function*), ambos com um parâmetro de penalidade $C = 2, 8$ e, no *kernel* de base radial, $\gamma = 10^{-1}$. Essas duas técnicas foram treinadas com e sem a utilização do descritor HOG que, por sua vez, foi configurado com suporte a 8 orientações, 16×16 *pixels* por células e 1×1 célula por bloco. Todos os métodos mencionados neste parágrafo foram providos e aplicados a partir da biblioteca *Scikit-learn* [Pedregosa et al. 2011].

Devido a algumas limitações referentes ao formato de entrada dos dados nos algoritmos CART, SVM e HOG, disponibilizados pela biblioteca *Scikit-learn*, nessas técnicas, foi-se necessário converter as imagens do *dataset* de forma a comportarem um único canal de cor, o cinza. Assim, o valor de cada *pixel* compreende-se entre 0 e 255, onde quanto mais próximo à 0, menor é a concentração de luz [Pedregosa et al. 2011].

As CNNs, por outro lado, foram elaboradas a partir da biblioteca *Keras*, um dos principais meios de implementação de redes convolutivas em *Python*. Diferentemente dos métodos clássicos, as CNNs dispensam a utilização de descritores como o HOG, à vista de sua arquitetura robusta que executa a extração de características por suas camadas convolucionais, conforme exemplifica a Figura 2.

Optou-se, então, por trabalhar com as arquiteturas LeNet e VGG-16 devido à notável popularidade desses modelos de CNNs, na literatura. Ambas as implementações foram treinadas com 60 épocas, uma vez que foi-se observado um ganho de quase 21% na acurácia final, quando em comparação com esses mesmos modelos treinados apenas com 30 épocas.

Todos os classificadores utilizaram a base de dados organizada a partir da metodologia *holdout*, reservando $\frac{2}{3}$ do *dataset* para treino e o restante para a avaliação, de forma aleatória. O ambiente utilizado para realizar tanto o treinamento quanto os testes foi uma instância dedicada do *Google Cloud Platform* com processamento *Intel® Xeon®* de 16 núcleos com 2,6GHz cada, 30GBi de memória RAM e sistema operacional *GNU/Linux Debian*.

4. Resultados e Discussões

Nesta seção, os resultados provenientes das avaliações experimentais dos métodos empregados neste trabalho, serão explanados e discutidos. Cada técnica foi testada com 594 imagens, equivalente a 33% do *dataset* e, com isso, foi possível calcular a taxa de acerto (acurácia) e erro, além da precisão de classificação de cada método, conforme explica a Tabela 1.

Tabela 1. Desempenho de classificação dos diferentes métodos abordados.

Técnica	Implementação	Acurácia (%)	Erro (%)	Precisão (%)
Rede Neural Convolutacional	LeNet	89.6	10.4	90.5
	VGG-16	48.5	51.5	24.0
Árvore de Decisão	CART	83.0	17.0	81.6
	CART + HOG	73.9	26.1	74.8
Máquina de Vetor de Suporte	<i>Kernel</i> linear	75.6	24.4	74.5
	<i>Kernel</i> RBF	49.8	50.2	25.0
	<i>Kernel</i> linear + HOG	81.1	18.9	85.1
	<i>Kernel</i> RBF + HOG	88.7	11.3	89.0

É possível observar, a partir da Tabela 1, que o modelo de CNN LeNet obteve a melhor performance de classificação, com uma acurácia e precisão de 89.6% e 90.5%,

respectivamente. A implementação do SVM com o *kernel* RBF, aliado ao descritor HOG, obteve o segundo melhor desempenho. O algoritmo CART e o SVM, com o *kernel* linear, conseguiram bons resultados, com e sem a utilização do HOG (*i.e.*, apenas a partir dos *pixels* das imagens) enquanto que o modelo VGG-16 e a implementação do SVM com o *kernel* RBF e sem a extração de características, obtiveram os piores resultados.

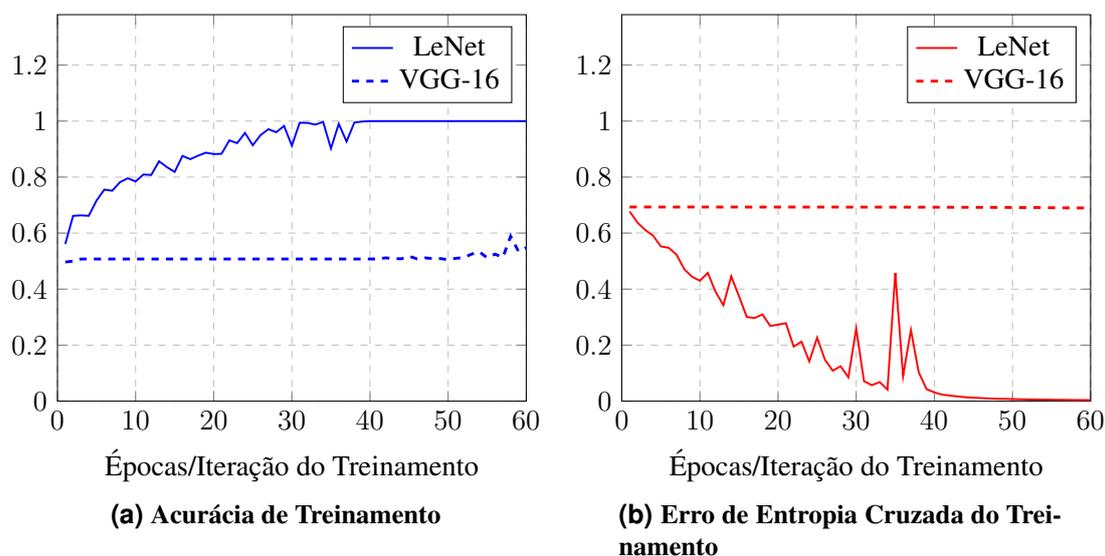


Figura 4. Métricas do treinamento de ambos os modelos de CNNs, a técnica que obteve, uma das melhores performances.

O comportamento de ambas as implementações das redes convolutivas (Figura 4), durante o treinamento, indica que, em 60 épocas, a rede LeNet convergiu rapidamente, isso, provavelmente, devido a simplicidade dessa arquitetura. A rede VGG-16, por outro lado, por ser um modelo mais robusto e com uma maior quantidade de "camadas profundas", em relação a LeNet, teve mais dificuldade para se estabilizar em bons resultados e isso pode ter ocorrido em consequência da quantidade de épocas definida para os treinos.

5. Considerações Finais

De forma geral, os métodos de classificação abordados nesse trabalho apresentaram bons resultados. Técnicas clássicas e estado da arte foram utilizadas a fim de obter-se uma comparação de performance para o contexto de distinção de cultivares de guaranazeiros, a partir da foto de uma amostra foliar. Os achados desta pesquisa referem-se a condições e protocolos experimentais, entretanto, com resultados promissores e que constatam a eficácia dos modelos de predição abordados ao decorrer deste projeto.

Mesmo que apenas dois cultivares (BRS-Amazonas e BRS-Cereçaporanga) tenham sido utilizados na elaboração de um *dataset* próprio, espera-se a expansão dessa base de imagens para um maior número classes e amostras fotografadas, além da disponibilização desse artefato na literatura, em um futuro breve.

Não obstante, novas metodologias e configurações de treinamento dos classificadores também podem ser exploradas em trabalhos posteriores. Técnicas como *fine-tuning* e/ou *cross-validation* podem ser agregadas em novos experimentos, em conjunto com o

uso de GPUs (*Graphics Processing Unit*) no processo de treinamento, para o enriquecimento dos resultados.

6. Agradecimentos

À Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM), pela disponibilização da bolsa de pesquisa; à Embrapa Amazônia Ocidental, pela infraestrutura disponibilizada; aos pesquisadores Firmino José do Nascimento Filho, Adauto Maurício Tavares e André Luiz Atroch, cuja disponibilidade e conhecimentos técnicos transmitidos foram imprescindíveis; e à toda a equipe do Núcleo de Tecnologia da Informação, em especial, ao Sr. Raimundo Barbosa e ao orientador deste trabalho, Marcos Filipe Alves Salame, por sua excelente orientação e recomendações.

Referências

- Arafat, S. Y., Saghir, M. I., Ishtiaq, M., and Bashir, U. (2016). Comparison of techniques for leaf classification. In *Digital Information and Communication Technology and its Applications (DICTAP), 2016 Sixth International Conference on*, pages 136–141. IEEE.
- Araújo, V. M., Britto, A. d. S. J., and Falate, R. (2015). Combinação de classificadores para identificação de plantas a partir da imagem da folha. *X Congresso Brasileiro de Agroinformática (SBIAGRO)*, 10.
- Dalal, N. and Triggs, B. (2005). Histograms of oriented gradients for human detection. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 1, pages 886–893. IEEE.
- Dvorak, P. and Menze, B. (2015). Structured prediction with convolutional neural networks for multimodal brain tumor segmentation. *Proceeding of the Multimodal Brain Tumor Image Segmentation Challenge*, pages 13–24.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., and Wang, G. (2015). Recent advances in convolutional neural networks. *arXiv preprint arXiv:1512.07108*.
- Haykin, S. O. (2001). *Redes Neurais: Princípios e Práticas*. Bookman, Porto Alegre, second edition.
- He, A. and Tian, X. (2016). Multi-organ plant identification with multi-column deep convolutional neural networks. In *Systems, Man, and Cybernetics (SMC), 2016 IEEE International Conference on*, pages 002020–002025. IEEE.
- IBGE (2015). Pesquisa mensal de previsão e acompanhamento das safras agrícolas no ano civil. *Levantamento Sistemático da produção Agrícola*, 29(4):49.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In Pereira, F., Burges, C. J. C., Bottou, L., and Weinberger, K. Q., editors, *Advances in Neural Information Processing Systems 25*, pages 1097–1105. Curran Associates, Inc.
- MAPA (2010). Instruções para execução dos ensaios de distinguibilidade, homogeneidade e estabilidade de cultivares de guaraná (*Paullinia cupana* var. *Sorbilis*). *República Federativa do Brasil: Diário Oficial da União*.

- Nascimento Filho, F., Atroch, A., Pereira, J., and Araújo, J. (2007). Brs-cereçaporanga: nova cultivar para o agronegócio do guaraná. *Embrapa Amazônia Ocidental. Comunicado Técnico*.
- Nascimento Filho, F. J., Atroch, A. L., da Silva Cravo, M., de Macêdo, J. L. V., Garcia, T. B., Júnior, R. C. C., and Ribeiro, J. d. R. C. (1999). *Clones de guaranazeiro para o Estado do Amazonas*. Embrapa Amazônia Ocidental.
- Nguyen, D. T. and Park, K. R. (2016). Enhanced gender recognition system using an improved histogram of oriented gradient (hog) feature from quality assessment of visible light and thermal images of the human body. *Sensors*, 16(7):1134.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12:2825–2830.
- Reyes, A. K., Caicedo, J. C., and Camargo, J. E. (2015). Fine-tuning deep convolutional networks for plant recognition. In *CLEF (Working Notes)*.
- Rocha, A., Hauage, D. C., Wainer, J., and Goldenstein, S. (2010). Automatic fruit and vegetable classification from images. *Computers and Electronics in Agriculture*, 70(1):96–104.
- Salame, Marcos F. A.; Salame, F. M. (2015). Comparação de técnicas de aprendizado de máquina com pré-processamento para decisão de profilaxia da tuberculose. In *I Congresso Amazônico de Computação e Sistemas Inteligentes*, volume 1, pages 73–80, Manaus. UEA.
- Shiba, M. H., Santos, R. L., Quintanilha, J. A., and KIM, H. (2005). Classificação de imagens de sensoriamento remoto pela aprendizagem por árvore de decisão: uma avaliação de desempenho. *Simpósio Brasileiro de Sensoriamento Remoto*, 12:4–319.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *CoRR*, abs/1409.1556.
- Tavares, A., Atroch, A., Nascimento Filho, F., Pereira, J., Araújo, J., Moraes, L., et al. (2005). Cultura do guaranazeiro no amazonas. *Manaus: Embrapa Amazônia Ocidental. Sistema de Produção*, 4.
- Tricaud, S., Pinton, F., and Pereira, H. d. S. (2016). Saberes e práticas locais dos produtores de guaraná (*paullinia cupana kunth var. sorbilis*) do médio amazonas: duas organizações locais frente à inovação. *Boletim do Museu Paraense Emílio Goeldi. Ciências Humanas*, 11(1):33–53.
- Vargas, A. C. G., Paes, A., and Vasconcelos, C. N. (2016). Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. *Conference on Graphics, Patterns and Images (SIBGRAPI)*, 29.
- Venkatesh, S. and Owens, R. (1990). On the classification of image features. *Pattern Recognition Letters*, 11(5):339–349.
- Yi, C., Yang, X., and Tian, Y. (2013). Feature representations for scene text character recognition: A comparative study. In *Document Analysis and Recognition (ICDAR), 2013 12th International Conference on*, pages 907–911. IEEE.