



Aprendizado de máquina aplicado na classificação de diferentes variedades de plantas da espécie *Acer palmatum*

Machine learning applied to the classification of different plant varieties of the species *Acer palmatum*

Patrick de Souza Sagioratto¹, Rúbia Eliza de Oliveira Schultz Ascari²

RESUMO

A identificação de plantas desempenha um papel crucial para a análise de populações e distribuição vegetal, contribuindo com o fornecimento de informações detalhadas sobre as características de cada espécie. Com este contexto em mente, este estudo tem como objetivo desenvolver uma solução de Inteligência Artificial para a classificação automatizada de diferentes variedades de plantas da espécie *Acer palmatum*, com base em imagens digitais. A abordagem propõe o uso de uma base de dados específica para a espécie *Acer palmatum* e a aplicação do algoritmo de aprendizado supervisionado *Support Vector Machine* (SVM). A pesquisa abrange experimentos realizados em três subconjuntos derivados dos dados originais, explorando quatro abordagens para processamento das imagens: originais, com *data augmentation*, extração de cores e extração de formato. Essas análises oferecem perspectivas diversas dos experimentos realizados. Os resultados mais promissores surgiram a partir do conjunto de folhas com fundo branco e a abordagem de extração de cores, resultando em um f1-score de 74%. Este estudo contribui para a automação eficaz da classificação de variedades de uma espécie de planta, com potenciais implicações para a identificação e rastreamento de espécies vegetais.

PALAVRAS-CHAVE: *Acer palmatum*; Classificação de plantas; *Support Vector Machine*.

ABSTRACT

Plant identification plays a crucial role in the analysis of populations and plant distribution, contributing to providing detailed information about each species. With this context in mind, this study aims to develop an Artificial Intelligence solution for the automated classification of plant varieties within the species *Acer palmatum*, based on digital images. The approach involves constructing a specific database for the *Acer palmatum* varieties and the application of the supervised learning algorithm *Support Vector Machine* (SVM). The research encompasses experiments conducted on three subsets derived from the original data, exploring four image processing approaches: original images, data augmentation, color extraction, and shape extraction. These analyses offer diverse perspectives on the experiments conducted. The most promising results emerged from the dataset of leaves with a white background and the color extraction approach, resulting in an f1-score of 74%. This study contributes to the effective automation of classification of varieties of a kind of plant, with potential implications for the identification and tracking of plant species.

KEYWORDS: *Acer palmatum*; Plant Classification; *Support Vector Machine*.

INTRODUÇÃO

Identificação de plantas é uma tarefa importante, pois fornece valiosas informações sobre as características de cada espécie, como seu *habitat*, exigências de cultivo, propriedades medicinais e até mesmo sua toxicidade potencial. A correta identificação da variedade/gênero pode ser útil na busca de informações sobre o manejo correto a ser dado à planta, principalmente por usuários menos especializados.

1 Bolsista da UTFPR. Universidade Tecnológica Federal do Paraná, Pato Branco, Paraná, Brasil. E-mail: patricksagioratto@alunos.utfpr.edu.br. ID Lattes: 5254893435147242.

2 Docente no Departamento Acadêmico de Informática da UTFPR-PB. Universidade Tecnológica Federal do Paraná, Pato Branco, Paraná, Brasil. E-mail: rubia@utfpr.edu.br. ID Lattes: 8086913547704538.



Plantas do gênero *Acer*, comumente conhecidas como bordo, contêm aproximadamente 200 espécies com folhas que variam em tamanho, forma e cor. *Acers* são amplamente distribuídas no hemisfério norte e cultivadas como plantas ornamentais em todo o mundo (JI et al., 1992), além de serem tradicionalmente usadas para tratar um abrangente número de enfermidades no leste da Ásia e América do Norte (BI et al., 2016).

A espécie *Acer palmatum* é original e popular no continente asiático (China, Coreia do Sul e Japão), mas atualmente já é difundida em várias partes do mundo e subdivide-se em diversas variedades, que diferem principalmente no tamanho, aparência e cor das folhas e pecíolos. Dentre as variedades de *Acer palmatum*, existem algumas com características específicas, como o *Acer palmatum Atropurpureum*, que apresenta folhas em tons avermelhados durante todo o ano, ou o *Acer palmatum Deshojo* que apresenta brotações em tom avermelhado e posteriormente as folhas tornam-se esverdeadas. Outras variedades tem brotações de folhas em tonalidade verde, sofrendo variações significativas somente no período de outono. Algumas variedades possuem características muito semelhantes, e essas peculiaridades inerentes a essas plantas motivaram este estudo.

Alguns algoritmos de aprendizado de máquina possuem tarefas em que o objetivo é encontrar uma função ou hipótese a partir de dados de treinamento, para que possa prever um rótulo/valor que caracterize um novo exemplo a partir de seus atributos de entrada. Esses algoritmos seguem o paradigma de aprendizado supervisionado, onde há um supervisor externo que conhece as entradas e devidas saídas, sendo capaz de avaliar a capacidade da hipótese de prever o valor de saída para novos exemplos (FACELI, 2011).

A classificação de variedades de plantas da espécie *Acer palmatum* não é considerada uma tarefa trivial, mesmo para cultivadores experientes, e em função disso, a utilidade do uso de um algoritmo inteligente para realização dessa tarefa é mais evidente, devido à possibilidade de identificar padrões que não são tão facilmente perceptíveis. Assim a proposta deste trabalho é o uso de um algoritmo de aprendizado de máquina para realizar a classificação automática de diferentes variedades de plantas da espécie *Acer palmatum*.

MATERIAIS E MÉTODO

O conjunto de dados utilizado foi o *Japanese Maple Dataset*³, cuja construção é descrita em Ascari et al. (2023). Este conjunto de dados é composto por imagens diversas de plantas do gênero *Acer*. Para este trabalho, foram selecionadas exclusivamente as imagens da espécie *Acer palmatum*.

Este conjunto de dados abrange uma ampla variedade de imagens, incluindo troncos, plantas inteiras, folhas ou combinações desses elementos. Essas imagens têm a possibilidade de apresentar tanto um fundo branco quanto um fundo mais complexo, referidos como fundos não-brancos. Esses fundos podem incluir elementos como luz solar, edificações, objetos ou outras plantas, como demonstrado na Figura 1, onde imagens da variedade *Acer palmatum Atropurpureum* exemplificam cada um desses tipos de imagem.

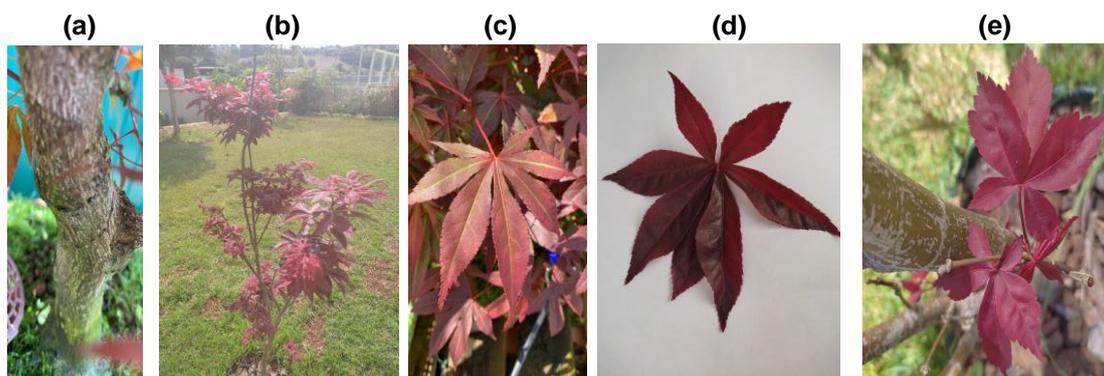
A organização de novos conjuntos de dados a partir do *Japanese Maple Dataset* tem como objetivo criar diferentes ambientes de avaliação para o algoritmo de aprendizado de máquina utilizado. Uma abordagem comumente utilizada para a análise de dados é encontrar relacionamentos entre objetos de dados botânicos, como características das

3 <https://drive.google.com/drive/folders/1jppddFRKKHRItAFs65UScqArKbCdRRbQe?usp=sharing>



folhas, padrões das cores, entre outros. Em seguida, pode-se realizar a análise restante usando esses relacionamentos em vez dos próprios objetos de dados. Essa abordagem visa revelar padrões e informações ocultas nos dados, permitindo diferentes percepções sobre os resultados dos algoritmos de análise (TAN; STEINBACH; KUMAR, 2016).

Figura 1 – Exemplos de imagens de *Acer palmatum Atropurpureum* compostas de (a) tronco, (b) planta inteira, (c) folhas com fundo complexo, (d) folhas com fundo branco, (e) mista



Os diferentes conjuntos de dados gerados possibilitaram a observação do comportamento da extração de características em cada cenário específico. O Quadro 1 descreve a lógica usada na organização dos conjuntos. É relevante ressaltar que o processo adotado em cada conjunto foi idêntico, porém as bases de dados são tratadas de maneira independente, sem qualquer tipo de interconexão entre elas. Em relação a cada conjunto, procedeu-se com aplicações individuais de extrações de características e *data augmentation*, o que permitiu analisar respostas individuais diante das alterações.

Quadro 1 – Conjuntos de dados criados a partir do original

Descrição	Espécies	Imagens
Conjunto 1 Espécies de <i>Acer palmatum</i> que possuem 10 ou mais imagens no <i>Japanese Maple Dataset</i> , considerando imagens com fundo complexo e fundo branco.	13	439
Conjunto 2 Imagens com fundo branco de todas as espécies de <i>Acer palmatum</i> do <i>Japanese Maple Dataset</i> , exceto as consideradas desfocadas ou com folhas muito danificadas.	7	322
Conjunto 3 Todas as imagens de <i>Acer palmatum</i> do <i>Japanese Maple Dataset</i> que passaram pelo procedimento de remoção do <i>background</i> da imagem usando a função <i>rembg</i> ⁴ e não perderam suas características essenciais (forma, textura, margem, etc).	7	266

Fonte: Elaborado pelos autores (2023).

Cada ferramenta empregada na extração das características é aplicada de maneira independente, fazendo uso da base de dados inicial específica para cada abordagem. Os métodos utilizados foram histograma de cores para a extração das cores e *zernike moments*

4 <https://github.com/danielgatis/rembg>



para análise de formato, pertencentes às bibliotecas disponíveis na linguagem de programação Python como o Scikit-learn⁵ e Mahotas⁶, respectivamente.

Data augmentation consiste em criar amostras adicionais a partir de dados existentes. Neste trabalho alguns conjuntos de dados de treinamento foram expandidos com a inclusão de novas amostras, geradas a partir de variações das amostras originais. Transformações geométricas, como rotações, reflexões e cisalhamentos, ajustes de intensidade e mudanças de brilho podem introduzir diferentes perspectivas das imagens e simular variações nas condições de iluminação.

Para realizar a classificação de imagens, é preciso separar o conjunto de dados entre dados de treinamento e teste. Para este estudo, foi empregado o método de validação cruzada K-fold estratificada com K=3 (útil quando o conjunto de dados apresenta distribuição desigual entre as classes). O conjunto de dados é particionado em K subconjuntos (*folds*), dos quais 1 é alocado para treinamento, enquanto o *fold* restante é reservado para validação. Essa operação é repetida K vezes, com cada *fold* servindo como conjunto de validação em uma iteração diferente. Os resultados são combinados para fornecer uma avaliação mais confiável do desempenho do modelo (HASTIE et al., 2009).

A escolha dos melhores classificadores para cada conjunto de validação foi feita utilizando a biblioteca *Hyperopt-sklearn*⁷. Essa abordagem permitiu a seleção automatizada dos melhores hiperparâmetros para cada modelo, os quais foram armazenados para uso posterior. Além da otimização de hiperparâmetros, a etapa de seleção dos melhores classificadores também envolveu a aplicação da técnica de *Soft Voting* da biblioteca Scikit-learn. Essa abordagem consiste em combinar as previsões de vários classificadores individuais de forma ponderada, resultando em uma decisão final mais robusta e geralmente mais precisa. No *Soft Voting*, cada classificador atribui uma pontuação de probabilidade para cada classe de saída, e a classe com a maior pontuação média ponderada é escolhida como a previsão final (GÉRON, 2022).

As avaliações dos modelos de classificação foram conduzidas utilizando um conjunto de métricas fundamentais, incluindo precisão, recall, F1-score. Essas métricas permitem medir a capacidade do modelo de identificar corretamente as instâncias de cada classe, quantificar o equilíbrio entre a taxa de verdadeiros positivos e a taxa de falsos negativos, além de combinar precisão e recall em um único valor. A interpretação conjunta dessas métricas oferece uma compreensão abrangente da eficácia do modelo em termos de assertividade e abrangência.

RESULTADOS

Observando a Tabela 1, percebe-se que a extração do formato e *data augmentation* em imagens sem tratamento não se mostraram eficazes, enquanto os melhores resultados emergiram dos conjuntos que permaneceram sem alterações e que tiveram extração de cores. Essa constatação levanta a possibilidade de uma explicação: a possível escassez de imagens de algumas espécies. Tal situação pode ter influenciado negativamente, pois a limitação de dados pode ter privado o classificador da quantidade necessária para detectar padrões distintivos, potencialmente desencadeando um cenário de *underfitting*.

5 <https://scikit-learn.org/>

6 <https://mahotas.readthedocs.io/en/latest/>

7 <https://hyperopt.github.io/hyperopt-sklearn/>



Tabela 1 – Média ponderada dos resultados referentes ao conjunto 1

	Precisão	Recall	F1-Score
Sem alteração	54%	48%	47%
Com <i>data augmentation</i>	47%	49%	45%
Extração de cores	56%	58%	54%
Extração do formato	33%	40%	31%

Fonte: Elaborado pelos autores (2023).

Em relação aos dados da Tabela 1, foi evidente um aumento na taxa de acertos nos dados apresentados na Tabela 2. Esse aumento pode ser atribuído às condições mais propícias para a classificação das imagens no conjunto 2, as quais não apresentam fundos complexos que poderiam influenciar nas decisões do classificador. Além disso, o conjunto 2 englobou apenas 7 espécies, ou seja, quase metade do número de espécies em relação ao conjunto 1, o que pode ter contribuído para uma classificação mais precisa e eficaz.

Tabela 2 – Média ponderada dos resultados referentes ao conjunto 2

	Precisão	Recall	F1-Score
Sem alteração	76%	68%	65%
Com <i>data augmentation</i>	69%	60%	57%
Extração de cores	75%	78%	74%
Extração do formato	34%	40%	35%

Fonte: Elaborado pelos autores (2023).

Diferentemente dos resultados apresentados na Tabela 2, os dados na Tabela 3 indicam que as imagens sem alteração e com extração de cores não se ajustaram bem à remoção do *background*. Em contraste, os conjuntos que incluíram extração do formato e utilizaram *data augmentation* demonstraram um desempenho mais favorável

Tabela 3 – Média ponderada dos resultados referentes ao conjunto 3

	Precisão	Recall	F1-Score
Sem alteração	48%	57%	48%
Com <i>data augmentation</i>	77%	69%	69%
Extração de cores	65%	67%	61%
Extração do formato	48%	52%	48%

Fonte: Elaborado pelos autores (2023).

Como apresentado em um mapeamento sistemático conduzido por Ascari et al. (2023), não é de conhecimento dos autores deste trabalho a existência de outros estudos com o mesmo objetivo, o que impede a comparação direta com trabalhos relacionados.

CONCLUSÃO

Neste estudo, exploramos diversas abordagens para a classificação automatizada de variedades de plantas *Acer palmatum*, utilizando conjuntos de dados derivados de um original. As diferentes estratégias aplicadas revelaram uma visão abrangente do desempenho de nosso sistema em várias condições.

A construção de uma base de dados específica para a espécie *Acer palmatum* representa um recurso valioso para futuras investigações relacionadas a essa espécie, fornecendo um ponto de partida sólido para estudos de identificação e rastreamento de



plantas. Dentre as abordagens exploradas, destacou-se a extração de cores em imagens de folhas com fundo branco, alcançando um f1-score de 74%. A taxa de acerto não é tão representativa, mas sabemos que a espécie trabalhada apresenta desafios inerentes, principalmente relacionados às características semelhantes dentre muitas variedades. Como trabalhos futuros pretende-se avaliar o uso de outros classificadores, empregando por exemplo Aprendizado Profundo.

Os resultados obtidos demonstram o potencial da Inteligência Artificial na automação da classificação de gêneros de plantas, com amplas aplicações que vão desde a pesquisa botânica até o monitoramento ambiental.

Agradecimentos

Os autores agradecem a UTFPR, CAPES e CNPQ pelo apoio à pesquisa.

Conflito de interesse

Não há conflito de interesse.

REFERÊNCIAS

- ASCARI, R. E. de O. S.; CASANOVA, D.; FÁVERO, E. M. D. B.; SAGIORATTO, P. de S.; BRAUN, V. C. Developing an automatic classifier of different plant genera of the subspecies *Acer Palmatum*. **Anais do Computer on the Beach**, v. 14, p. 166–173, 3 maio 2023. DOI 10.14210/cotb.v14.p166-173. Disponível em: <https://periodicos.univali.br/index.php/acotb/article/view/19429>. Acesso em: 8 set. 2023.
- BI, W.; GAO, Y.; SHEN, J.; HE, C.; LIU, H.; PENG, Y.; ZHANG, C.; XIAO, P. Traditional uses, phytochemistry, and pharmacology of the genus *Acer* (maple): A review. **Journal of Ethnopharmacology**, v. 189, p. 31–60, 2 ago. 2016. DOI 10.1016/j.jep.2016.04.021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378874116302124>. Acesso em: 8 set. 2023.
- FACELI, K.; LORENA, A. C.; GAMA, J.; ALMEIDA, T. A. de; CARVALHO, A. C. P. de L. F. de. **Inteligência artificial: uma abordagem de aprendizado de máquina**. 1. ed. [S. l.]: LTC, 2021.
- GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow**. 3. ed. [S. l.]: O'Reilly Media, Inc., 2022.
- JI, S.-B.; YOKOI, M.; SAITO, N.; MAO, L.-S. Distribution of anthocyanins in aceraceae leaves. **Biochemical Systematics and Ecology**, v. 20, n. 8, p. 771–781, 1 dez. 1992. DOI 10.1016/0305-1978(92)90036-D. Disponível em: <https://www.sciencedirect.com/science/article/pii/030519789290036D>. Acesso em: 8 set. 2023.
- TAN, P.-N.; MICHAEL, S.; VIPIN, K. **Introduction to Data Mining**. 1. ed. [S. l.]: PEARSON INDIA, 2016.