

# Classificação de Guaranazeiros Através do Padrão de Venação e Formato de Foliolos Utilizando Aprendizagem de Máquina

Alex de Lima Sousa<sup>1</sup>, Marcos Filipe Alves Salame<sup>1</sup>

<sup>1</sup> Núcleo de Tecnologia da Informação  
Embrapa Amazônia Ocidental  
Manaus – AM – Brasil

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

**Abstract.** *The guarana plant is a species considered an important source of income in Amazonian states that cultivate it. However, these cultivations are harmed due to the proliferation of local diseases and pests. To fix this problem, Embrapa provided cultivars resistant to the main problems that affect the cultivation of guarana in the Amazon, but the identification process of these cultivars are manual, costly and lacks human resources. Thus, this paper explored some supervised machine learning techniques such as Random Forests, Support Vector Machines, and Multilayer Perceptron Networks applied to help in this task, using venation patterns and leaflet shape. The results were stable and satisfactory, suggesting a new perspective on this problem*

**Resumo.** *O guaranazeiro é uma importante fonte de renda para estados amazônicos que o cultivam, porém sua produção é afetada devido à proliferação de pragas e doenças locais. Embrapa, então, lançou cultivares resistentes aos principais problemas que afetam a guaranaicultura na Amazônia, mas o processo de identificação desses cultivares são manuais, custosos e carente de recursos humanos. Assim, este trabalho buscou comparar técnicas de aprendizagem de máquinas como Florestas Aleatórias, Máquinas de Vetores de Suporte e Redes Perceptron aplicadas à tarefa de classificação desses cultivares, através do padrão da nervura e formato dos folíolos. Os resultados apresentam-se estáveis e satisfatórios, sugerindo uma nova perspectiva para o problema em questão.*

## 1. Introdução

O guaranazeiro (*Paullinia cupana* var. *sorbilis*) é uma planta nativa da biota amazônica, popular no Brasil devido as suas propriedades gastronômicas e energéticas. Suas sementes, por deterem alto teor de cafeína, são amplamente utilizadas em indústrias de energéticos e refrigerantes, podendo também serem comercializadas na forma de xarope, extratos e pó, agregando considerável valor socioeconômico aos estados que cultivam essa espécie [da Silva et al. 2016].

Porém, mesmo sendo uma planta originalmente da Amazônia, os Estados dessa região não são os principais produtores no Brasil [IBGE 2017]. Dentre as principais causas dessa baixa produtividade, há a ausência de uma diversidade genética suficientemente resistente a proliferação de pragas e doenças amazônicas. Esse cenário não é novo e motivou, no final da década de 70, a Empresa Brasileira de Pesquisa Agropecuária (Embrapa), através da unidade Amazônia Ocidental (em Manaus, Amazonas), iniciar um programa

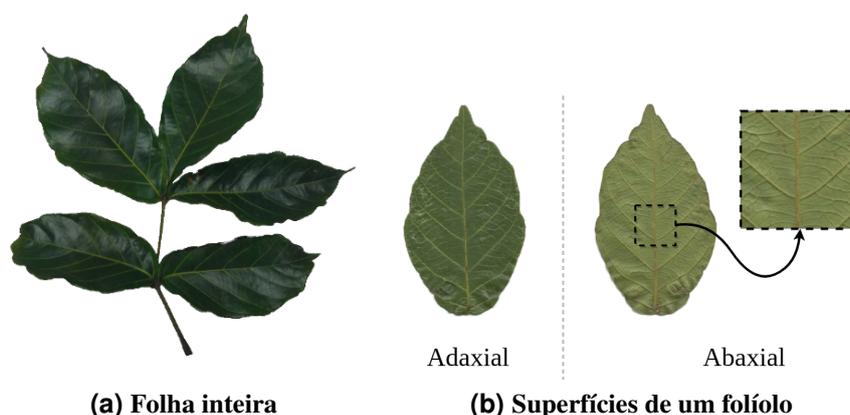
de melhoramento genético no guaranazeiro que objetivava a expansão da produção do guaraná na Amazônia. Assim, foram desenvolvidas e disponibilizadas 19 cultivares resistentes aos principais fatores bióticos e abióticos que afetam a guaranaicultura na região amazônica [Tricaud et al. 2016].

Tendo em vista a quantidade e a similaridade fenotípica dentre esses cultivares desenvolvidos, o Ministério da Agricultura, Pecuária e Abastecimento do Brasil disponibilizou uma documentação catalogando as principais características desses organismos para auxiliar o seu processo de distinção [MAPA 2010].

Esse documento, entretanto, possui dados que são apresentados de forma que apenas especialistas em botânica e/ou guaranaicultura possam usufruir corretamente de seu conteúdo. Além disso, análises para distinguir cultivares através dos dispostos desse material podem demandar tempo e recursos financeiros em processos técnicos laboratoriais.

Os recentes avanços em *hardware* e áreas como a aprendizagem de máquina, já viabilizam processos automatizados para identificação de espécies vegetais. Dentre as vantagens oferecidas, esse tipo de abordagem ajuda na otimização de tempo e do erro humano, uma vez que essas análises podem se tornar complexas devido à alta similaridade entre algumas características morfológicas dos cultivares [Wu et al. 2007].

Abordagens que utilizam descritores visuais como o formato, textura e/ou coloração das folhas para esse tipo de tarefa são profusas na literatura [Rocha et al. 2010, Arafat et al. 2016, He and Tian 2016, Lee et al. 2017]. Essas características também podem ser exploradas por especialistas em processos de classificação manual e, no caso dos cultivares de guaranazeiros, geralmente a textura e a forma da folha inteira são os principais descritores usados [MAPA 2010].



**Figura 1. Folha do guaranazeiro e a superfície de seus folíolos. Em (a), há a imagem da folha inteira de um dos cultivares, enquanto que (b) ilustra as duas superfícies que cada folíolo da folha possui, destacando parte da nervação foliar visível na superfície abaxial.**

Acredita-se que a vantagem ao utilizar a folha inteira esteja relacionada à quantidade de características presentes em uma única amostra. Por exemplo, de modo geral uma única unidade foliar do guaranazeiro é composta por cinco folíolos conectados a uma ráquis, com duas superfícies: adaxial e abaxial, conforme a Figura 1 ilustra.

Trabalhos que exploraram a classificação de cultivares de guaranazeiros, atra-

vés de técnicas de aprendizagem de máquinas, costumam utilizar imagens da superfície adaxial de folhas inteiras (Figura 1a), como é o caso apresentado em [Sousa and Salame 2017], onde a performance de técnicas clássicas, como Máquinas de Vetores de Suporte (*Support Vector Machines* – SVM) e Árvores de Decisão (*Decision Trees* – DT), são comparadas a modelos de Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNN), a fim de identificar uma abordagem mais acurada.

Entretanto, os padrões de venação (Figura 1b), mais visíveis na superfície abaxial de folhas, também possuem destaque em tarefas de classificação vegetal, através de técnicas de aprendizagem supervisionada de máquinas. Alguns trabalhos ([Park et al. 2008, Grinblat et al. 2016, Larese and Granitto 2016]) que abordam esse descritor como entrada em seus algoritmos apresentam resultados promissores devido a morfologia dessas estruturas, que são tidas como um robusto identificador biométrico de grupos taxonômicos [Sack and Scoffoni 2013, Lee et al. 2017].

Consideramos avaliar neste trabalho, então, o comportamento de três populares técnicas clássicas de aprendizagem supervisionada de máquinas: i) SVMs; ii) Redes Perceptron Multicamada (*Multilayer Perceptron* – MLP); e iii) Florestas Aleatórias (*Random Forests* – RF), quando utilizadas para a tarefa de classificação de três cultivares de guaranazeiros, através de imagens de toda a superfície abaxial dos folíolos desses cultivares. Assim, combinando dois descritores morfológicos: o formato do folíolo e sua venação.

Em relação às técnicas de classificação que serão abordadas, as SVMs, baseadas na Teoria de Aprendizado Estatístico (TAE), obtiveram atenção da comunidade nos últimos anos devido a sua boa capacidade de generalização, com resultados comparáveis ou superiores às Redes Neurais Artificiais (RNA), especialmente em contextos de categorização de texto e campos como a visão computacional. Já as redes do tipo MLP constituem uma categoria de RNAs que, por meio de uma ou mais camadas ocultas de neurônios artificiais, podem ser utilizadas em problemas não lineares de classificação. As RFs, por sua vez, surgem da combinação de duas ou mais DTs (*i.e.*, *ensemble*) não podadas e são caracterizadas pela seleção randômica dos atributos de decisão de cada árvore, além da utilização de métodos de subamostragem de dados [Marsland 2009, Faceli et al. 2011].

Dessa forma, espera-se identificar através dos experimentos, se a hipótese quanto ao padrão de venação combinado com o formato das folhas constituem um identificador biométrico significativo para o problema de identificação das variedades de guaranazeiros, através de técnicas clássicas de aprendizagem de máquina.

O texto deste artigo está organizado da seguinte forma: a Seção 2 apresenta a metodologia utilizada na aquisição da base de dados, pré-processamento e experimentação das técnicas; a 3 busca apresentar e discutir sobre os resultados alcançados e, por fim, a Seção 4 traz algumas considerações sobre o trabalho, como um todo.

## 2. Material e métodos

### 2.1. Base de dados

Observado a ausência de uma base de dados (*dataset*) com imagens de folíolos dos cultivares de guaranazeiros desenvolvidos pela Embrapa, foi necessária a elaboração de uma base específica para o contexto deste trabalho.

Dessa forma, o *dataset* foi elaborado com as três seguintes variedades: i) BRS-Luzéia; ii) BRS-Maués; e iii) CG-612. Todos esses espécimes são considerados clones de alta produtividade (*i.e.*, capazes de produzir, ao menos, 1Kg de sementes secas por planta/ano), apresentando maiores índices de produção do guaraná e resistência às principais pragas e doenças locais, quando comparados com guaranazeiros de cultivos tradicionais, oriundos de sementes [do Nascimento Filho et al. 1999, Costa 2017].

A coleta de todas as folhas ocorreu no mesmo dia, em dezembro de 2017, no campo de guaranazeiros da Embrapa Amazônia Ocidental (2°53'39.5" S 59°58'20.8" W). As amostras foram agrupadas por cultivar e cada unidade foliar teve seus folíolos destacados para, então, se iniciar a aquisição das imagens. Nessa última etapa, foram utilizados os sensores *Canon EOS 6D* e *Samsung Xpress M2070FW* para se obter, respectivamente, representações gráficas fotografadas e escaneadas da superfície abaxial de cada folíolo.

Com as amostras já no formato digital e devidamente organizadas, a base foi validada por engenheiros agrônomos e pesquisadores especialistas em guaranaicultura, da própria Embrapa. Dessa forma, foi possível obter um *dataset* conciso com 434 imagens da superfície abaxial de folíolos dos cultivares selecionados, dispostas conforme a Tabela 1.

**Tabela 1. Disposição do *dataset*, com a quantidade de imagens por cultivar/classe.**

Rótulo	Classe	Quant. de imagens	%
0	BRS-Luzéia	148	34
1	BRS-Maués	157	36
2	CG-612	129	30
<b>Total</b>		434	100

## 2.2. Pré-processamento

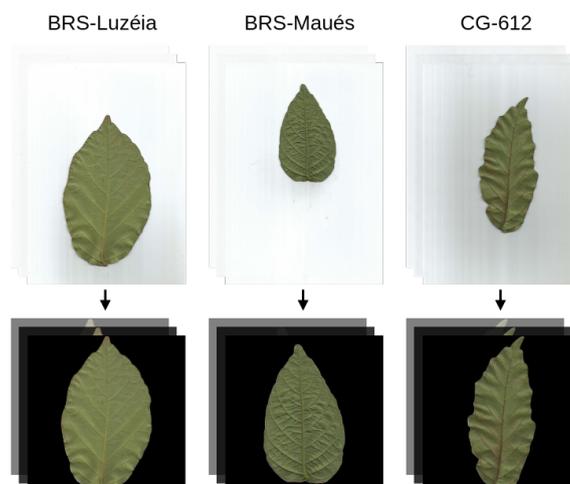
As técnicas de Pré-processamento Digital de Imagens (PDI) foram utilizadas em cada instância do *dataset* elaborado e, visto que as imagens da base não se encontram em grandíssima quantidade, os procedimentos foram aplicados manualmente através de ferramentas disponibilizadas por softwares de edição gráfica, como o *Adobe Photoshop*.

Assim, essa etapa se iniciou com a subtração do plano de fundo de cada amostra, de modo a reduzir ruídos adjacentes à região de interesse. Em seguida, os folíolos foram ajustados e centralizados em uma matriz RGB, com dimensões de  $1024 \times 1024$  pixels. Uma visualização das imagens antes e após esse processo é ilustrada na Figura 2.

Objetivando reduzir o tempo de treinamento dos classificadores e também atenuar ruídos, neste trabalho, as imagens foram redimensionadas para  $128 \times 128$  pixels. Por fim, o *dataset* foi armazenado no formato HDF5 (*Hierarchical Data Format*), para ser utilizado posteriormente com mais praticidade.

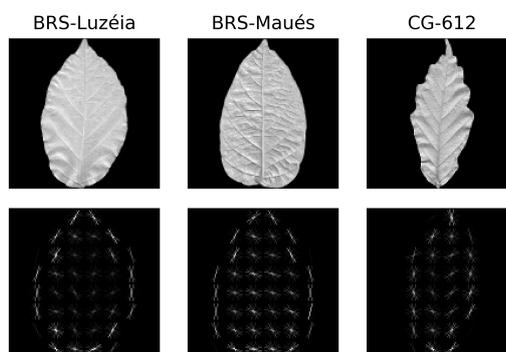
## 2.3. Extração de características

No processo de classificação de dados não estruturados, como no caso de imagens, vídeos, áudios e textos, geralmente são utilizadas técnicas para extração de uma representação das



**Figura 2.** Amostras da base de imagens antes e após a etapa de pré-processamento.

características primitivas dos dados. À vista disso, as informações de entrada para o classificador são otimizadas, uma vez que se utiliza apenas as estruturas mais discriminativas das amostras [Yi et al. 2013, Arafat et al. 2016].



**Figura 3.** Imagens em tons de cinza e, em seguida, as respectivas representações de suas características extraídas pelo algoritmo HOG.

Dessa forma, cada imagem da base elaborada passou por uma etapa cujo propósito concentrou-se na extração de uma representação das características primitivas. Dentre os diversos métodos possíveis para essa tarefa, foi utilizado o algoritmo de Histogramas de Gradientes Orientados (*Histogram of Oriented Gradients* – HOG) a fim de se obter representações baseadas na variação de intensidade dos *pixels*. Essa técnica foi escolhida por também ser utilizada em [Sousa and Salame 2017] e, portanto, permitirá comparar os resultados entre as abordagens.

Antes da aplicação do extrator de características, as imagens foram convertidas para um único canal de cor, em tons de cinza, visando amenizar a influência das cores no processo de classificação, preservando apenas o formato e intensidade de luminosidade dos folíolos. Na Figura 3, é possível observar demonstrações de entradas (imagens em tons de cinza) e saídas (vetores de características) do HOG.

O algoritmo HOG foi configurado para registrar características em 8 orientações distintas, utilizando  $16 \times 16$  *pixels* por célula e  $2 \times 2$  células por bloco, sendo que cada bloco foi normalizado através da função *L2-Hys*.

## 2.4. Experimentos

Os experimentos foram elaborados com três técnicas de classificação: SVMs, RFs e MLPs. Cada uma treinada e avaliada a partir dos mesmos vetores de características, obtidos através do algoritmo HOG. Os parâmetros de cada classificador foram ajustados (*tuning*) através da classe *RandomizedSearchCV*, implementada na biblioteca *Scikit-learn*, da linguagem de programação *Python*. No processo de *tuning* das técnicas, foi utilizado 80% da base, enquanto que o restante foi reservado para validar a qualidade dos parâmetros encontrados. Durante as 500 iterações executadas em cada técnica, para se encontrar bons parâmetros, a performance foi verificada por meio da validação cruzada com 10 *folds* usando dados embaralhados.

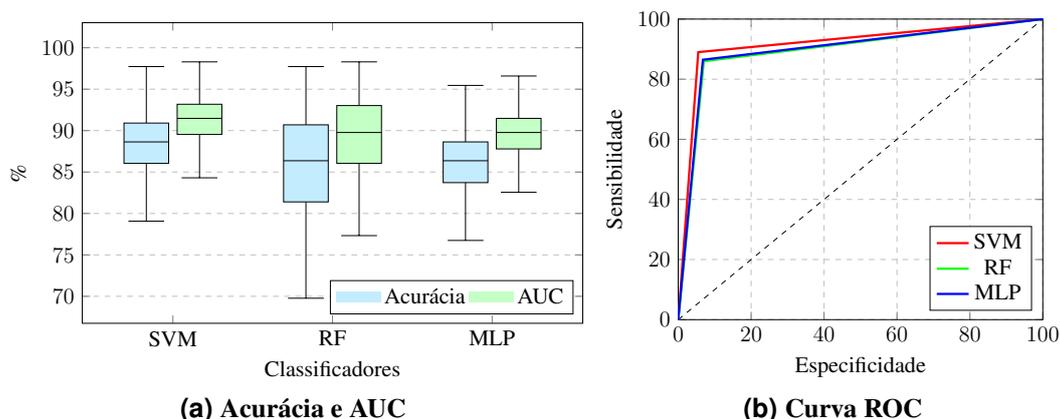
Nas SVMs, por se utilizar o *kernel* de base radial (*Radial Basis Function* – RBF) devido à classificação multiclasse, o parâmetro de penalidade *C* e o coeficiente gama ( $\gamma$ ) do *kernel* foram ajustados de modo que, para essas variáveis, respectivamente, os valores 11.211131845694453 e 0.00020940922647248966 apresentaram maior ganho de performance. No caso das RFs, os parâmetros ajustados que mais ajudaram a técnica a desenvolver-se no contexto foram: o número de árvores, a profundidade máxima de cada árvore, o número mínimo de amostras necessárias para dividir um nó interno e o número mínimo de amostras requeridas em cada nó da folha. Os melhores valores identificados para cada uma dessas variáveis foram, respectivamente: 100, 40, 2 e 2. Por fim, o *tuning* realizado na técnica MPL combinou algumas topologias, funções de ativação, otimizadores e taxas de aprendizagem, visando identificar um arranjo que ajudasse a técnica obter boa performance no contexto deste trabalho. Dessa forma, identificou-se que uma rede rasa, com uma única camada oculta de 100 neurônios artificiais, utilizando a função de ativação *ReLU*, o otimizador *Adam* e taxa de aprendizagem adaptativa, com valor inicial de 0.001, obtinha melhores resultados.

Após o *tuning*, as técnicas foram retreinadas com os parâmetros identificados e utilizando, agora, toda a base em uma validação cruzada com 10 *folds*. Para cada técnica, esse processo ocorreu com 10 repetições, totalizando 100 treinamentos e avaliações. Assim, os resultados obtidos nesta fase são apresentados e discutidos na Seção 3.

Ao longo de toda a fase de experimentação, que envolve os passos descritos nesta seção, a avaliação dos classificadores ocorreu a partir de métricas como: matriz de confusão normalizada, taxa acurácia, curva ROC (*Receiver Operating Characteristic*) e área abaixo da curva ROC (*Area Under the Curve* – AUC).

## 3. Resultados e discussão

Os experimentos realizados mostraram que todas as técnicas abordadas apresentam, de forma geral, resultados satisfatórios quando aplicadas ao contexto, conforme observa-se na Figura 4. Dessa forma, os resultados alcançados corroboram o que outros trabalhos na literatura expõem em relação à influência dos padrões de venação foliar. Não obstante, a combinação desse descritor com o formato do folíolo pode ajudar as técnicas, uma vez que essa característica também é utilizada por especialistas.



**Figura 4. Performance de classificação das técnicas, obtidas a partir 100 execuções de validação cruzada 10-fold.**

A Tabela 2 expressa o resultado médio da acurácia e AUC, obtidas para cada um dos classificadores utilizados. Assim, é possível observar que as máquinas de vetores de suporte apresentam uma melhor performance quando comparada às demais técnicas.

**Tabela 2. Média das principais métricas utilizadas.**

Classificador	Acurácia (%)	AUC (%)
SVM	$89.00 \pm 4.41$	$91.75 \pm 3.30$
MLP	$86.47 \pm 4.88$	$89.85 \pm 3.66$
RF	$85.97 \pm 5.78$	$89.48 \pm 4.33$

Embora os resultados apresentados aqui ainda não sejam superiores aos obtidos através de metodologias que utilizam imagens da superfície adaxial de folhas inteiras, no processo de classificação [Sousa and Salame 2017], acredita-se que abordagens baseadas na venação foliar de folíolos dos cultivares de guaranazeiros possam evoluir, através de experimentos com novas técnicas de classificação e/ou extração de características.

#### 4. Considerações finais

Este trabalho buscou explorar três técnicas de aprendizagem supervisionada de máquina, aplicadas ao contexto de classificação de cultivares guaranazeiros desenvolvidos pela Embrapa, através de características extraídas de imagens com o padrão de venação foliar e formato dos folíolos.

Os resultados apresentam-se promissores, mostrando que o padrão de venação de fato pode ser utilizado em tarefas de classificação dos cultivares de guaranazeiros. Além disso, há também a possibilidade de disponibilização desses modelos como um produto (*e.g.*, um aplicativo para *smartphones*), a fim de colaborar com o trabalho de técnicos e especialistas. Nesse caso, acredita-se que há a necessidade de utilizar técnicas automatizadas de PDI para realizar a subtração do fundo, preservando apenas o folíolo na imagem.

Outra contribuição deste trabalho está no *dataset* elaborado exclusivamente para os processos metodológicos abordados. Dessarte, constituindo-se a primeira base de imagens, com folíolos dos cultivares de guaranzeiros da Embrapa. Espera-se disponibilizar essa base em breve, visando contribuir com pesquisas futuras neste tema.

A exploração de técnicas mais sofisticadas, como as redes neurais convolucionais, e a adição de novos cultivares ao *dataset*, mostram-se também interessantes etapas a se abordar futuramente. Da mesma forma, a experimentação utilizando apenas o padrão de venação, localizado no centro do folíolo, visando verificar se o formato da folha contribui com a performance das técnicas de classificação é uma possibilidade intrigante a se estudar.

## 5. Agradecimentos

Os autores expressam seus agradecimentos à Fundação de Amparo à Pesquisa do Amazonas (FAPEAM), pela bolsa de pesquisa concedida ao primeiro autor deste trabalho; e aos pesquisadores da Embrapa Amazônia Ocidental, Firmino José do Nascimento Filho e André Luiz Atroch, pelo auxílio técnico no que diz respeito à guaranaicultura.

## 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.
- Costa, L. F. B. d. (2017). Cultivadores de guaraná: um estudo do processo de monopolização do território pelo capital no município de Maués-AM. 2017. Master's thesis, Universidade Federal do Amazonas, Manaus. Mestrado em Geografia.
- da Silva, E. F., de Sousa, S. B., da Silva, G. F., Sousa, N. R., do Nascimento Filho, F. J., and Hanada, R. E. (2016). Trap and srp markers to find genetic variability in complex polyploid paullinia cupana var. sorbilis. *Plant Gene*, 6:43–47.
- do Nascimento Filho, F., Atroch, A., Cravo, M. d. S., de Macedo, J., Coutinho, E., Ribeiro, J., and Costa Júnior, R. (1999). Guaraná: BRS-Amazonas e BRS-Maués - clones para o Estado do Amazonas. *Embrapa Amazônia Ocidental-Fôlder/Folheto/Cartilha (INFOTECA-E)*.
- Faceli, K., Lorena, A. C., Gama, J., and de Carvalho, A. C. P. L. F. (2011). *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*. LTC Editora, Rio de Janeiro, 1 edition.
- Grinblat, G. L., Uzal, L. C., Larese, M. G., and Granitto, P. M. (2016). Deep learning for plant identification using vein morphological patterns. *Computers and Electronics in Agriculture*, 127:418–424.
- 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 (2017). Levantamento sistemático da produção agrícola: pesquisa mensal de previsão e acompanhamento das safras agrícolas no ano civil. *Levantamento sistemático da produção agrícola*, 30(12):1–82.

- Larese, M. G. and Granitto, P. M. (2016). Finding local leaf vein patterns for legume characterization and classification. *Machine Vision and Applications*, 27(5):709–720.
- Lee, S. H., Chan, C. S., Mayo, S. J., and Remagnino, P. (2017). How deep learning extracts and learns leaf features for plant classification. *Pattern Recognition*, 71:1–13.
- 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*.
- Marsland, S. (2009). *Machine Learning: An Algorithmic Perspective*. Chapman and Hall/CRC, Boca Raton - FL - USA, 2 edition.
- Park, J., Hwang, E., and Nam, Y. (2008). Utilizing venation features for efficient leaf image retrieval. *Journal of Systems and Software*, 81(1):71–82.
- 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.
- Sack, L. and Scoffoni, C. (2013). Leaf venation: structure, function, development, evolution, ecology and applications in the past, present and future. *New Phytologist*, 198(4):983–1000.
- Sousa, A. d. L. and Salame, M. F. A. (2017). Uma abordagem comparativa de algoritmos de aprendizado supervisionado para classificação dos cultivares da planta paullinia cupana. *VI Encontro Regional de Computação e Sistemas de Informação (ENCOSIS)*, pages 121–129.
- 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.
- Wu, S. G., Bao, F. S., Xu, E. Y., Wang, Y., Chang, Y., and Xiang, Q. (2007). A leaf recognition algorithm for plant classification using probabilistic neural network. In *2007 IEEE International Symposium on Signal Processing and Information Technology*, pages 11–16.
- 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.