

Reconhecimento de Plantas Medicinais através de Características das Folhas e Aprendizagem de Máquina

Luciano D. S. Pacifico¹, Larissa F. S. Britto¹, Teresa B. Ludermir²

¹Departamento de Computação (DC) – Universidade Federal Rural de Pernambuco (UFRPE) – Recife – PE – Brazil

²Centro de Informática (CIn) – Universidade Federal de Pernambuco (UFPE) – Recife - PE - Brazil

{luciano.pacifico,larissa.felicianana}@ufrpe.br,tbl@cin.ufpe.br

Abstract. *In this work, we tackle the problem of automatic plant recognition by means of Machine Learning and Computer Vision techniques. We focus on the case of Medicinal Plants, given their potential as natural medicines to prevent and treat human diseases, with lower costs and less side effects (when properly used) than standard medicines. We develop a plant recognition system and a new dataset, based on the extraction of texture and shape features from plant leaf images. Experimental results showed accuracy rates about 98% on the proposed dataset for the best selected classifiers.*

Resumo. *Neste trabalho, o problema do reconhecimento automático de espécies de plantas é atacado através de técnicas de Aprendizagem de Máquina e Visão Computacional. O foco é dado para o caso específico das Plantas Medicinais, dado o potencial das mesmas como remédios naturais que previnem e tratam doenças em humanos, com baixo custo e menos efeitos colaterais (quando usadas apropriadamente) que remédios industrializados. Um sistema de reconhecimento de plantas e uma base de dados são desenvolvidos, baseados em características de textura e forma das folhas. Resultados experimentais indicam uma taxa de acurácia de aproximadamente 98% na base de dados proposta para os melhores classificadores selecionados.*

1. Introdução

As plantas são organismos indispensáveis para seus ecossistemas, provendo recursos insubstituíveis para os animais, como oxigênio e alimentos. Algumas espécies de plantas possuem também papel importante na medicina, servindo tanto como substratos para a indústria farmacéutica, ou sendo elas mesmas usadas como remédios e tratamentos médicos. Plantas usadas no tratamento ou prevenção de doenças e enfermidades são conhecidas como **plantas medicinais** [Sabu et al. 2017].

Embora as plantas estejam em todos os lugares, a identificação correta das espécies de plantas permanece sendo um grande desafio, tradicionalmente requerendo a consulta aos especialistas em botânica. Porém, especialistas nem sempre são facilmente encontrados, principalmente levando-se em consideração que um especialista em um tipo de família de plantas não é necessariamente treinado para reconhecer outras espécies. Além disso, o processo de identificação manual de amostras de plantas é bastante demorado e passível a erros humanos.

No intuito de evitar tais problemas, sistemas automáticos de categorização de plantas têm sido propostos na literatura nos últimos anos [Agarwal et al. 2006, Kumar et al. 2012, Mallah et al. 2013, Jin et al. 2015, Jose et al. 2018, Adinugroho and Sari 2018], fazendo tais sistemas uso de técnicas sofisticadas de áreas como a Aprendizagem de Máquina e Visão Computacional.

Os sistemas automáticos de reconhecimento de plantas possuem três módulos básicos: a aquisição das imagens, a extração de características e a etapa de reconhecimento (classificação) das espécies [Sahay and Chen 2016]. A aquisição das imagens é geralmente realizada sob ambientes controlados (como em [Kumar et al. 2012, Mallah et al. 2013, Sahay and Chen 2016]) ou em ambientes naturais, como em [Cerutti et al. 2013, Sun et al. 2017]. Grande parte dos sistemas de reconhecimento de plantas focam na extração de características relacionadas às folhas das mesmas, como forma, textura, venação, dentre outras [Cope et al. 2012, Jin et al. 2015, Sabu and Sreekumar 2017, Sabu et al. 2017, Britto et al. 2019, Pacifico et al. 2019]. Por fim, vários algoritmos da literatura de Aprendizagem de Máquina têm sido aplicados ao reconhecimento de plantas: Árvores de Decisão [Rahmani et al. 2015], K-Vizinhos Mais Próximos [Mallah et al. 2013, Mallah and Orwell 2013, Britto and Pacifico 2018], Máquinas de Vetores de Suporte [Venkataraman and Mangayarkarasi 2016], Algoritmo de Floresta Aleatória [Britto et al. 2019, Pacifico et al. 2019] e Redes Neurais Artificiais [Prasad and Singh 2017, Adinugroho and Sari 2018, Hu et al. 2018, Pacifico et al. 2018].

Neste trabalho, um sistema de reconhecimento de espécies de plantas medicinais é proposto. Uma nova base de dados é elaborada, formada pela extração de características da textura e da forma das folhas dessas plantas. A base de dados proposta é composta por amostras obtidas de 16 espécies de plantas medicinais comumente encontradas no Brasil. Para a composição do módulo de reconhecimento do sistema proposto, quatro classificadores da literatura de Aprendizagem de Máquina são testados através de uma análise experimental executada na base de dados proposta. O presente trabalho dá continuidade às avaliações iniciadas em [Britto et al. 2019, Pacifico et al. 2019], pelo aumento da base de dados e pela combinação de características de textura e forma das imagens obtidas para a geração da base de dados. Além disso, a influência da resolução das imagens é analisada no presente trabalho, visando a obtenção de imagens com a menor resolução possível e que apresentem boas taxas de classificação, de modo que o sistema de reconhecimento final não faça uso desnecessário de memória de armazenamento.

O trabalho está dividido como segue. A metodologia utilizada para o desenvolvimento da base de dados proposta é definida na Seção 2. Em seguida, os resultados experimentais são discutidos (Seção 3). Por fim, as conclusões e possíveis linhas de continuidade da pesquisa são apresentadas (Seção 4).

2. Metodologia

Neste trabalho, uma nova base de dados é apresentada. A base de dados proposta é composta de amostras de imagens obtidas de 16 espécies de plantas medicinais facilmente encontradas no Brasil. As imagens foram coletadas através da internet e pela aquisição de imagens em campo, tendo a coleta das mesmas sido iniciada em [Britto et al. 2019, Pacifico et al. 2019]. Tanto as imagens obtidas pela internet quanto as imagens obtidas em campo foram classificadas com a ajuda de especialistas.




Figura 1. Etapas do Pré-Processamento: (a) Imagem Original, (b) Obtenção dos Segmentos de Imagem, (c) Segmento de Imagem isolado, (d) Conversão de um Segmento de Imagem para Níveis de Cinza, (e) Binarização de um Segmento de Imagem.

Tabela 1. Distribuição Amostral dos Segmentos de Imagem por Espécie de Planta Medicinal.

Espécie	#Amostras	Espécie	#Amostras
<i>Achillea millefolium</i>	12	<i>Chondrodendron platyphyllum</i>	15
<i>Aconitum napellus</i>	9	<i>Cinnamomum verum</i>	32
<i>Apium graveolens</i>	18	<i>Eugenia uniflora</i>	20
<i>Argemone mexicana</i>	25	<i>Glycyrrhiza glabra</i>	24
<i>Bidens pilosa</i>	16	<i>Illicium verum</i>	28
<i>Bixa orellana</i>	18	<i>Oxalis acetosella</i>	7
<i>Caesalpinia ferrea</i>	17	<i>Plectranthus amboinicus</i>	16
<i>Casearia sylvestris</i>	33	<i>Sambucus nigra</i>	13
Total		303	

Após a coleta das imagens, iniciam-se os processos de pré-processamento (Figura 1) e extração de características. Dado que as imagens coletadas em campo podem conter mais do que uma amostra das folhas, cada folha em uma imagem é separada em um *segmento de imagem* próprio, sendo essa separação realizada manualmente. A distribuição amostral desses segmentos de imagem por espécie é apresentada na Tabela 1. Para gerar uma maior variabilidade nas amostras, cada segmento de imagem é rotacionado em três orientações diferentes (90°, 180° e 270°) [Lee et al. 2015], resultando em um total de 1212 segmentos de imagens.

Como o foco do presente trabalho é na utilização de características de textura e forma das folhas, os segmentos de imagens (que estão no padrão RGB) são convertidos para **níveis de cinza**, de modo que as características de textura possam ser extraídas, e em seguida, são **binarizados**, de onde as características da forma das folhas são obtidas. As características de textura e da forma das folhas adotadas neste trabalho são descritas abaixo:

1. Características do Histograma de Coocorrência de Níveis de Cinza (*Gray-Level Co-occurrence Matrix*, ou GLCM) (características de **textura**) [Sabu and Sreekumar 2017, Kadir 2014, Albregtsen et al. 2008, Pushpa et al. 2016]:

(a) Contraste (Con):

$$Con = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} (i-j)^2 GLCM(i,j) \quad (1)$$

(b) Correlação (Cor):

$$Cor = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} GLCM(i,j) \frac{(i-\mu_i)(j-\mu_j)}{\sigma_i \sigma_j} \quad (2)$$

(c) Dissimilaridade (Dis):

$$Dis = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} GLCM(i,j) |i-j| \quad (3)$$

(d) Energia (Eng):

$$Eng = \sqrt{\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} GLCM(i,j)^2} \quad (4)$$

(e) Entropia (Ent):

$$Ent = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} -GLCM(i,j) \ln(GLCM(i,j)) \quad (5)$$

(f) Homogeneidade (Hom):

$$Hom = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} \frac{GLCM(i,j)}{1+(i-j)^2} \quad (6)$$

(g) Segundo Momento Angular (ASM):

$$ASM = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} GLCM(i,j)^2 \quad (7)$$

onde $GLCM(i, j)$ é refere-se ao elemento da posição (i, j) do GLCM normalizado e simétrico, e L é o número de níveis de cinza da imagem.

2. Momentos Invariantes de Hu [Hu 1962] (características da **forma**):

$$I_1 = \mu_{20} + \mu_{02} \quad (8)$$

$$I_2 = (\mu_{20} - \mu_{02})^2 + 4\mu_{11}^2 \quad (9)$$

$$I_3 = (\mu_{30} - 3\mu_{12})^2 + (3\mu_{21} - \mu_{03})^2 \quad (10)$$

$$I_4 = (\mu_{30} + \mu_{12})^2 + (\mu_{21} + \mu_{03})^2 \quad (11)$$

$$\begin{aligned} I_5 = & (\mu_{30} - 3\mu_{12})(\mu_{30} + \mu_{12})[(\mu_{30} + \mu_{12})^2 \\ & - 3(\mu_{21} + \mu_{03})^2] + (3\mu_{21} - \mu_{03})(\mu_{21} \\ & + \mu_{03})[3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] \end{aligned} \quad (12)$$

$$\begin{aligned} I_6 = & (\mu_{20} - \mu_{02})[(\mu_{30} + \mu_{12})^2 - (\mu_{21} \\ & + \mu_{03})^2] - (\mu_{30} - 3\mu_{12})(\mu_{21} + \mu_{03})[3(\mu_{30} \\ & + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] \end{aligned} \quad (13)$$

$$\begin{aligned} I_7 = & (3\mu_{21} - \mu_{03})(\mu_{30} + \mu_{12})[(\mu_{30} + \mu_{12})^2 \\ & - 3(\mu_{21} + \mu_{03})^2] - (\mu_{30} - 3\mu_{12})(\mu_{21} \\ & + \mu_{03})[3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] \end{aligned} \quad (14)$$

onde μ_{ij} são momentos invariantes à escala [Hu 1962].

No intuito de gerar um sistema de reconhecimento que não desperdice recursos computacionais, os segmentos de imagens foram padronizados em quatro escalas diferentes, visando a economia de espaço de armazenamento: testes foram realizados com imagens com resolução de 30x30 pixels, 60x60 pixels, 90x90 pixels e 120x120 pixels. O intuito desta avaliação é obter o melhor conjunto de segmentos de imagens que permita uma boa taxa de acerto na classificação das espécies, e com a menor resolução possível, de modo a evitar o desperdício de memória de armazenamento. Para cada um dos quatro conjuntos de resolução das imagens, as quatorze características (sete de textura e sete de forma) foram extraídas, de modo que quatro bases de dados diferentes (em termos de resolução das imagens) foram geradas.

3. Avaliação Experimental

Nesta seção, os resultados experimentais serão apresentados. Quatro classificadores provenientes da literatura de Aprendizagem de Máquina são comparados: Árvore de Decisão (DT), k -Vizinhos mais Próximos (KNN), k -Vizinhos mais Próximos Ponderado (WKNN) e o Classificador de Floresta Aleatória (RFC). Todas as variações do KNN foram testadas com $k = 3, 4$ e 5 , usando a distância euclidiana como medida de dissimilaridade. Todos os algoritmos foram implementados na linguagem de programação **Python**, através do uso da biblioteca *scikit-learn* [Pedregosa et al. 2011, Buitinck et al. 2013].

Os experimentos foram conduzidos através de um *framework* do tipo validação cruzada *10-fold*: a base de dados proposta é dividida aleatoriamente em dez partes (sem sobreposição entre essas partes), e em cada uma das dez etapas da repetição do experimento, uma dessas partes é usada como *conjunto de teste*, enquanto as outras nove partes são usadas como *conjunto de treinamento* dos modelos. O processo de validação cruzada *10-fold* foi repetido 10 vezes (totalizando 100 experimentos), sendo em cada uma dessas vezes os dados redistribuídos aleatoriamente para a formação das *folds*, de modo a evitar resultados obtidos por sorte.

Os resultados experimentais são apresentados na Tabela 2. A avaliação dos resultados experimentais leva em consideração uma análise empírica em relação à **acurácia no conjunto de teste**.

Tabela 2. Resultados Experimentais. Média: valor médio da acurácia de teste nos 100 experimentos; Std: desvio padrão da acurácia de teste nos 100 experimentos.

Algoritmo	30 x 30		60 x 60		90 x 90		120 x 120	
	Média	Std	Média	Std	Média	Std	Média	Std
DT	0.8854	0.0302	0.9120	0.0275	0.9365	0.0275	0.9352	0.0302
KNN ₃	0.4279	0.0398	0.5124	0.0409	0.5859	0.0377	0.6191	0.0385
KNN ₄	0.4032	0.0399	0.4837	0.0424	0.5547	0.0417	0.5895	0.0430
KNN ₅	0.4344	0.0436	0.5101	0.0472	0.5751	0.0399	0.6198	0.0420
WKNN ₃	0.8631	0.0331	0.9130	0.0264	0.9241	0.0296	0.9315	0.0291
WKNN ₄	0.8474	0.0365	0.9063	0.0268	0.9193	0.0316	0.9285	0.0305
WKNN ₅	0.8425	0.0341	0.8974	0.0290	0.9134	0.0316	0.9215	0.0316
RFC	0.9471	0.0263	0.9681	0.0233	0.9788	0.0182	0.9795	0.0170

Da Tabela 2, em uma análise empírica, podemos observar que o RFC obteve os melhores resultados em respeito a todas as resoluções de imagem selecionadas, em comparação aos demais classificadores. A DT e o WKNN₃ obtiveram, respectivamente, o segundo e o terceiro melhores desempenhos médios. Pelos experimentos, podemos observar que tanto no KNN quanto no WKNN o desempenho médio decaiu com o aumento do valor do parâmetro k . Considerando o fato de que a base de dados proposta possui dezesseis classes, sendo essas classes não balanceadas entre si, esse decaimento na performance é completamente esperado, corroborando resultados obtidos na literatura [Rahmani et al. 2015, Pacifico et al. 2018, Britto et al. 2019, Pacifico et al. 2019].

Em uma avaliação geral, levando em consideração tanto os valores das acurácias quanto o tamanho da resolução das imagens, podemos concluir que o classificador de Floresta Aleatória seria uma escolha mais adequada como módulo de reconhecimento do sistema proposto, e que tendo em vista a economia de memória de armazenamento, a

resolução de 90x90 pixels seria a recomendada, dado que não houve ganho acentuado na acurácia ao se aumentar a resolução das imagens após esse valor.

4. Conclusões

Neste trabalho, uma abordagem para o desenvolvimento de um sistema automático de reconhecimento de imagens de plantas medicinais é apresentada. Uma base de dados de plantas medicinais é elaborada, obtida através da extração de características de forma e textura de segmentos de imagens de folhas. Quatro abordagens supervisionadas são empregadas na classificação dos segmentos de imagens: Árvore de Decisão, K-Vizinhos Mais Próximos, K-Vizinhos Mais Próximos Ponderado e o classificador de Floresta Aleatória.

Como forma de avaliação dos classificadores selecionados, uma análise empírica foi aplicada, levando-se em consideração quatro variações na resolução das imagens, no intuito da elaboração de um sistema que seja o mais robusto possível, e com o menor consumo de recursos computacionais, como memória de armazenamento.

Os resultados experimentais apontaram que o RFC, a DT e o WKNN (com $k = 3$) obtiveram os melhores desempenhos em relação à acurácia de teste, respectivamente. Como resultado da avaliação realizada, pode-se concluir que, para a base de dados proposta, o melhor cenário para a implementação do sistema levaria em consideração imagens com resoluções de 90x90 pixels, e utilizaria o algoritmo RFC como módulo de reconhecimento, tendo este obtido uma acurácia média de 97,88% no conjunto de teste.

Como trabalhos futuros, pretendemos expandir a base de dados proposta, tanto pelo acréscimo de novas espécies de plantas, quanto pelo aumento do número de imagens por espécie. Também pretendemos expandir a análise pela avaliação de outras características que possam ser extraídas das imagens das folhas (tais como venação, características de margem, entre outras). Por fim, uma ferramenta de propósito geral será desenvolvida, que além de oferecer um reconhecimento automático e preciso das espécies de plantas medicinais, também apresentará informações sobre o uso correto dessas plantas, como forma de difusão dos conhecimentos a cerca dessas espécies.

Agradecimentos

Os autores gostariam de agradecer à FACEPE, ao CNPq e a CAPES pelo suporte financeiro.

Referências

- Adinugroho, S. and Sari, Y. A. (2018). Leaves classification using neural network based on ensemble features. In *2018 5th International Conference on Electrical and Electronic Engineering (ICEEE)*, pages 350–354. IEEE.
- Agarwal, G., Belhumeur, P., Feiner, S., Jacobs, D., Kress, W. J., Ramamoorthi, R., Bourg, N. A., Dixit, N., Ling, H., Mahajan, D., et al. (2006). First steps toward an electronic field guide for plants. *Taxon*, 55(3):597–610.
- Albregtsen, F. et al. (2008). Statistical texture measures computed from gray level co-occurrence matrices. *Image processing laboratory, department of informatics, university of oslo*, 5.

- Britto, L. F. S. and Pacifico, L. D. S. (2018). Plant classification using weighted k-nn variants. In *Anais do XV Encontro Nacional de Inteligência Artificial e Computacional*, pages 58–69. SBC.
- Britto, L. F. S., Pacifico, L. D. S., and Ludermir, T. B. (2019). An automatic leaf classification system based on shape features. In *Anais do XVI Encontro Nacional de Inteligência Artificial e Computacional*, pages 1–12. SBC.
- Buitinck, L., Louppe, G., Blondel, M., Pedregosa, F., Mueller, A., Grisel, O., Niculae, V., Prettenhofer, P., Gramfort, A., Grobler, J., Layton, R., VanderPlas, J., Joly, A., Holt, B., and Varoquaux, G. (2013). API design for machine learning software: experiences from the scikit-learn project. In *ECML PKDD Workshop: Languages for Data Mining and Machine Learning*, pages 108–122.
- Cerutti, G., Tougne, L., Mille, J., Vacavant, A., and Coquin, D. (2013). Understanding leaves in natural images—a model-based approach for tree species identification. *Computer Vision and Image Understanding*, 117(10):1482–1501.
- Cope, J. S., Corney, D., Clark, J. Y., Remagnino, P., and Wilkin, P. (2012). Plant species identification using digital morphometrics: A review. *Expert Systems with Applications*, 39(8):7562–7573.
- Hu, J., Chen, Z., Yang, M., Zhang, R., and Cui, Y. (2018). A multiscale fusion convolutional neural network for plant leaf recognition. *IEEE Signal Processing Letters*, 25(6):853–857.
- Hu, M.-K. (1962). Visual pattern recognition by moment invariants. *IRE transactions on information theory*, 8(2):179–187.
- Jin, T., Hou, X., Li, P., and Zhou, F. (2015). A novel method of automatic plant species identification using sparse representation of leaf tooth features. *PloS one*, 10(10):e0139482.
- Jose, C.-R., Erick, M.-M., and Herve, G. (2018). Hidden biases in automated image-based plant identification. In *2018 IEEE International Work Conference on Bioinspired Intelligence (IWOBI)*, pages 1–9. IEEE.
- Kadir, A. (2014). A model of plant identification system using glcm, lacunarity and shen features. *arXiv preprint arXiv:1410.0969*.
- Kumar, N., Belhumeur, P. N., Biswas, A., Jacobs, D. W., Kress, W. J., Lopez, I. C., and Soares, J. V. (2012). Leafsnap: A computer vision system for automatic plant species identification. In *Computer Vision—ECCV 2012*, pages 502–516. Springer.
- Lee, S. H., Chan, C. S., Wilkin, P., and Remagnino, P. (2015). Deep-plant: Plant identification with convolutional neural networks. In *2015 IEEE international conference on image processing (ICIP)*, pages 452–456. IEEE.
- Mallah, C., Cope, J., and Orwell, J. (2013). Plant leaf classification using probabilistic integration of shape, texture and margin features. *Signal Processing, Pattern Recognition and Applications*, 5(1).
- Mallah, C. D. and Orwell, J. (2013). Probabilistic classification from a k-nearest-neighbour classifier. *Computational Research*, 1(1):1–9.

- Pacifico, L. D. S., Britto, L. F. S., Oliveira, E. G., and Ludermir, T. B. (2019). Automatic classification of medicinal plant species based on color and texture features. In *2019 8th Brazilian Conference on Intelligent Systems (BRACIS)*, pages 741–746. IEEE.
- Pacifico, L. D. S., Macario, V., and Oliveira, J. F. L. (2018). Plant classification using artificial neural networks. In *2018 International Joint Conference on Neural Networks (IJCNN)*, pages 1–6. IEEE.
- 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.
- Prasad, S. and Singh, P. P. (2017). Medicinal plant leaf information extraction using deep features. In *Region 10 Conference, TENCON 2017-2017 IEEE*, pages 2722–2726. IEEE.
- Pushpa, B., Anand, C., and Mithun Nambiar, P. (2016). Ayurvedic plant species recognition using statistical parameters on leaf images. *International Journal of Applied Engineering Research*, 11(7):5142–5147.
- Rahmani, M. E., Amine, A., and Hamou, M. R. (2015). Plant leaves classification. *ALL-DATA 2015*, 82.
- Sabu, A. and Sreekumar, K. (2017). Literature review of image features and classifiers used in leaf based plant recognition through image analysis approach. In *Inventive Communication and Computational Technologies (ICICCT), 2017 International Conference on*, pages 145–149. IEEE.
- Sabu, A., Sreekumar, K., and Nair, R. R. (2017). Recognition of ayurvedic medicinal plants from leaves: A computer vision approach. In *Image Information Processing (ICIIP), 2017 Fourth International Conference on*, pages 1–5. IEEE.
- Sahay, A. and Chen, M. (2016). Leaf analysis for plant recognition. In *Software Engineering and Service Science (ICSESS), 2016 7th IEEE International Conference on*, pages 914–917. IEEE.
- Sun, Y., Liu, Y., Wang, G., and Zhang, H. (2017). Deep learning for plant identification in natural environment. *Computational intelligence and neuroscience*, 2017.
- Venkataraman, D. and Mangayarkarasi, N. (2016). Computer vision based feature extraction of leaves for identification of medicinal values of plants. In *Computational Intelligence and Computing Research (ICCIC), 2016 IEEE International Conference on*, pages 1–5. IEEE.