

# Classificação de Folhas Nativas do Cerrado Usando Aprendizizado de Máquina

Edilaine Gonçalves Costa de Faria, Deborah Bambil,  
Daniel Chaves Café e Francisco Assis de Oliveira Nascimento

**Resumo**— Este trabalho compara 8 algoritmos de aprendizado de máquina em função da sua acurácia média de classificação de 30 espécies de plantas. O sistema de classificação utiliza fotos de folhas como entrada para o sistema de classificação. Os resultados evidenciam que o algoritmo Análise de Discriminante Linear se mostrou o mais apropriado para este problema específico, chegando a 98,46% de acurácia média.

**Palavras-Chave**— Aprendizagem de máquina, Classificadores de folhas, Cerrado.

**Abstract**— This work compares 8 machine learning algorithms in terms of their average accuracy in classifying 30 plant species. The classification system uses leaf photos as input to the classification system. The results show that the Linear Discriminant Analysis algorithm proved to be the most appropriate for this specific problem, reaching an average accuracy of 98.46%.

**Keywords**— Machine learning, Leaf classifiers, Cerrado.

## I. INTRODUÇÃO

O Brasil é um país de dimensões continentais. Nele encontramos diversos tipos de clima e de solo, o que confere diferentes condições ambientais. Como resultado também se tem uma megadiversidade biológica. Essa megadiversidade de espécies da flora e da fauna podem ser traduzida nos diferentes ecossistemas e faixas de transição ou fronteiras zonais com espécies exclusivas dessas zonas [1]. Podemos citar, pelo menos, nove importantes ecossistemas brasileiros denominados: Amazônia, Caatinga, Cerrado, Mata Atlântica, Mata dos Cocais, Pantanal, Mata de Araucárias, Mangue e Pampas. Com uma pequena observação panorâmica do país pode-se delinear um grande patrimônio natural que precisa ser explorado de forma racional e, mais ainda, deve ser preservado.

Em especial o mundo inteiro volta os olhares para a Amazônia que se constitui na maior área remanescente de florestas tropicais do mundo. Ela ocupa aproximadamente metade do território brasileiro. Os biomas brasileiros são ricos em uma grande variedade de plantas e, dentre elas, muitas têm aplicações medicinais. É de interesse identificar as espécies de plantas e as suas respectivas distribuições regionais.

A identificação da espécie a partir de suas folhas é possível. Contudo, é uma atividade que requer um indivíduo qualificado para tal. Essa é uma atividade manual, trabalhosa e demorada.

Edilaine Gonçalves Costa de Faria, Departamento de Engenharia Elétrica, Universidade de Brasília (UnB), Brasília-DF, email: edilaine@ieee.org; Deborah Bambil, Departamento de Sistemas e Computação, Universidade Regional de Blumenau (FURB), Blumenau-SC, e-mail: deborahbambil@gmail.com; Daniel Chaves Café, Departamento de Engenharia Elétrica, Universidade de Brasília (UnB), Brasília-DF, email: dccafe@gmail.com; Francisco Assis de Oliveira Nascimento, Departamento de Engenharia Elétrica, Universidade de Brasília (UnB), Brasília-DF, email: assis@unb.br.

Pode-se usar o conhecimento tecnológico de forma a conceber uma ferramenta de apoio a biólogos e a botânicos. Foi nesta linha de raciocínio que nos apegamos para o desenvolvimento deste trabalho. A partir da construção de um banco de dados de imagens (fotografias) das folhas de espécies brasileiras procuramos desenvolver ferramentas de aprendizado de máquina para classificar as espécies. A ideia original consiste em se construir uma ferramenta computacional para a classificação das espécies.

É relevante realizar estudos relacionados à detecção de diferentes espécies de plantas. A identificação e classificação de espécies de plantas vêm sendo realizadas desde Teofrasto, em aproximadamente 300 a.C. [2]. Atualmente, este trabalho é comumente realizado por biólogos e botânicos.

A identificação de plantas, além de ser útil para biólogos e botânicos, é também importante para o estudo da química, genética, medicina, microbiologia, farmacologia e farmácia [3], já que se faz necessário conhecer as espécies de plantas que possuem uso medicinal e alimentício nessas disciplinas. Outro uso de identificação e classificação de plantas é de detectar espécies que possuem substâncias tóxicas que podem causar algum tipo de prejuízo [4].

Diante disso, o problema investigado neste artigo consiste em detectar diferentes espécies de folhas de forma automática. Isso é importante, pois dentre diferentes espécies que possuem aparências semelhantes e que podem ter inclusive funções extremamente diferentes, como por exemplo, uma ser venenosa e outra ser de aplicação medicinal. Este trabalho consiste portanto em uma ferramenta computacional para classificação automática das espécies e de auxílio a, sobretudo, botânicos e biólogos.

Este trabalho é constituído de cinco seções. A seção II apresenta trabalhos correlatos. Na seção III é apresentada a descrição da construção do banco de dados, da ferramenta de extração de atributos e de uma visão panorâmica dos classificadores utilizados. Na seção IV são apresentados os resultados obtidos para os vários classificadores utilizados. Os objetivos e resultados são revisitados na seção V. Os resultados são discutidos para tirada de conclusões e são listados possíveis trabalhos futuros.

## II. REVISÃO BIBLIOGRÁFICA

Na literatura são reportados alguns trabalhos que buscaram a mesma abordagem de implementação de algoritmos em diversos contextos, distintos da aplicação em classificação de folhas. Implementações com redes neurais convolucionais (CNN) usam a imagem representada por seus pixels como

TABELA I  
ALGORITMOS DE CLASSIFICAÇÃO.

Algoritmo	Referência
Análise de Discriminante Linear (ADL)	[14]
Árvores de Decisão (AD)	[15]
Extra-Trees (ET)	[16]
Gradient Boosting (GB)	[17]
Histogram-based Gradient Boosting (HGB)	[18]
K-Vizinhos mais Próximos (KVP)	[19]
Naive-Bayes (NB)	[20]
Regressão Logística (RL)	[21]

entrada [5], [6], [7], [8]. As CNNs apresentam bom desempenho com acurácia acima de 99%, resultado obtido em outro conjunto de dados, o qual consiste em um estudo de detecção automática em um sistema de visão para avaliação da qualidade da limpeza robótica de plantas de processamento de pescado [9].

Na literatura, foram encontrados métodos classificadores de imagens de folhas usando máquinas de vetores de suporte (SVM). H. Kan et al. fizeram a classificação de plantas medicinais com base na extração de várias características das próprias folhas [10]. P. L. Filho et al. usaram imagens macroscópicas para o reconhecimento de espécies florestais [11]. Mônica G. Laresse et al. fizeram a classificação automática de leguminosas usando recursos de imagem de nervuras foliares [12].

D. Bambil et al. utilizaram características morfológicas, tais como cor, formato e textura em técnicas de aprendizado de máquina [13]. O mesmo banco de dados do trabalho de D. Bambil será utilizado aqui para explorar o desempenho de outros classificadores.

No presente estudo, investigou-se técnicas de classificação baseada em inferência Bayesiana e em inferência frequencista. Ambas consistem em diferentes tipo de estatística inferencial. Na abordagem deste trabalho é necessário se extrair um conjunto de atributos da imagem que é utilizado como entrada do processo de aprendizagem. A tabela I lista as diversas técnicas de aprendizado de máquina utilizadas neste trabalho.

### III. METODOLOGIA

#### Área de estudo e coleta de imagens

Um banco de dados de imagens de espécies nativas do cerrado foi construído a partir de fotografias tiradas de lâminas foliares, coletadas na Reserva Particular de Patrimônio Natural (20°27'S, 54°37'W) no município de Campo Grande, MS – Brasil. Foram coletadas 40 amostras de folhas de 30 espécies de plantas. As lâminas foliares foram fotografadas em ambas as faces, adaxial e abaxial, com aparelho celular modelo lumia 820, câmera de 8 mega pixels, instalado em suporte com ângulo de 90° a 20 cm de distância das folhas, com fundo branco usando flash do próprio aparelho. A resolução da imagem foi fixada em 2000 x 3552 pixels.

A Figura 1 apresenta duas folhas de espécies distintas do banco de dados utilizado. Sendo que a da esquerda é da espécie *Annona cassiflora* e a figura da direita corresponde a espécie *Annona coriacea*.



Fig. 1. Exemplos de folhas de diferentes espécies de plantas utilizadas neste trabalho. *Annona cassiflora* na esquerda e *Annona coriacea* na direita.

#### Extração de Atributos das imagens

No processo de extração dos atributos foram computadas 460 grandezas estatísticas e parâmetros de forma a evidenciar as assinaturas espectrais locais e/ou globais associadas às bandas de cores, à forma, à dimensão e à textura [13]. Para o espaço de representação de cores, foram computados os momentos de primeira até quarta ordem para formatos RGB (*Red-Green-Blue*), HSV (*Hue-Saturation-Value*) e CIELab (espaço de cores definido pela *The International Commission on Illumination – CIE*). A partir da imagem convertida para o formato de níveis de cinza, também são calculados os atributos decorrentes de características locais ou globais, de textura, de forma, de dimensão e estatísticas.

Para as imagens representadas em níveis de cinza foram computados a histogramação de amplitude, os momentos (centrais e invariantes), os descritores direcionais e os descritores de informação distribuída em sub-bandas no domínio das frequências. Para este caso, calcularam-se 7 (sete) momentos centrais denominados “momentos invariantes a transformações – Hu” [22]. Momentos invariantes têm sido amplamente aplicados ao reconhecimento de padrões em imagens em uma variedade de aplicações devido às suas características invariantes na translação, escalonamento e rotação da imagem [22]. A estes foram adicionados os atributos computados a partir dos histogramas de gradiente orientados [23].

Histograma de gradientes orientados, também conhecido como HOG (*Histograms of Oriented Gradient*), é um algoritmo usado em visão computacional e processamento de imagens para fins de detecção de objetos. A técnica conta as ocorrências de orientação de gradiente em uma determinada região de uma imagem (célula).

Também foram computados os descritores locais como os de Haralick [24], os momentos de Zernike [25], os atributos derivados do padrão binário local (LBP - *Local Binary Patterns*) e os atributos derivados padrão direcional local (LDP - *Local Directional Patterns*). Os descritores de textura de Haralick são calculados a partir de uma matriz que conta a ocorrência de níveis de cinza vizinhos na imagem (GLCM - *Gray Level Co-occurrence Matrix*). Semelhante aos momentos invariantes Hu, os momentos Zernike também podem ser usados para descrever a forma de um objeto, entretanto, como os polinômios de Zernike são ortogonais entre si, não há redundância de informações entre os momentos.

O LBP se caracteriza por ser um operador de textura que rotula os pixels de uma imagem limitando o processo a uma vizinhança de cada pixel. O resultado é codificado como um

TABELA II  
ESPÉCIES DE FOLHAS UTILIZADAS NOS ALGORITMOS.

Classe	Espécie de folha
1	<i>Xylopia aromatica</i>
2	<i>Terminalia argentea</i>
3	<i>Tabebuia aurea</i>
4	<i>Stryphnodendron obovatum</i>
5	<i>Salvertia convallariodora</i>
6	<i>Rhamnidium elaeocarpum</i>
7	<i>Qualea multiflora</i>
8	<i>Qualea grandiflora</i>
9	<i>Pseudobombax sp</i>
10	<i>Miconia albicans</i>
11	<i>Matayba guianensis</i>
12	<i>Licania humilis</i>
13	<i>Lafoensia pacari</i>
14	<i>Eugenia sp</i>
15	<i>Eriotheca pubescens</i>
16	<i>Diptychandra aurantiaca</i>
17	<i>Dimorphandra mollis</i>
18	<i>Curatella americana</i>
19	<i>Copaifera langsdorffii</i>
20	<i>Connarus suberosus</i>
21	<i>Chrysophyllum marginatum</i>
22	<i>Caryocar brasiliense</i>
23	<i>Byrsonima verbascifolia</i>
24	<i>Byrsonima coccolobifolia</i>
25	<i>Bowdichia virgilioides</i>
26	<i>Astronium fraxinifolium</i>
27	<i>Annona crassiflora</i>
28	<i>Annona coriacea</i>
29	<i>Andira cujabensis</i>
30	<i>Agonandra brasiliensis</i>

número binário [26]. O LDP que tem sido usado com sucesso em identificação de faces [27], usa a mudança da magnitude do gradiente em uma direção específica ao redor dos pixels para codificar a textura local. Em vez de comparar o valor da intensidade de pixels vizinhos, esse método compara a magnitude do gradiente do pixel vizinho ao longo de uma direção específica e a codifica como um LBP trivial.

Finalmente, foi proposto se extrair o comportamento de cada imagem no domínio das frequências por meio da DFT-2D (*Two-dimensional Discrete Fourier Transform*). O espectro de energia é segmentado em um conjunto de sub-bandas. A energia normalizada computada em cada sub-banda é utilizada como atributo descritor global da imagem. Nos resultados apresentados foram utilizadas 8 sub-bandas com larguras iguais em frequência. Todos os atributos extraídos são concatenados para cada imagem, formando uma sequência de números que vai fazer parte de uma matriz de atributos. Cada imagem processada produz uma nova linha nesta matriz. A quantidade de colunas desta matriz corresponde a quantidade de atributos extraídos por imagem. Depois de se processar todo o banco de imagens, a matriz de atributos é salva e deve constituir a entrada dos algoritmos de aprendizado.

A Tabela II apresenta as diferentes espécies de plantas utilizadas neste trabalho conforme a ordem e numeração utilizadas nos sistemas classificadores.

#### Algoritmo de Classificação

A Tabela I apresenta os algoritmos de classificação utilizados neste trabalho. Uma varredura aleatória foi aplicada

TABELA III  
ACURÁCIA DOS CLASSIFICADORES.

Classificador	Acurácia Média [%]
RL	95,48
ADL	98,46
KVP	78,73
AD	88,90
NB	87,27
ET	75,94
GB	94,79
HGB	97,23

para o conjunto de dados de treinamento de entrada. Seus desempenhos são comparados na seção IV.

O arquivo de características do conjunto de dados original tem 1200 instâncias e 30 classes. O procedimento de treinamento e de avaliação da acurácia do modelo foi repetido 10 vezes. Em cada iteração foi selecionado randomicamente um conjunto de dados para treinamento e um conjunto de dados para avaliação de desempenho. Um conjunto de 80% do banco de dados foi utilizado para treinamento, o que resulta em 960 exemplos. Apenas 20% ou 240 instâncias foram usadas para teste. Os resultados apresentados correspondem à média dos desempenhos obtidos.

#### Métrica de desempenho

Para verificar o desempenho dos algoritmos foi utilizada a acurácia média como métrica. Ela consiste na média das acurácias de cada loop durante o processo de treinamento e validação.

A acurácia em sistema de mais de duas classes, o caso deste trabalho, é definida pela Equação 1.

$$A = \frac{\sum_{k=1}^N V_P[k]}{\sum_{k=1}^N V_P[k] + F_P[k]}, \quad (1)$$

sendo  $V_P$  correspondente a verdadeiro positivo,  $F_P$  a falso positivo e  $k$  corresponde a cada classe.

## IV. RESULTADOS

A Tabela III apresenta os valores de acurácia média obtida por cada algoritmo de classificação indicado na Tabela I.

Na Tabela III, observa-se que a acurácia média variou entre 75,94% a 98,46%. O algoritmo classificador com os maiores resultados de acurácia média foi o ADL. E o algoritmo com menor resultado de acurácia média foi ET. Além disso, observa-se que os três maiores resultados de acurácia média foram ADL, HGB e RL, com os valores de acurácia 98,46%, 97,23% e 95,48%, respectivamente. Os três menores valores de acurácia média foram do ET, KVP, e NB, com os valores de acurácia de 75,94%, 78,73% e 87,27%, respectivamente.

A Tabela IV apresenta os resultados de desempenho (quantidade de verdadeiro positivos dividido pelo total da classe) para cada classe em (%). Nas linhas estão as classes utilizadas nos classificadores segundo as diferentes espécies de folhas mostradas na Tabela II e nas colunas estão cada algoritmo

TABELA IV  
DESEMPENHO DOS ALGORITMOS POR CLASSE (ESPÉCIE DE PLANTA) EM %.

Classes	Algoritmos implementados							
	Acurácia (%)							
	RL	ADL	KVP	AD	NB	ET	GB	HGB
1	<b>100,0</b>	<b>100,0</b>	91,93	91,30	98,76	74,53	96,27	<b>100,0</b>
2	92,12	<b>100,0</b>	61,82	71,52	86,06	62,42	95,15	96,36
3	95,57	<b>99,37</b>	96,84	86,08	89,24	81,65	96,20	96,20
4	87,5	<b>98,12</b>	60,0	83,75	61,87	71,25	93,12	96,25
5	<b>100,0</b>	<b>100,0</b>	80,29	90,51	94,89	74,45	94,89	96,35
6	94,87	97,36	85,26	89,74	94,87	73,08	94,87	<b>97,44</b>
7	96,23	<b>100,0</b>	76,73	87,42	81,76	71,07	94,97	95,6
8	93,84	<b>97,26</b>	90,41	<b>97,26</b>	95,89	86,99	94,52	95,89
9	<b>98,20</b>	<b>98,20</b>	96,41	95,21	<b>98,20</b>	93,41	96,41	<b>98,20</b>
10	<b>100,0</b>	<b>100,0</b>	89,70	96,36	98,79	83,64	98,18	<b>100,0</b>
11	93,79	94,41	85,71	90,68	83,23	70,19	95,65	<b>96,89</b>
12	<b>100,0</b>	<b>100,0</b>	94,87	99,36	94,23	80,77	98,72	<b>100,0</b>
13	<b>100,0</b>	<b>100,0</b>	<b>100,0</b>	96,95	96,34	97,56	<b>100,0</b>	<b>100,0</b>
14	94,90	<b>96,18</b>	69,43	79,62	64,33	70,70	91,72	94,27
15	96,11	<b>100,0</b>	33,89	89,44	77,78	68,89	93,33	95,56
16	86,34	<b>96,89</b>	63,98	83,85	95,65	68,94	93,79	95,03
17	94,33	<b>99,29</b>	69,50	90,78	95,04	72,34	95,74	97,87
18	<b>100,0</b>	95,54	86,62	97,45	88,54	85,99	99,36	99,36
19	94,87	<b>95,51</b>	64,10	80,13	55,77	62,18	91,03	95,51
20	94,16	<b>98,70</b>	64,29	84,42	62,99	44,16	91,56	96,1
21	<b>100,0</b>	<b>100,0</b>	96,13	96,13	97,24	93,92	96,69	97,24
22	96,86	<b>99,37</b>	93,71	96,86	97,48	92,45	97,48	98,74
23	90,91	<b>96,97</b>	76,97	88,48	83,64	75,76	93,33	96,36
24	96,72	<b>100,0</b>	89,62	90,16	93,99	86,89	91,26	96,17
25	91,93	93,17	72,05	86,96	90,06	77,02	94,41	<b>96,27</b>
26	95,39	<b>98,68</b>	63,16	77,63	71,05	68,42	86,84	96,05
27	<b>99,37</b>	96,86	88,05	84,28	94,34	70,44	91,82	96,23
28	94,33	<b>100,0</b>	58,16	91,49	90,78	69,50	99,29	<b>100,0</b>
29	90,80	<b>100,0</b>	74,71	94,83	90,23	68,97	94,25	98,85
30	95,12	<b>99,39</b>	85,37	77,44	93,29	75,0	93,29	98,17

classificador utilizado de acordo com a ordem apresentada na Tabela I. A quantidade de instâncias de todos os algoritmos apresentados na Tabela IV foram iguais. Analisando cada classe dos algoritmos, com exceção da classe 15, 21, 24 e 29 que tiveram 4% na quantidade de instâncias, as demais tiveram 3%.

Além disso, verifica-se na Tabela IV que a classe 13 obteve melhores resultados de acurácia, chegando a 100% na maioria dos algoritmos utilizados. Essa classe corresponde a espécie *Lafoensia pacari*, conforme Tabela II. Supõe-se que os resultados elevados dessa classe ocorreram, pois as folhas adquiridas no banco de dados possuem tamanhos e formatos parecidos. Além disso, a classe 20, que corresponde a espécie *Connarus suberosus*, obteve bastante variação entre os classificadores, supõe-se que isso ocorreu, pois as imagens obtidas possuem tonalidades diferentes, o que pode ter dificultado o desempenho de alguns classificadores. E a classe 15, espécie *Eriotheca pubescens*, obteve o menor valor no KVP dentre as diferentes classes, pois os formatos e as tonalidades

diferentes das folhas podem ter dificultado o método de ajuste do algoritmo.

## V. CONCLUSÃO

Este estudo dá continuidade ao estudo de D. Bambil [13]. Foram avaliadas diferentes técnicas de classificação de espécies de folhas de plantas nativas do cerrado brasileiro, utilizando outros algoritmos de classificação, tais como, RL, ADL, KVP, AD, NB, ET, GB e HGB, conforme apresentado na Tabela I.

Analisando a Tabela III observa-se que os valores de acurácia média mostram um alto desempenho dos algoritmos dos sistemas classificadores, com valores que alcançaram até 98,46%. com o algoritmo de ADL, desta forma pode ser verificado que métodos lineares podem ser priorizados em escolhas de aplicações deste tipo.

Além disso, analisando a Tabela IV é possível verificar também que o ADL foi o algoritmo que obteve mais classes

com os maiores resultados de acurácia dentre os diferentes algoritmos.

Diante disso, observa-se que os resultados obtidos por alguns classificadores, tais como, KVP, AD, *Naive-Bayes* e ET (Tabela III) tiveram alguns resultados menores do que os resultados obtidos na literatura que analisou as mesmas espécies de plantas, em que as acurácias obtidas estiveram no intervalo entre 93,5% a 98,4% [13].

Nesse trabalho, foram investigadas diversas técnicas para a classificação de distintas espécies de folhas. Para isso foram escolhidos os seguintes algoritmos: RL, ADL, KVP, AD, NB, ET, GB e HGB. O estudo realizado neste trabalho mostrou que as técnicas utilizadas, sobretudo, ADL, HGB e RL adequaram-se bem ao problema estudado. Portanto, observou-se que os desempenhos dos algoritmos utilizados foram promissores e compatíveis com os resultados obtidos na literatura. Apesar disso, uma das limitações desse trabalho é a escolha do melhor classificador, pois apesar do algoritmo ADL obter maior acurácia média, em algumas classes outros algoritmos obtiveram melhores resultados. Diante disso, como trabalho futuro, propõe-se melhorar o desempenho de cada classe, verificando, por exemplo, os pesos da rede neural para guiar a escolha do melhor classificador. E também otimizar a plataforma multi algorítmica para aumentar os resultados de acurácia. Além disso, é relevante estender este estudo a aplicações de espécies de folhas de plantas em outros países com intuito de desenvolver uma ferramenta de auxílio a detecção de plantas no cenário mundial.

## REFERÊNCIAS

- [1] *Plantas Medicinais e Aromáticas do Brasil*, Ministério da Agricultura, Pecuária e Abastecimento – MAPA, Empresa Brasileira de Pesquisa Agropecuária – Embrapa, Embrapa Recursos Genéticos e Biotecnologia, <http://www.cenargen.embrapa.br>, 2010.
- [2] G. M. Barroso, “Sistemática de angiospermas do Brasil.” In *Viçosa: Universidade Federal de Viçosa*, pp. 88–94, 1986.
- [3] B. C. Bennett and M. J. Balick, “Does the name really matter? the importance of botanical nomenclature and plant taxonomy in biomedical research,” *Journal of Ethnopharmacology*, vol. 152, no. 3, pp. 387–392, 2014. [Online]. Available: <http://dx.doi.org/10.1016/j.jep.2013.11.042>
- [4] D. R. Bambil, H. Pistori, F. Bao, and I. M. Bortolotto, “Banco de imagens de lâminas foliares de espécies do Cerrado: técnicas de extração e classificação de imagens por visão computacional. Dissertação (Mestrado em Biologia Vegetal),” *Universidade Federal de Mato Grosso do Sul*, 2017.
- [5] V. Ganchenko and A. Doudkin, “Agricultural Vegetation Monitoring Based on Aerial Data Using Convolutional Neural Networks,” *Optical Memory and Neural Networks*, vol. 28, no. 2, pp. 129–134, April 2019.
- [6] D. Morris, “A Pyramid CNN for Dense-Leaves Segmentation,” in *2018 15th Conference on Computer and Robot Vision (CRV)*. IEEE, 2018, pp. 238–245.
- [7] L. Zhang, C. Xia, D. Xiao, P. Weckler, Y. Lan, and J. M. Lee, “A coarse-to-fine leaf detection approach based on leaf skeleton identification and joint segmentation,” *Biosystems Engineering*, vol. 206, pp. 94–108, 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1537511021000787>
- [8] I. Zingman, N. Zippel, G. Birk, S. Eder, L. Thomas, T. Schönberger, B. Stierstorfer, and F. Heinemann, “Deep Learning-Based Detection of Endothelial Tip Cells in the Oxygen-Induced Retinopathy Model,” *Toxicologic Pathology*, vol. 49, no. 4, pp. 862–871, 2021, pMID: 33896293. [Online]. Available: <https://doi.org/10.1177/0192623320972964>
- [9] E. Bjørlykhaug and O. Egeland, “Vision System for Quality Assessment of Robotic Cleaning of Fish Processing Plants Using CNN,” *IEEE Access*, vol. 7, pp. 71 675–71 685, 2019.
- [10] H. Kan, L. Jin, and F. Zho, “Classification of medicinal plant leaf image based on multi-feature extraction,” *Pattern Recognition and Image Analysis*, vol. 27, pp. 581–587, 2017.
- [11] P. L. Filho, L. S. Oliveira, S. Nisgoski, and A. S. Britto, “Forest species recognition using macroscopic images,” *Machine Vision and Applications*, vol. 25, no. 4, p. 1019–1031, 2014.
- [12] M. G. Larese, R. Namías, R. M. Craviotto, M. R. Arango, C. Gallo, and P. M. Granitto, “Automatic classification of legumes using leaf vein image features,” *Pattern Recognition*, vol. 47, no. 1, pp. 158–168, 2014. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0031320313002641>
- [13] D. Bambil, H. Pistori, F. Bao, V. Weber, F. M. Alves, E. G. G. ..., and I. M. Bortolotto, “Plant species identification using color learning resources, shape, texture, through machine learning and artificial neural networks,” *Environment Systems and Decisions*, vol. 40, no. 4, pp. 480–484, 2020.
- [14] F. J. Hastie T., Tibshirani R., *The Elements of Statistical Learning*, 2008, section 4.3.
- [15] L. Breiman, J. Friedman, R. Olshen, and C. Stone, “Classification and Regression Trees,” *Wadsworth, Belmont, CA*, 1984.
- [16] Breiman, “Arcing Classifiers,” *Annals of Statistics* 1998, 1998.
- [17] S. M. Piryonesi, T. E. El-Diraby, and ., “Data Analytics in Asset Management: Cost-Effective Prediction of the Pavement Condition Index,” *Journal of Infrastructure Systems*, vol. 26, no. 1, 2020.
- [18] J. H. Friedman, “Stochastic gradient boosting,” *Computational Statistics Data Analysis*, vol. 38, no. 4, pp. 367–378, 2002, nonlinear Methods and Data Mining. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0167947301000652>
- [19] E. Fix and J. L. Hodges, “Discriminatory Analysis. Nonparametric Discrimination: Consistency Properties,” *USAF School of Aviation Medicine*, 1951, (Report), Randolph Field, Texas.
- [20] A. McCallum, “Graphical Models, Lecture2: Bayesian Network Representation,” 2019, retrieved 22 October 2019.
- [21] C. M. Bishop, *Pattern Recognition and Machine Learning*, 2006, chapter 4.3.4.
- [22] Z. Huang and J. Leng, “Analysis of Hu’s moment invariants on image scaling and rotation,” in *2010 2nd International Conference on Computer Engineering and Technology*, vol. 7, 2010, pp. V7–476–V7–480.
- [23] N. Dalal and B. Triggs, “Object Detection using Histograms of Oriented Gradients,” *Pascal VOC 2006 Workshop, ECCV 2006, Graz, Austria*, pp. 1–6, 2006.
- [24] T. Löfstedt, P. Brynolfsson, T. Askund, T. Nyholm, and A. Garpebring, “Gray-level invariant haralick texture features,” *PLOS ONE*, vol. 14, no. 2, pp. 1–18, 02 2019. [Online]. Available: <https://doi.org/10.1371/journal.pone.0212110>
- [25] A. Górnaiak and E. Skubalska-Rafajłowicz, “Object classification using sequences of zernike moments,” in *Computer Information Systems and Industrial Management*, K. Saeed, W. Homenda, and R. Chaki, Eds. Cham: Springer International Publishing, 2017, pp. 99–109.
- [26] L. Liu, J. Chen, P. Fieguth, G. Zhao, R. Chellappa, and M. Pietikäinen, “From BoW to CNN: Two Decades of Texture Representation for Texture Classification,” *International Journal of Computer Vision*, vol. 127, no. 1, pp. 74–109, 2019.
- [27] S. P. Ramalingam and C. M. P.V.S.S.R., “Dimensionality reduced local directional pattern (dr-ldp) for face recognition,” *Expert Systems with Applications*, vol. 63, pp. 66–73, 2016.