

Medicinal Plant Recognition Using Color, Texture and Shape Features

Larissa F. S. Britto¹, Luciano D. S. Pacifico¹, Matheus F. Silva¹,
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

{larissa.feliciano,luciano.pacifico,matheus.fsilva}@ufrpe.br,
tbl@cin.ufpe.br

Abstract. *The correct identification of plants species is an important task in several areas. The identification is even more important when the consumption and use of those plants are adopted as a way of preventing and treating diseases, where incorrect classification can bring serious consequences. In this work, an automatic plant species identification system is proposed, using machine learning and computer vision techniques. For the experimental evaluation, a real database of medicinal plants, composed of color, shape and texture features from the leaves, is proposed. Some of the main classifiers in the Machine Learning literature were adopted and evaluated.*

Resumo. *A correta identificação da espécie de plantas é uma tarefa importante em diversas áreas. A identificação é ainda mais importante quando o consumo e uso dessas plantas são adotados como forma de prevenção e tratamento de doenças, onde a classificação incorreta pode trazer graves consequências. Neste trabalho, um sistema automático de identificação de espécies de plantas é proposto, utilizando técnicas de aprendizagem de máquina e visão computacional. Para a avaliação experimental, uma base de dados reais de plantas medicinais, contendo características das cores, da forma e da textura das folhas, é proposta. Alguns dos principais classificadores da literatura de Aprendizagem de Máquina foram adotados e avaliados.*

1. Introdução

A classificação de espécie de plantas é uma tarefa de grande impacto, devido à importância das plantas para os seres humanos e para o planeta. Essa tarefa acaba sendo essencial em muitas áreas, em decorrência das diversas aplicações das plantas, que vão desde a produção de alimentos, roupas e até mesmo medicamentos, onde as plantas por si só podem ser utilizadas para prevenir ou tratar doenças, sendo as plantas nesta última categoria conhecidas como **plantas medicinais** [Sabu et al. 2017].

A classificação da espécie de uma determinada planta consiste da identificação da classe taxonômica à qual a mesma pertence. Para essa identificação, características de diferentes partes das plantas podem ser utilizadas, tais quais forma das folhas, cor

das flores, quantidade de pétalas, entre outras. A identificação da espécie de plantas é complexa, e muitas vezes realizada de forma artesanal, onde a presença de um especialista é necessária. Porém, o acesso a um especialista nem sempre é possível, e mesmo com um especialista, a identificação é suscetível a erros humanos.

A falta de identificação ou a identificação incorreta da espécie de planta pode acarretar em consequências graves, principalmente do ponto de vista das plantas medicinais, onde o uso indiscriminado pode provocar riscos à saúde. Métodos para reconhecimento automático de espécies de planta foram propostos com a intenção de substituir o reconhecimento manual, fazendo com que não seja sempre necessária a existência de um especialista humano, diminuindo assim a possibilidade de falha, o que também torna o processo de classificação da espécie mais rápido. Diferentes técnicas de Aprendizagem de Máquina e Visão Computacional têm sido empregadas nessa tarefa, e alguns sistemas de reconhecimento foram propostos recentemente [Barré et al. 2017, Prasad et al. 2017, Raut and Bhalchandra 2018].

Neste trabalho, um sistema de reconhecimento automático de espécies de plantas é proposto. Esse sistema é utilizado para a identificação de espécies de plantas medicinais tradicionalmente utilizadas no Brasil. Para isso, uma base de dados contendo características da forma, cores e textura das folhas de plantas medicinais é proposto. Alguns dos principais algoritmos da literatura (*k*-Vizinhos Mais Próximos, *k*-Vizinhos Mais Próximos Ponderados, Floresta Aleatória, Máquina de Vetores de Suporte) foram testados e seus desempenhos comparados, visando determinar qual o melhor classificador para compor o módulo de reconhecimento do sistema proposto.

O trabalho está dividido como segue. Trabalhos relacionados são apresentados brevemente na Seção 2. A metodologia utilizada para o desenvolvimento da base de dados proposta é definida na Seção 3. Em seguida, os resultados experimentais são discutidos (Seção 4). Por fim, as conclusões e possíveis linhas de continuidade da pesquisa são apresentadas (Seção 5).

2. Trabalhos Relacionados

A identificação de espécies de plantas têm sido um desafio em diversas áreas de estudo. A abordagem tradicional, feita de forma manual, é complexa, onde a presença de especialistas é fundamental. Nesse sentido, diferentes guias são desenvolvidos para o auxílio na diferenciação das características das plantas [Senterre 2016, Smith and Chinnappa 2015, Sheahan 2015], no intuito de facilitar a identificação de diversas espécies. Apesar do auxílio de guias, a classificação manual ainda é trabalhosa e demorada, e está suscetível a erros humanos.

Para resolver esse problema, sistemas automáticos de reconhecimento de espécies de plantas têm sido propostos nos últimos anos, utilizando, na grande maioria, técnicas avançadas de Aprendizagem de Máquina e Visão Computacional. As principais etapas desses sistemas são: aquisição de imagens, pré-processamento, extração de características e classificação.

A aquisição de imagens é uma etapa fundamental para a correta identificação da espécie da planta. Boas práticas são necessárias para que as imagens possuam alta qualidade, evitando problemas no momento da classificação [Grabowski 2015]. Em

[Rzanny et al. 2017], diferentes perspectivas, planos de fundo e iluminações são utilizados para a captura das imagens sob ambientes controlados. A aquisição das imagens em ambientes controlados é bastante comum na maioria dos trabalhos, a fim de evitar possíveis problemas do ambiente natural. Em [Mallah et al. 2013], cada folha da planta é posta em um fundo branco no momento da captura, aumentando o contraste da imagem. Essa mesma abordagem também é usada em [Kumar et al. 2012, Sahay and Chen 2016]. A captura em ambiente natural, também é realizada em alguns trabalhos, como em [Goëau et al. 2016, Sun et al. 2017, Seeland et al. 2017].

Após a aquisição das imagens, uma etapa de pré-processamento é executada, com o objetivo de padronizar tanto a escala quanto a orientação das imagens. Alguns processos comuns nessa etapa são a conversão da imagem para níveis de cinza ou sua binarização, remoção de ruídos e correção do histograma [Sabu and Sreekumar 2017].

Com as imagens normalizadas, a etapa de extração de características pode ser executada. Características de diferentes partes das plantas podem ser extraídas, como das flores [Nguyen et al. 2016] e da plântula [Alimboyong et al. 2018], sendo as características mais comumente adotadas as extraídas das folhas. Em [Chaki et al. 2019], características de cor e textura das bordas de folhas são combinadas com o objetivo de fazer a identificação de imagens de folhas fragmentadas. Em [Kaur and Tulsi 2019], a forma e cor das folhas também são utilizadas. Em [Yigit et al. 2019], em adição à forma e à cor, a dimensão e a textura também são extraídas, além de padrões obtidos através das coordenadas e do centro das folhas.

A principal etapa do sistema de reconhecimento de espécies de plantas é a classificação. Nessa etapa, a partir das características extraídas das plantas, um algoritmo será treinado para identificar a qual classe uma determinada planta pertence. Dentre os principais algoritmos e abordagens podemos citar Máquina de Vetores de Suporte [Kaur and Tulsi 2019, Yigit et al. 2019], Redes Neurais Artificiais [Sun et al. 2017, Chaki et al. 2019, Kaya et al. 2019], k -Vizinhos Mais Próximos [Pearline et al. 2019, Yigit et al. 2019] e o Classificador de Floresta Aleatória [Pearline et al. 2019, Yigit et al. 2019].

3. Metodologia

Neste trabalho, uma nova base de dados é apresentada. A base de dados proposta é composta de amostras de imagens obtidas de 17 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.

Após a coleta das imagens, iniciam-se as etapas 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 1500 segmentos de imagens.




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
<i>Achillea millefolium</i>	12
<i>Aconitum napellus</i>	9
<i>Apium graveolens</i>	18
<i>Argemone mexicana</i>	25
<i>Bidens pilosa</i>	16
<i>Bixa orellana</i>	18
<i>Caesalpinia ferrea</i>	17
<i>Casearia sylvestris</i>	33
<i>Chondrodendron platyphyllum</i>	15
<i>Cinnamomum verum</i>	32
<i>Eugenia uniflora</i>	20
<i>Glycyrrhiza glabra</i>	24
<i>Illicium verum</i>	28
<i>Oxalis acetosella</i>	7
<i>Plectranthus amboinicus</i>	42
<i>Plectranthus barbatus</i>	46
<i>Sambucus nigra</i>	13
Total	375

Como o foco do presente trabalho é na utilização de características das cores, da textura e da forma das folhas, extraem-se primeiro as características das cores dos segmentos de imagens (que estão no padrão RGB), considerando-se **um canal do RGB por vez**. Desta forma, cada canal do RGB de um segmento de imagem I será tratado como uma imagem individual em níveis de cinza, resultando nos segmentos I_R , I_G e I_B . Em seguida, os segmentos de imagem originais (I) são convertidos para **níveis de cinza**, de modo que as características de textura possam ser extraídas. Por fim, os segmentos de imagens são **binarizados**, de onde as características da forma das folhas são obtidas. As características das cores, da textura e da forma das folhas adotadas neste trabalho são descritas abaixo:

1. **Características das Cores** [Sabu and Sreekumar 2017, Kadir 2014]:

(a) Média (μ):

$$\mu = \frac{1}{MN} \sum_{i=0}^M \sum_{j=0}^N p(i,j) \quad (1)$$

(b) Desvio Padrão (σ):

$$\sigma = \sqrt{\frac{1}{MN} \sum_{i=0}^M \sum_{j=0}^N (p(i,j) - \mu)^2} \quad (2)$$

(c) Assimetria (θ):

$$\theta = \frac{1}{MN\delta^3} \sum_{i=0}^M \sum_{j=0}^N (p(i,j) - \mu)^3 \quad (3)$$

(d) Curtose (γ):

$$\gamma = \frac{1}{MN\delta^4} \sum_{i=0}^M \sum_{j=0}^N (p(i,j) - \mu)^4 - 3 \quad (4)$$

onde M e N são as dimensões da imagem, $p(i, j)$ é a intensidade do pixel da posição (i, j) na imagem.

2. **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, Albrechtsen et al. 2008, Pushpa et al. 2016]:

(a) Contraste (Con):

$$Con = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} (i-j)^2 GLCM(i,j) \quad (5)$$

(b) Correlação (Cor):

$$Cor = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} GLCM(i,j) \frac{(i-\mu_i)(j-\mu_j)}{\sigma_i \sigma_j} \quad (6)$$

(c) Dissimilaridade (Dis):

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

(d) Energia (Eng):

$$Eng = \sqrt{\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} GLCM(i,j)^2} \quad (8)$$

(e) Entropia (Ent):

$$Ent = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} -GLCM(i,j) \ln(GLCM(i,j)) \quad (9)$$

(f) Homogeneidade (Hom):

$$Hom = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} \frac{GLCM(i,j)}{1+(i-j)^2} \quad (10)$$

(g) Segundo Momento Angular (*ASM*):

$$ASM = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} GLCM(i,j)^2 \quad (11)$$

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.

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

$$I_1 = \mu_{20} + \mu_{02} \quad (12)$$

$$I_2 = (\mu_{20} - \mu_{02})^2 + 4\mu_{11}^2 \quad (13)$$

$$I_3 = (\mu_{30} - 3\mu_{12})^2 + (3\mu_{21} - \mu_{03})^2 \quad (14)$$

$$I_4 = (\mu_{30} + \mu_{12})^2 + (\mu_{21} + \mu_{03})^2 \quad (15)$$

$$\begin{aligned} I_5 = & (\mu_{30} - 3\mu_{12})(\mu_{30} + \mu_{12})[(\mu_{30} + \mu_{12})^2 \\ & - 3(\mu_{21} + \mu_{03})^2] + (3\mu_{21} - \mu_{03})(\mu_{21} \\ & + \mu_{03})[3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] \end{aligned} \quad (16)$$

$$\begin{aligned} I_6 = & (\mu_{20} - \mu_{02})[(\mu_{30} + \mu_{12})^2 - (\mu_{21} \\ & + \mu_{03})^2] - (\mu_{30} - 3\mu_{12})(\mu_{21} + \mu_{03})[3(\mu_{30} \\ & + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] \end{aligned} \quad (17)$$

$$\begin{aligned} I_7 = & (3\mu_{21} - \mu_{03})(\mu_{30} + \mu_{12})[(\mu_{30} + \mu_{12})^2 \\ & - 3(\mu_{21} + \mu_{03})^2] - (\mu_{30} - 3\mu_{12})(\mu_{21} \\ & + \mu_{03})[3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] \end{aligned} \quad (18)$$

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

4. **Outras Características da Forma da Folha:**

- (a) **Perímetro da Folha ($leaf_{per}$):** O perímetro da folha é calculado contando-se o número de pixels na margem da folha.
- (b) **Área da Folha ($leaf_{area}$):** A área da folha é calculada como o número de pixels tendo valor binário 1 no segmento de imagem binário.
- (c) **Compacidade da Folha ($leaf_{comp}$):** A compacidade da folha é calculada como:

$$leaf_{comp} = 4\pi \frac{leaf_{area}}{leaf_{per}^2} \quad (19)$$

A base de dados final será (1500 x 30) dimensional, uma vez que para cada segmento de imagem serão extraídas um total de 29 características, além do rótulo de sua espécies (*classe*), de acordo com a Tabela 2.

No intuito de gerar um sistema de reconhecimento que não desperdice recursos computacionais, os segmentos de imagens foram padronizados em cinco escalas diferentes, visando a economia de espaço de armazenamento: testes foram realizados com imagens com resolução de 30x30 pixels, 60x60 pixels, 90x90 pixels, 120x120 pixels e 150x150 pixels. O intuito desta avaliação é obter o melhor conjunto de segmentos de

Tabela 2. Conjunto de Características para Cada Padrão da Base (Segmento de Imagem).

Número	Característica	Número	Característica	Número	Característica
#01	μ_R (cor)	#11	θ_B (cor)	#21	I_2 (forma)
#02	σ_R (cor)	#12	γ_B (cor)	#22	I_3 (forma)
#03	θ_R (cor)	#13	ASM (textura)	#23	I_4 (forma)
#04	γ_R (cor)	#14	Con (textura)	#24	I_5 (forma)
#05	μ_G (cor)	#15	Cor (textura)	#25	I_6 (forma)
#06	σ_G (cor)	#16	Dis (textura)	#26	I_7 (forma)
#07	θ_G (cor)	#17	Eng (textura)	#27	$leaf_{per}$ (forma)
#08	γ_G (cor)	#18	Ent (textura)	#28	$leaf_{area}$ (forma)
#09	μ_B (cor)	#19	Hom (textura)	#29	$leaf_{comp}$ (forma)
#10	σ_B (cor)	#20	I_1 (forma)	#30	Espécie (classe)

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 cinco conjuntos de resolução das imagens, um novo conjunto total de características (de acordo com a Tabela 2) foi extraído, de modo que cinco bases de dados diferentes (em termos de resolução das imagens) foram geradas. As bases de dados geradas foram normalizadas na escala [0,1], padronizando a escala das características, de modo a evitar a dominância de características em decorrência da diferença de escala.

4. Avaliação Experimental

Nesta seção, os resultados experimentais serão apresentados. Quatro classificadores provenientes da literatura de Aprendizagem de Máquina são comparados: k -Vizinhos mais Próximos (k -Nearest Neighbors, ou KNN) [Cover and Hart 1967], k -Vizinhos mais Próximos Ponderado (*Weighted k-Nearest Neighbors*, ou WKNN) [Dudani 1976], Máquina de Vetores de Suporte (*Support Vector Machin*, ou SVM) [Haykin 2001] e o Classificador de Floresta Aleatória (*Random Forest Classifier*, ou RFC) [Criminisi et al. 2011]. Todas as variações do KNN foram testadas com $k = 3, 4$ e 5 , usando a distância euclidiana como medida de dissimilaridade. O SVM fez uso das funções de *kernel* **Linear** e **RBF**. 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], usando suas configurações *default*.

Todos os experimentos foram executados em um computador com um processador i5-5250U e 8GB de memória RAM. A avaliação foi realizada pela adoção de quatro métricas bem estabelecidas na literatura de Aprendizagem de Máquina: a Acurácia (eq. (20)), a Precisão (21)), a Revocação (22)), e a F -Measure (23)). Além dessas métricas, o tempo médio de execução de cada algoritmo também será avaliado.

$$Acur. = \frac{TP+TN}{TP+FP+TN+FN} \quad (20)$$

$$Prec. = \frac{TP}{TP+FP} \quad (21)$$

$$Revoc. = \frac{TP}{TP+FN} \quad (22)$$

$$F-Measure = 2 \times \frac{Prec. \times Revoc.}{Prec. + Revoc.} \quad (23)$$

onde TP = Verdadeiros Positivos, FP = Falsos Positivos, TN = Verdadeiros Negativos e FN = Falsos Negativos.

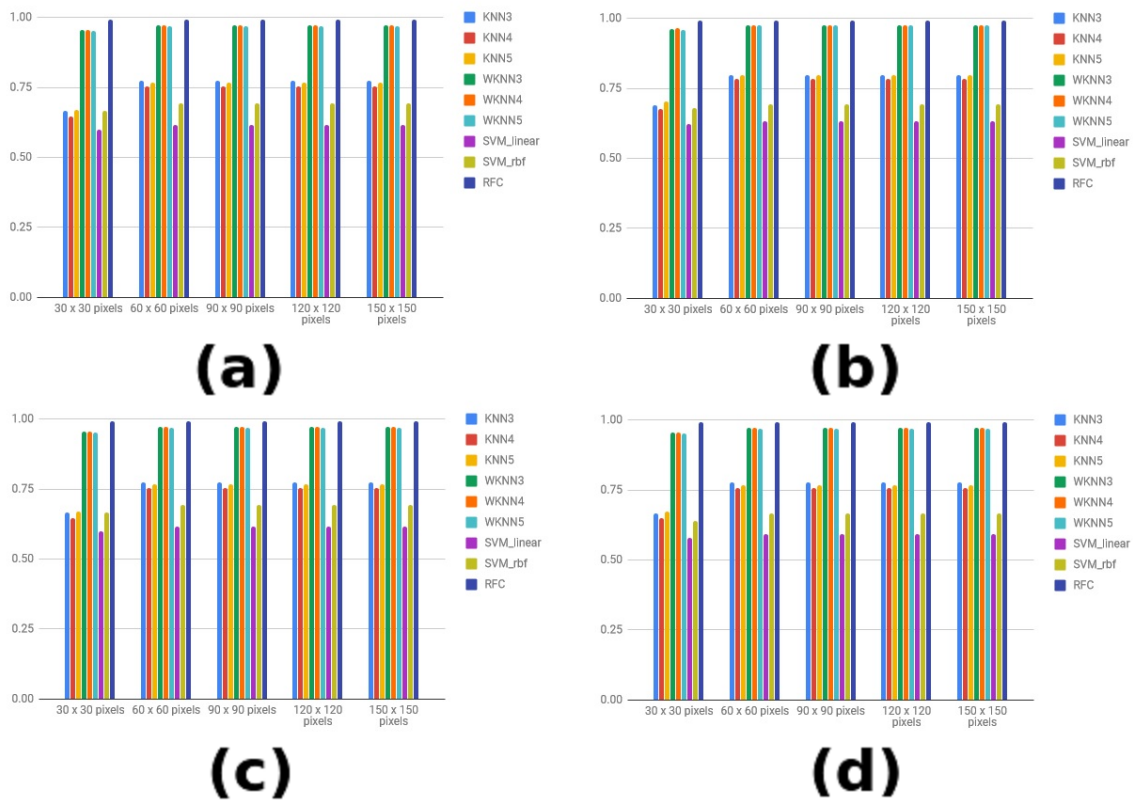


Figura 2. Valores médios obtidos para diferentes dimensões da base de dados: (a) Acurácia, (b) Precisão, (c) Revocação, (d) *F-Measure*.

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.

A Fig. 2 apresenta a variação média de cada uma das métricas avaliadas com o aumento na dimensão das imagens (de 30x30 pixels até 150x150 pixels). Por essa imagem, é possível observar que não há variação significativa nas métricas de avaliação com o aumento da escala das imagens após a dimensão de 60x60 pixels, tendo os classificadores adotados obtido seus melhores desempenhos para essa escala das imagens. Desta forma, a avaliação será conduzida pela análise apenas do caso das imagens com 60x60 pixels. A Tabela 3 apresenta os resultados experimentais.

Da Tabela 3, em uma análise empírica, podemos observar que o RFC obteve os melhores resultados em respeito a todas as métricas de classificação adotadas, em comparação aos demais classificadores. O WKNN₃ e o WKNN₄ obtiveram, respectivamente, o segundo e o terceiro melhores desempenhos médios. Pelos experimentos, podemos observar que tanto no KNN quanto no WKNN o desempenho médio oscilou de forma não muito significativa com o aumento do número de vizinhos a serem con-

Tabela 3. Resultados Experimentais para as imagens com dimensões de 60 x 60 pixels. Média: valor médio da métrica nas 100 repetições do experimentos; Std: desvio padrão da métrica nas 100 repetições do experimentos. O tempo médio de execução está em segundos.

Algoritmo	Acurácia		Precisão		Revocação		<i>F-Measure</i>		Tempo
	Média	Std	Média	Std	Média	Std	Média	Std	
KNN ₃	0.7747	0.0325	0.7987	0.0324	0.7747	0.0325	0.7758	0.0328	0.0106
KNN ₄	0.7551	0.0355	0.7824	0.0359	0.7551	0.0355	0.7558	0.0363	0.0116
KNN ₅	0.7671	0.0309	0.7957	0.0309	0.7671	0.0309	0.7672	0.0316	0.0117
WKNN ₃	0.9704	0.0187	0.9759	0.0156	0.9704	0.0187	0.9703	0.0189	0.0108
WKNN ₄	0.9713	0.0190	0.9765	0.0158	0.9713	0.0190	0.9711	0.0192	0.0116
WKNN ₅	0.9691	0.0185	0.9744	0.0160	0.9691	0.0185	0.9688	0.0191	0.0121
SVM _{linear}	0.6163	0.0417	0.6334	0.0482	0.6163	0.0417	0.5934	0.0455	0.2873
SVM _{rbf}	0.6928	0.0358	0.6943	0.0469	0.6928	0.0358	0.6653	0.0403	0.3881
RFC	0.9921	0.0084	0.9933	0.0070	0.9921	0.0084	0.9920	0.0085	0.0545

siderados (valor do parâmetro k). Dado o fato de que a base de dados proposta possui dezesseis classes, sendo essas classes não balanceadas entre si, essa oscilação 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].

Considerando-se o tempo médio de execução dos algoritmos, o WKNN foi capaz de obter uma boa performance em relação ao RFC (por exemplo, o WKNN₃ executou em aproximadamente um quinto do tempo de execução do RFC), o que pode ser levado em consideração na escolha do classificador a compor o modo de reconhecimento pelo projetista de um sistema de classificação de plantas medicinais.

Em uma avaliação geral, levando em consideração tanto os valores médios obtidos para cada métrica, o tamanho da resolução das imagens, e o tempo médio de execução dos algoritmos, 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 60x60 pixels seria a recomendada, dado que não houve variação significativa nas métricas de avaliação ao se aumentar a resolução das imagens após esse valor. Se o fator mais determinante para o sistema for o tempo médio de execução, o WKNN pode ser considerado como classificador alternativo ao RFC, no cenário avaliado.

5. 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 das cores, da forma e da textura de segmentos de imagens de folhas. Quatro abordagens supervisionadas são empregadas na classificação dos segmentos de imagens: K-Vizinhos Mais Próximos, K-Vizinhos Mais Próximos Ponderado, Máquina de Vetores de Suporte e o classificador de Floresta Aleatória.

Como forma de avaliação dos classificadores selecionados, uma análise empírica foi aplicada, levando-se em consideração quatro métricas de avaliação da área de classificação, assim como cinco resoluções diferentes 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 e o WKNN obtiveram os melhores desempenhos em relação às métricas 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 60x60 pixels, e utilizaria o algoritmo RFC como módulo de reconhecimento, tendo este obtido uma acurácia média de 99,21% nesse cenário.

Como trabalhos futuros, pretendemos dar continuidade à expansão da base de dados proposta através da coleta de imagens em campo, 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) e de outros órgãos das plantas (como frutos, flores, etc.). Por fim, a base de dados elaborada será disponibilizada ao público, assim como 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

- 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.
- Alimboyong, C., Hernandez, A., and Medina, R. (2018). Classification of plant seedling images using deep learning. pages 1839–1844.
- Barré, P., Stöver, B. C., Müller, K. F., and Steinhage, V. (2017). Leafnet: A computer vision system for automatic plant species identification. *Ecological Informatics*, 40:50 – 56.
- 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.
- Chaki, J., Dey, N., Moraru, L., and Shi, F. (2019). Fragmented plant leaf recognition: Bag-of-features, fuzzy-color and edge-texture histogram descriptors with multi-layer perceptron. *Optik*, 181:639 – 650.
- Cover, T. and Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1):21–27.

- Criminisi, A., Shotton, J., and Konukoglu, E. (2011). Decision forests for classification, regression, density estimation, manifold learning and semi-supervised learning [internet]. *Microsoft Research*.
- Dudani, S. A. (1976). The distance-weighted k-nearest-neighbor rule. *IEEE Transactions on Systems, Man, and Cybernetics*, 1(4):325–327.
- Goëau, H., Bonnet, P., and Joly, A. (2016). Plant identification in an open-world (lifeclef 2016). In *CLEF*.
- Grabowski, J. (2015). Best practices to follow when taking photos for plant identification. *Florida ECS Quick*.
- Haykin, S. S. (2001). *Neural networks: a comprehensive foundation*. Tsinghua University Press.
- Hu, M.-K. (1962). Visual pattern recognition by moment invariants. *IRE transactions on information theory*, 8(2):179–187.
- Kadir, A. (2014). A model of plant identification system using glcm, lacunarity and shen features. *arXiv preprint arXiv:1410.0969*.
- Kaur, S. and Tulsı, P. K. (2019). Plant species identification based on plant leaf using computer vision and machine learning techniques. *Journal of Multimedia Information System*, 6:49–60.
- Kaya, A., Keceli, A. S., Catal, C., Yalic, H. Y., Temucin, H., and Tekinerdogan, B. (2019). Analysis of transfer learning for deep neural network based plant classification models. *Computers and Electronics in Agriculture*, 158:20 – 29.
- 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).
- Nguyen, N., Le, V., Le, T., Hai, V., Pantuwong, N., and Yagi, Y. (2016). Flower species identification using deep convolutional neural networks.
- 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.
- Pearline, A., Kumar, S., and Harini, S. (2019). A study on plant recognition using conventional image processing and deep learning approaches. *Journal of Intelligent and Fuzzy Systems*, 36:1–8.

- 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., Kumar, P. S., and Ghosh, D. (2017). An efficient low vision plant leaf shape identification system for smart phones. *Multimedia Tools and Applications*, 76(5):6915–6939.
- 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.
- Raut, S. P. and Bhalchandra, A. S. (2018). Plant recognition system based on leaf image. In *2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)*, pages 1579–1581.
- Rzanny, M., Seeland, M., Wäldchen, J., and Mäder, P. (2017). Acquiring and preprocessing leaf images for automated plant identification: Understanding the tradeoff between effort and information gain. *Plant Methods*, 13:97.
- 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.
- Seeland, M., Rzanny, M., Alaqraa, N., Wäldchen, J., and Mäder, P. (2017). Plant species classification using flower images—a comparative study of local feature representations. *PLOS ONE*, 12(2):1–29.
- Senterre, B. (2016). Practical plant identification training guide.
- Sheahan, C. (2015). Plant guide for canadian serviceberry (amelanchier canadensis). *USDA-Natural Resources Conservation Service*.
- Smith, B. and Chinnappa, C. (2015). *Plant Collection, Identification, and Herbarium Procedures*, pages 541–572.
- Sun, Y., Liu, Y., Wang, G., and Zhang, H. (2017). Deep learning for plant identification in natural environment. *Computational intelligence and neuroscience*, 2017.
- Yigit, E., Sabanci, K., Toktas, A., and Kayabasi, A. (2019). A study on visual features of leaves in plant identification using artificial intelligence techniques. *Computers and Electronics in Agriculture*, 156:369 – 377.