

Reconhecimento de plantas comestíveis não convencionais: uma análise de métodos de classificação aplicados à visão computacional

Gustavo Rangel T. de Almeida¹, Virgílio Locatelli Soares¹,
Márcio Jose Moutinho da Pontes¹, Fábio Manoel França Lobato¹

¹Instituto de Engenharia e Geociências - Universidade Federal do Oeste do Pará
Santarém, Pará, Brasil

gr.almeida00@gmail.com, virgiliopaumgartten@gmail.com

mjmoutinho@yahoo.com.br, fabio.lobato@ufopa.edu.br

Resumo. *A vasta biodiversidade da floresta amazônica abre portas para muitos estudos, inclusive acerca da utilização de métodos computacionais para analisar fauna e flora. Verificando uma lacuna no estudo de plantas comestíveis não convencionais (PANCs) na Região do Oeste do Pará, objetivou-se utilizar de técnicas de visão computacional para identificação automática de plantas pertencentes à esta categoria. Para obter tal resultado, avaliou-se a utilização de sete classificadores para reconhecimento em imagens digitais das PANCs. Os resultados apresentaram uma boa precisão no reconhecimento das classes das imagens de teste. Como impacto direto do estudo, destaca-se a possibilidade de se desenvolver um aplicativo de suporte à decisão para reconhecimento automático de PANCs a fim de ser utilizado por órgãos reguladores.*

Abstract. *Amazon forest's vast biodiversity opens doors to many studies, including the use of computational methods to analyze the fauna and flora. Checking the gap in the study of unconventional edible plants (UEPs) in the western region of Pará, in this work are used computer vision techniques to automatically identify plants belonging to this category. For such a result, we evaluated the use of seven classifiers for recognition in digital images of UEPs. The results showed good accuracy in the recognition of the classes on the test images. As a direct impact of the study, we highlight the possibility of developing a decision support application for automatic recognition of UEPs in order to be used by regulatory institutions.*

1. Introdução

É consenso que a floresta amazônica possui um dos maiores ecossistemas do planeta terra. Portanto, é compreensível que muitas pessoas que vivem nesta região não a conheçam inteiramente, em termos de fauna e flora [Hoorn et al. 2010]. Mesmo nessa falta de conhecimento completo sobre o ambiente, a população brasileira sempre incorporou a cultura original de populações indígenas na culinária popular, assim como de outras culturas, como as de origem africana e japonesa, entre outras. Muitos alimentos típicos do Brasil são bem conhecidos, outros permaneceram no anonimato para a população em geral [Kinupp and Lorenzi 2014].

Recentemente, os recursos alimentares silvestres têm atraído o interesse do consumidor pelo valor nutricional que lhes é reconhecido, pela sua importância na identidade gastronômica local, bem como pela necessidade de diversificar a alimentação e descobrir alimentos com novas cores, paladares e texturas [Bredariol 2015]. Os alimentos citados anteriormente foram denominados pela comunidade científica de Plantas Alimentícias Não Convencionais (PANCs) [Duarte 2018].

A quantidade de plantas que pertencem a essa categoria ainda não foi completamente mapeada, sendo que cada região, independentemente de ser no Brasil ou no exterior, possuem seus tipos específicos de PANCs [Bredariol 2015]. Na literatura, são encontrados alguns trabalhos que realizam a categorização ou classificação de PANCs em determinadas regiões, porém não foram encontrados trabalhos que realizassem estas pesquisas na Região Norte do Brasil [Duarte 2018].

Observando as constatações supracitadas, este trabalho objetiva aplicar uma técnica de reconhecimento de imagem utilizando como base as PANCs, dessa forma criando uma ferramenta capaz de classificar as plantas e gerar um modelo de reconhecimento preciso, mais especificamente as plantas presentes no Oeste do estado do Pará. Para realizar este reconhecimento foi definido que será utilizada uma técnica baseada em *Machine learning* chamada classificação por *K-Nearest Neighbors*.

Este é um estudo de natureza aplicada e experimental, similar ao trabalho de [Sousa et al. 2018], que comparou técnicas de aprendizado de máquina para a previsão anual de precipitação em Manaus, Amazonas. No presente estudo, fez-se necessário a implementação das técnicas de aprendizado de máquina utilizadas em reconhecimento de imagens digitais e em paralelo a aquisição de conhecimento através do saber popular sobre os vegetais comestíveis exóticos.

Como a pesquisa de PANCs na Região Norte ainda não foi muito aprofundada, um dos diferenciais do presente estudo foi a construção de um banco de dados de PANCs por meio de coleta manual de imagens digitais das plantas de interesse. Estas imagens foram utilizadas para treinar sete métodos de classificação, cujos desempenhos foram comparados para o reconhecimento de plantas comestíveis não convencionais. Os resultados mostram os métodos que apresentam boa acurácia, mas também o custo computacional associado. Como potencial impacto deste trabalho têm-se o desenvolvimento de uma aplicação móvel para coleta automática de imagens e monitoramento em tempo real, tal como no trabalho de [Visentini et al. 2018]. Tal aplicação pode auxiliar a tarefa de monitoramento agrícola e em feiras.

O artigo está organizado como segue. A Seção 2 trata de pesquisas relacionadas que utilizam da visão computacional e técnicas de classificação. Na Seção 3 a metodologia seguida no trabalho é descrita. Na Seção 4 os resultados alcançados são apresentados e discutidos. Por fim, na Seção 5 são apresentadas as conclusões do estudo e sugestões de trabalhos futuros.

2. Trabalhos Relacionados

O uso de técnicas de aprendizado de máquina (AM) para classificação de padrões vem aumentando nos últimos anos e já existem diversas áreas em que o benefício advindo desse tipo de técnica é bastante positivo. Uma dessas áreas é a de reconhecimento de

imagens [Bezerra and Oliveira 2006]. Pesquisas de AM estudam o desenvolvimento de métodos capazes de extrair conceitos (conhecimento) a partir de amostras de dados.

Na área de reconhecimento de plantas existe uma ferramenta bem estabelecida no mercado, conhecida por *PlantNet*¹. Esta ferramenta utiliza bancos de dados de imagens diversificados, entre as várias regiões do mundo e tipos de plantas, para entregar um classificador de plantas acurado. Além disso, estes bancos de dados são constantemente incrementados por usuários. Apesar do *dataset* robusto, ele pode não reconhecer plantas não convencionais, devido ao desconhecimento da população de uma região sobre sua fauna ou pela falta de tecnologias em certas regiões para geração de novos *datasets*. E, apesar de sua acurácia e reconhecimento, o seu código não é aberto, o que dificulta a replicabilidade ou incrementação das técnicas utilizadas. Portanto, o estudo de técnicas de reconhecimento na literatura é necessário.

Em [Hossain and Amin 2010] os autores utilizaram PNN para classificar as plantas com folhas largas e planas. Neste algoritmo haviam poucos *selects*, ou seja, pontos em que o usuário precisa para identificar as folhas e um ponto de base com o qual a imagem é alinhada e comparada com as outras imagens com base em algumas características como área, excentricidade, etc. Nesse estudo 1200 folhas de amostra pertencentes a 30 plantas diferentes foram utilizadas para treinar seu sistema. Este sistema também é semi-automático e com precisão de 91,41 %.

Embora uma quantidade significativa de pesquisa tenha sido feita estudando vários aspectos da identificação de folhas em sistemas de estoque, a maioria deles lida com sistemas semi automatizados. Um sistema de última geração que é totalmente automatizado e requer menos interação humana ainda está para ser desenvolvido [Satti et al. 2013]. Diferentes tipos de técnicas são utilizadas pelos autores para o reconhecimento de imagens contendo folhas. Apesar de ser notória a grande utilização de redes neurais em pesquisas nesse âmbito, as demais técnicas também são facilmente encontradas.

Em [Kumar et al. 2011] é feita uma pesquisa de *survey* sobre os melhores classificadores para reconhecimento de plantas e folhas. Este autor determina que o classificador KNN (*K-Nearest Neighbors*) é o que possui o funcionamento mais simples, e tem seu uso mais específico para *datasets* pequenos. Apesar de ter um funcionamento simples, este obtém bons resultados e tem a vantagem de o seu tempo de computação para treinamento dos modelos de reconhecimento serem quase instantâneos. No trabalho de [Satti et al. 2013] o KNN é utilizado, assim como, a classificação ANN (Artificial Neural Network) e seus resultados são comparados. Como resultado é verificado que a precisão do KNN é maior quando o *dataset* tem menos classes, porém quando o *dataset* aumenta, o ANN ultrapassa em precisão.

3. Metodologia

Nesta seção serão apresentadas as atividades executadas nesta pesquisa, baseadas nas etapas do Processamento de Digital de Imagem (PDI), que é uma metodologia padrão para estudos de análise de imagens digitais. Na Figura 1 é demonstrado uma instanciação das fases desse processo, as quais foram seguidas como metodologia do trabalho.

¹<https://identify.plantnet.org>

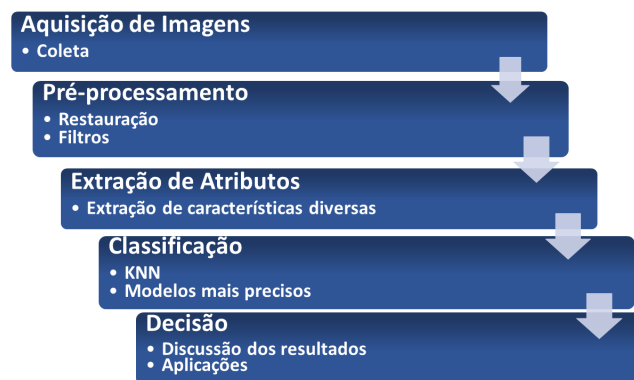


Figura 1. Processos de Processamento Digital de Imagens utilizados no estudo.

3.1. Aquisição das imagens

Nesta pesquisa foram utilizados oito tipos diferentes de PANCs, coletadas e fotografadas no decorrer da pesquisa, conforme apresentado na Figura 2, a citar: a - Jurubeba (*Solanum Paniculatum*); b - Beldroega (*Portulaca Oleracea*); c - Corifeu (Nome científico não identificado); d - Capeba (*Pothomorphe Umbellata*); e - Maxixe (*Cucumis Anguria*); f - Crista de Galo (*Celosia argentea*); g - Broto de Samambaia (*Pteridium Aquilinum*); h - Fruta-pão (*Artocarpus altilis*).




Figura 2. Exemplos de PANCs utilizados no estudo.

Os espécimes apresentados na Figura 2 foram adquiridos na mata selvagem próxima a cidade de Alenquer – PA, e as fotos foram retiradas no campus da universidade utilizando uma câmera fotográfica semi profissional.

3.2. Pré-processamento

Nesta etapa, são executados dois pré-processamentos: restauração e filtragem. Na restauração, a imagem foi alterada para que a folha seja o único foco e o fundo possua o máximo de branco possível. Esta alteração foi realizada automaticamente em todas as imagens utilizando uma ferramenta de edição de imagem e um *script* de automação. Já na utilização de filtros, as imagens passaram por duas filtragens: uma de transformação para escala de cinza e outra em que as regiões identificadas da folha são preenchidas por um nível de cinza médio.

3.3. Extração de características

Cada uma das imagens teve suas características extraídas para posterior análise. A partir desta fase da metodologia, todas os códigos e resultados foram alcançados utilizando a ferramenta MATLAB². A função “*leafFeaExtract*” no código tem como dever realizar essa extração, coletando as seguintes características: área/perímetro, excentricidade, maiores e menores distâncias entre pontos cartesianos, área convexa, média e variância. Além disso, também foram identificadas a borda da folha e uma lista dos índices dos *Pixels*. Esses dados, apesar de não serem visualizados nos resultados, são utilizados pelo classificador para obter os seus resultados.

3.4. Classificação

Para a análise e classificação das imagens, escolheu-se por utilizar a técnica baseada em *Machine learning* chamada de classificação por *K-Nearest Neighbors*. Com esta técnica objetiva-se obter um modelo de reconhecimento que utilizando as características extraídas, identifique com precisão a qual classe uma planta de determinada imagem pertence. Ela foi selecionada por suas altas taxas de reconhecimento e tempo de computação baixo, quando utilizada em *datasets* pequenos, o que se aplica no estudo de caso atual.

4. Resultados

Nesta seção serão apresentados os resultados das etapas definidas na metodologia. Em resumo, o estudo de caso utilizado no experimento, os resultados da extração de características e da classificação, e uma análise de desempenho de métodos de classificação.

4.1. Estudo de caso

Como estudo de caso para o experimento tem-se os oito tipos de folhas coletadas, sendo que o número de instâncias para cada classe de folha é apresentado na Figura 3. Nela temos as oito classes de folhas, e um total de 281 instâncias dentro das classes.




Figura 3. Distribuição de exemplos por classe.

²<https://www.mathworks.com/matlabcentral/>

4.2. Produtos da extração de características

Para observar a extração das características, em uma imagem arbitrária do *dataset* foram executadas as fases finais do pré-processamento, citadas na metodologia. Na Figura 4 estão presentes as versões geradas da imagem.

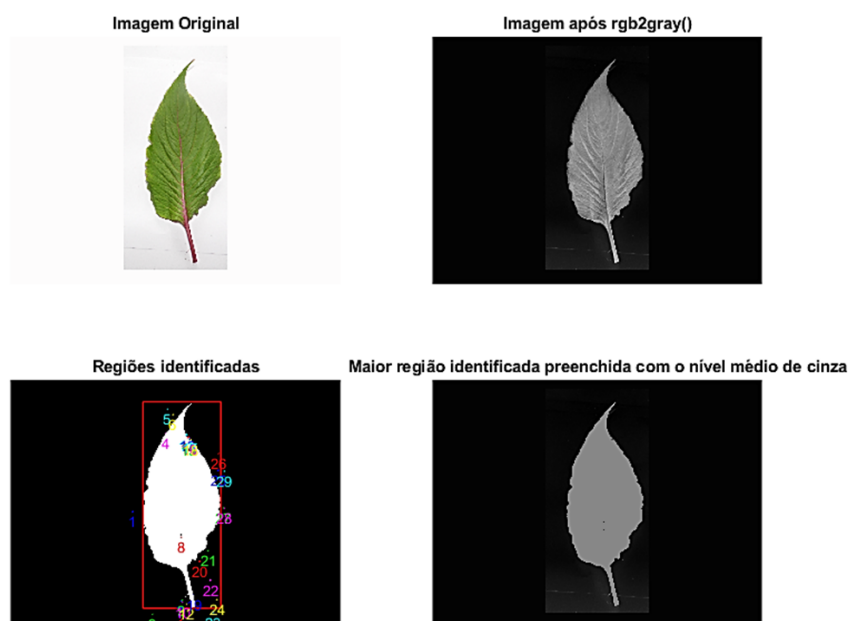


Figura 4. Resultado da extração de característica em uma das folhas do *dataset*.

Além disso, possuímos a distribuição das características identificadas no *dataset* de imagens na Figura 5. A distribuição por classe também pode ser visualizada, mas para os dados testados o resultado é semelhante ao da Figura 5.




Figura 5. Distribuição de características no *dataset*.

4.3. Resultados da classificação

A classificação através da técnica de KNN obteve **92,52%** de precisão no reconhecimento do *dataset*. Para obter uma precisão ainda melhor o *dataset* foi normalizado e o classificador obteve uma precisão de **98,22%**. Na Figura 6 é apresentado a matriz de confusão obtida.




Figura 6. Matriz de confusão obtido pelo classificador.

Para entender melhor o funcionamento da classificação e do modelo gerado para reconhecimento dos dados, foi realizada uma seleção sequencial das características que obtêm as melhores precisões. Uma seleção simples que testa cada característica e seleciona as combinações das leituras com melhores precisões. Este método obtêm o modelo de reconhecimento com melhor desempenho (Melhor precisão e menor número de características utilizadas), como mostrado na Figura 7, sendo o modelo identificado o que utiliza as características [3, 6, 4] (maiores e menores distâncias entre pontos cartesianos, variância e área convexa, respectivamente), com precisão de **98,3%**.

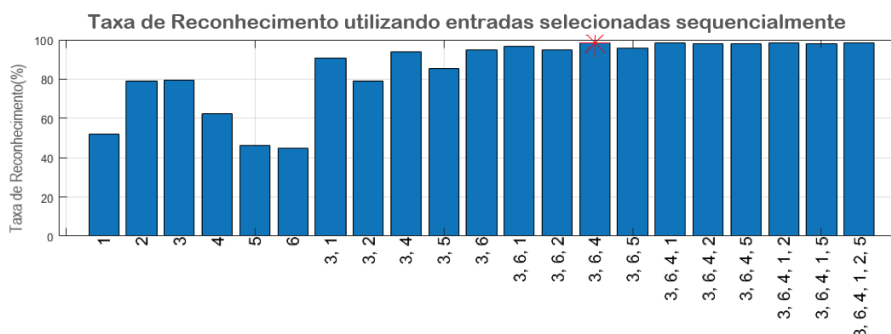


Figura 7. Seleção sequencial de características para obtenção de melhor modelo de reconhecimento.

4.4. Análise de desempenho

Para verificar a qualidade da precisão do classificador utilizado é realizada uma comparação com outros métodos de classificação (Figura 8) aplicados ao *dataset* construído, a citar: NBC (*Naive Bayes Classifier*), QC (*Q-Learning Classification*), SRC (*Sparse Representation Classification*), KNNC (*K-Nearest Neighbors*), GMMC (*Gaussian Mixture Models*), LINC (*Linear Classification*) e SVMC (*Support Vector Machine Classifier*).

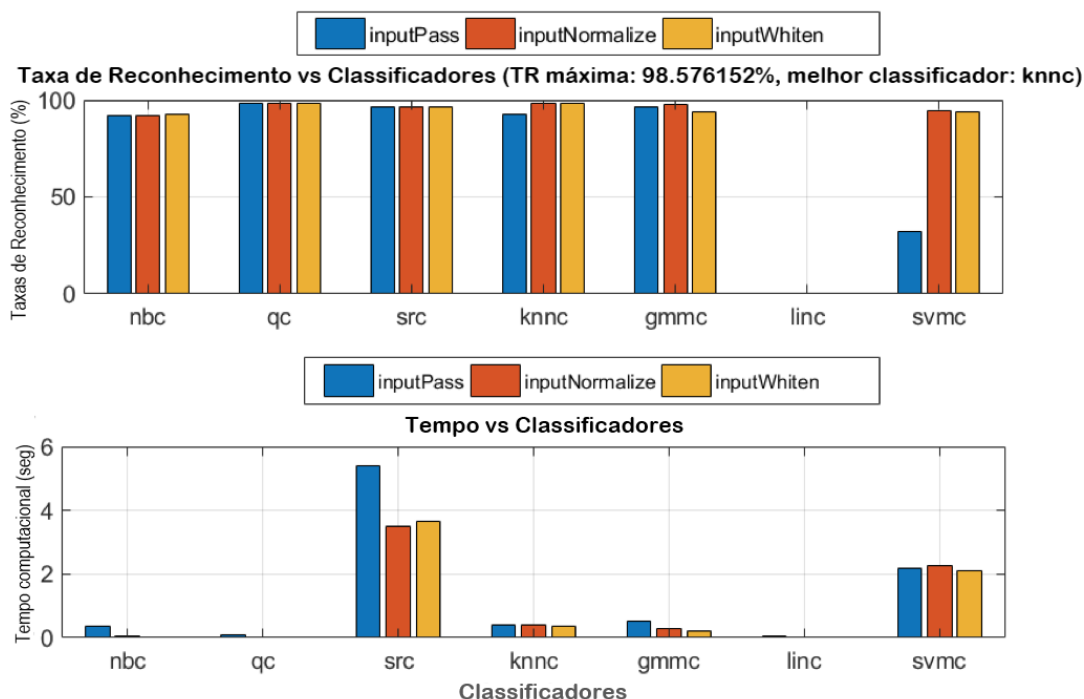


Figura 8. Comparação de taxa de reconhecimento e custo computacional de técnicas de classificação.

Como verificado na Figura 8, a classificação por KNN possui a melhor precisão e está entre os melhores tempos computacionais de execução. Verificado que o KNN é um dos melhores classificadores para utilizar no *dataset* construído, parte-se para verificar se o resultado encontrado está de acordo com a literatura. Para esta questão buscou-se trabalhos na literatura que trabalhavam no mesmo foco de pesquisa. Na Tabela 1 são demonstrados os resultados obtidos neste trabalho assim como nos trabalhos pesquisados, salientando a técnica de classificação utilizada, a precisão encontrada e o tamanho do *dataset* utilizado.

Fonte	Classificador	Precisão	Tamanho do Dataset
Resultado do artigo atual	KNN	98,3%	281
[Satti et al. 2013]	KNN	85,9%	1907
[Satti et al. 2013]	ANN	93,3%	1907
[Castillo et al. 2008]	KNN*	100%	308

Tabela 1. Comparação das precisões alcançadas por trabalhos da área, com classificadores KNN e ANN.

Como observado na Tabela 1, para *datasets* menores a precisão do KNN é bem alta, e para os maiores outras técnicas de classificação ultrapassam a sua eficiência. Além da menor precisão, outro motivo para não utilizar o KNN para grandes quantidades de dados é que o seu tempo computacional cresce muito, tendo em vista que este método realiza a comparação dos dados de teste com todos os dados de treinamento no momento da classificação. No trabalho de [Castillo et al. 2008] houve uma precisão de 100%, pois os autores, na fase de pré-processamento, utilizaram técnicas de pré-processamento e transformação baseados em centralização por média dos dados. Ressaltando que, os dados podem ser corrigidos através de técnicas computacionais de pré-processamento e correção de dados, para otimizar as precisões de classificação do KNN.

5. Conclusões

Este trabalho objetivou a implementação de um classificador baseado em KNN para realizar o reconhecimento de folhas pertencentes a classe de plantas alimentícias não convencionais. Buscando verificar a eficiência da técnica implementada, os resultados de reconhecimento foram comparados com outros classificadores e também com resultados de trabalhos na área.

É importante salientar que um dos pontos fortes deste trabalho foi a utilização de um *dataset* próprio e de plantas regionais, visto que a maioria dos trabalhos utilizam as bases de dados de imagens disponibilizadas livremente. As precisões encontradas nos modelos de reconhecimento foram muito altas, demonstrando que o classificador foi capaz de identificar os dados de treino utilizados. Porém, devido ao pequeno número de imagens diferentes (Algumas das imagens eram fotos de uma mesma folha) a precisão pode não conseguir reconhecer uma grande variedade de folhas das classes definidas. A análise da técnica realizada através da comparação demonstrou que para o *dataset* definido neste trabalho a técnica de KNN era a melhor escolha, adquirindo a melhor precisão em reconhecimento das classes e menor custo computacional. Como trabalhos futuros pretende-se obter um número maior de imagens de folhas e com mais qualidade, além de ampliar as variedades de folhas.

Referências

- Bezerra, M. E. R. and Oliveira, A. L. I. (2006). Métodos baseados na regra do vizinho mais próximo para reconhecimento de imagens.
- Bredariol, L. R. (2015). Levantamento e caracterização das plantas alimentícias não convencionais (panc's) espontâneas presentes em um sistema agroflorestal no município de rio claro-sp.
- Castillo, R., Contreras, D., Freer, J., Ruiz, J., and Valenzuela, S. (2008). Supervised pattern recognition techniques for classification of eucalyptus species from leaves nir spectra. *Journal of the Chilean Chemical Society*, 53(4):1709–1713.
- Duarte, G. d. R. (2018). *Levantamento e caracterização das plantas alimentícias não convencionais do Parque Florestal de Monsanto-Lisboa*. PhD thesis.
- Hoorn, C., Wesselingh, F. P., ter Steege, H., Bermudez, M. A., Mora, A., Sevink, J., Sanmartín, I., Sanchez-Meseguer, A., Anderson, C. L., Figueiredo, J. P., Jaramillo, C., Riff, D., Negri, F. R., Hooghiemstra, H., Lundberg, J., Stadler, T., Särkinen, T.,

- and Antonelli, A. (2010). Amazonia through time: Andean uplift, climate change, landscape evolution, and biodiversity. *Science*, 330(6006):927–931.
- Hossain, J. and Amin, M. A. (2010). Leaf shape identification based plant biometrics. In *2010 13th International conference on computer and information technology (ICCIT)*, pages 458–463. IEEE.
- Kinupp, V. F. and Lorenzi, H. (2014). *Plantas Alimentícias Não Convencionais (PANC) no Brasil: guia de identificação, aspectos nutricionais e receitas ilustradas*. Instituto Plantarum de Estudos da Flora Ltda.
- Kumar, M., Kamble, M., Pawar, S., Patil, P., and Bonde, N. (2011). Survey on techniques for plant leaf classification. *International Journal of Modern Engineering Research*, 1(2):538–544.
- Satti, V., Satya, A., and Sharma, S. (2013). An automatic leaf recognition system for plant identification using machine vision technology. *International journal of engineering science and technology*, 5(4):874.
- Sousa, R. d. S., Guedes, E. B., and Oliveira, M. B. L. (2018). Previsão anual de precipitações em manaus, amazonas: Um comparativo de técnicas de aprendizado de máquina. In *9º Workshop de Computação Aplicada a Gestão do Meio Ambiente e Recursos Naturais (WCAMA_CSBC 2018)*, volume 9. SBC.
- Visentini, G. C., Pavan, W., Holbig, C. A., and Fernandes, J. M. (2018). Aplicativo ios para coleta autônoma de imagens e monitoramento do meio agrícola. In *9º Workshop de Computação Aplicada a Gestão do Meio Ambiente e Recursos Naturais (WCAMA_CSBC 2018)*, volume 9. SBC.