

## Os Coeficientes de Hurst e de Variação Espacial aplicados na Tarefa de Classificação de Espécies Vegetais

L. F. SCABINI<sup>1,\*</sup>, L. ABREU<sup>1,†</sup>, D. N. GONÇALVES<sup>1,‡</sup>, D. BOAVENTURA<sup>1,§</sup>,  
W. N. GONÇALVES<sup>1,¶</sup>,

[1] Curso de Ciência da Computação, Universidade Federal de Mato Grosso do Sul,  
Campus de Ponta Porã, MS, Brasil,

Submetido em 31/01/2015; Aceito em 31/07/2015; Publicado em 24/12/2015

**Resumo.** A identificação de espécies vegetais é crucial em várias áreas do cotidiano, como na indústria alimentícia, medicinal, etc. Porém, ainda hoje o processo de taxonomia vegetal é executado manualmente, na maioria dos casos. A falta de processos automatizados para essa tarefa motivou este trabalho, que apresenta a aplicação de dois métodos na extração de características texturais de imagens, o coeficiente de Hurst e de variação espacial. O objetivo é a extração de dados relevantes que caracterizem e diferenciem cada espécie para que seja realizada a classificação automática. As imagens analisadas são amostras de texturas de diferentes espécies vegetais. Neste trabalho procurou-se estudar métodos já conhecidos na literatura e testar possíveis melhorias e ajustes nas estratégias de análise textural. A proposta apresentada aplica uma combinação dos cálculos dos dois métodos, onde foi observada uma maior capacidade de descrição comparada com os resultados de cada método aplicado individualmente, além de manter o custo computacional. Na classificação, foram utilizados os algoritmos de inteligência artificial: Redes neurais e K-Vizinhos mais próximos, e nos experimentos foram utilizadas 40 espécies diferentes de plantas, onde o classificador foi capaz de alcançar uma porcentagem de acerto de 71,41%.

**Palavras-chave.** Coeficiente de Hurst, Coeficiente de variação espacial, Taxonomia vegetal, Reconhecimento de padrões.

**Abstract.** The identification of plant species is crucial in many areas of daily life, as in the food industry, medicine, etc. However, the plant taxonomy process is still performed manually in most cases. The lack of automated processes for this task motivated this work, showing the application of two methods for extracting textural features of images, the Hurst exponent and spatial variation. The goal is to extract relevant data that characterize and distinguish each species for which classification is performed. The

---

\*leonardo.f.scabini@gmail.com

†lucasabreudasilva@gmail.com

‡dnunesgoncalves@gmail.com

§diogo.boaventura.ufms@gmail.com

¶wnunesgoncalves@gmail.com, Professor Orientador

analyzed images are samples of different plant species textures. In this work we study methods from the literature and test possible improvements and adjustments in the textural analysis strategies. The proposed method applies a combination of both methods keeping the computational cost and improving the description capability compared with the results of each method individually. In the classification, it was used the artificial intelligence algorithms: Neural networks and K-Nearest neighbors, and in the experiments we have used 40 different species of plants, where the classifier was able to achieve 71.41%.

## 1. Introdução

O processo de identificação de espécies vegetais, denominado Taxonomia Vegetal, muitas vezes se torna um trabalho complexo e massivo, devido à grande biodiversidade presente no meio ambiente. O responsável pela classificação deve verificar, manualmente, o catálogo de espécies à procura de um dado que seja compatível com a planta em questão, trabalho que pode levar muito tempo. Porém, apesar da expressividade da área e da alta tecnologia hoje existente, todo o trabalho de identificação e caracterização ainda é realizado manualmente [1]. A falta de métodos automatizados para essa tarefa motivou este trabalho, que apresenta técnicas conhecidas na literatura combinadas para a caracterização de texturas foliares.

Atualmente não existe uma definição formal para o termo textura que seja amplamente aceita na literatura. Um dos primeiros pesquisadores a definir um conceito de textura foi Julesz [2, 3], nos anos 60 e 70. Segundo ele, texturas possuem padrões visuais relacionados se possuírem estatísticas de primeira e segunda ordem parecidas. A textura também pode ser entendida como uma forma de relevo tridimensional em relação às variações de intensidade e cor pela imagem. Em plantas, a textura presente nas folhas pode servir como um poderoso critério de caracterização. Segundo [4], existem cerca de 275.000 espécies de plantas que podem ser reconhecidas e distinguidas apenas pelas suas folhas. Mesmo assim, poucos autores adotaram a textura foliar como método de identificação de espécimes pelo fato da grande similaridade, aparente, dentre as plantas. Vários trabalhos utilizam outros critérios, como forma [5, 6] e estrutura biométrica [7]. Além de existirem poucos trabalhos na literatura sobre classificação vegetal por folhas, o atributo textura ainda é muito pouco utilizado [8, 9, 10]. Em [9], o autor apresenta uma revisão dos métodos utilizados para análise de textura em imagens digitais, investigando a aplicabilidade de métodos tradicionais como Matrizes de coocorrência, Gabor wavelets e Dimensão fractal volumétrica para a classificação vegetal. Em [8], o autor aplica equações diferenciais parciais e dimensão fractal na tarefa de taxonomia vegetal, extraíndo informações sobre texturas das folhas. Em [10], são aplicadas técnicas de caminhadas determinísticas do turista em redes complexas para descrição de texturas, aplicadas na identificação de espécies vegetais.

Porém, neste trabalho, procurou-se avaliar a aplicabilidade dos métodos do coeficiente de Hurst [11] e de variação espacial (CVE) [12], que buscam descrever a textura através da análise da variação de intensidades em uma região de pixels vizinhos. O método de Hurst é mais indicado no cálculo da variação utilizando a imagem convertida em tons de cinza, enquanto que o método do Coeficiente de variação espacial é melhor aplicado a imagens multi-espectrais em três tons (vermelho, verde e azul, ou RGB).

Porém, neste trabalho, foram aplicados ambos em cada um dos formatos das imagens, cuja capacidade de caracterização textural dos exemplos se mostrou mais eficiente. A combinação dos dois métodos resultou em somente 12 valores numéricos, representados em um vetor de características e apresentados ao algoritmo de classificação. Utilizando uma base de imagens com 40 espécies de plantas, o método foi capaz de atingir uma porcentagem de acerto de 71,41%.

O restante do artigo é descrito como segue. A Seção 2 descreve os conceitos teóricos das abordagens, enquanto que a Seção 3 detalha o método proposto. Os experimentos e resultados são apresentados na Seção 4. Por fim, a Seção 5 discute as conclusões e trabalhos futuros.

## 2. Dimensão Fractal

Na geometria clássica, os conceitos e métodos descrevem objetos considerados regulares, enquanto que, os objetos irregulares são desconsiderados. Por exemplo, as propriedades de curvas e superfícies podem ser caracterizadas por meio do conceito de derivada. Porém, alguns fenômenos, a maioria naturais (ex. crescimento e declínio de populações, distribuição da chuva), são irregulares, portanto não são modelados corretamente se utilizados os conceitos da geometria clássica. Nas últimas décadas, trabalhos têm reportado que estes conjuntos irregulares podem ser considerados pela geometria fractal. Algumas definições do termo geometria fractal foram descritas na literatura. Mandelbrot foi o primeiro a descrever este conceito, dando o nome de fractal para todos os conjuntos irregulares cuja dimensão de Hausdorff é estritamente maior que sua dimensão topológica. Porém, existem alguns conjuntos que deveriam ser considerados como fractais, mas não se adequam aos critérios definidos por Mandelbrot. Outras definições foram feitas para fractais, mas não existe uma definição única que se adeque a todos os conjuntos irregulares [13]. Fractais são formas complexas que não podem ser medidas apenas por dimensão topológica. A dimensão fractal surge então como uma alternativa de medição já que pode assumir valores fracionários, obtendo assim o grau de complexidade de uma forma. Pode-se afirmar que a dimensão fractal de um conjunto é um valor que diz o quão densamente um conjunto ocupa o espaço métrico em que ele existe. Apesar de ainda não existir nenhuma caracterização exata do conjunto fractal, a ideia intuitiva é o conjunto que contém uma cópia reduzida de si mesmo, podendo ou não ser acompanhado de deformações. Alguns destes conjuntos podem ser construídos para servir de exemplos do problema. Para descrever os métodos de dimensão fractal em imagens, consideremos primeiro uma imagem composta por pixels  $p_i = (x_i, y_i)$  com intensidade  $I(p_i) \in [0, 255]$ .

### 2.1. Coeficiente de Hurst

O coeficiente de Hurst é uma aproximação da dimensão fractal para imagens em níveis de cinza. Ele consiste em dividir uma imagem em grupos de pixels de acordo com a distância Euclidiana. Em seguida, cada um destes grupos são analisados com o intuito de extrair informações relevantes sobre a variação de intensidade tonal entre estes pixels. Para calcular o Coeficiente de Hurst são necessárias três etapas. Na primeira etapa, é necessário calcular a distância Euclidiana de cada pixel em relação ao pixel central,

definida pela equação

$$d(x_i, y_i, x_c, y_c) = \sqrt{(x_c - x_i)^2 + (y_c - y_i)^2}$$

onde  $(x_c, y_c)$  são as coordenadas do pixel central e  $(x_i, y_i)$  as coordenadas do pixel de destino que se deseja calcular a distância. Uma matriz com a mesma dimensão da imagem pode ser calculada para armazenar as distâncias de cada pixel. A Tabela 1 ilustra esta matriz para uma imagem 5x5, onde cada cor corresponde a um grupo de pixels que possuem a mesma distância. Por exemplo, o grupo azul é o grupo com distância igual a  $\sqrt{2}$ .

$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$
$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$
2	1	0	1	2
$\sqrt{5}$	$\sqrt{2}$	1	$\sqrt{2}$	$\sqrt{5}$
$\sqrt{8}$	$\sqrt{5}$	2	$\sqrt{5}$	$\sqrt{8}$

Tabela 1: Matriz com as distâncias euclidianas de cada pixel em relação ao pixel central, representadas por cores distintas.

Na segunda etapa, cada grupo de distância é analisado. O objetivo dessa etapa é obter o maior e o menor valor de cada um destes grupos, e calcular a diferença entre estes valores. Esse método será feito para todas as distâncias, assim obtendo uma tabela com as respectivas diferenças de nível de cinza de cada distância. A terceira etapa consiste em calcular o logaritmo natural das diferenças e das distâncias. Depois de obtido os valores necessários, é possível estimar a reta que passa pelos pontos das coordenadas logarítmicas. Naturalmente, a equação da reta é definida por  $y = bx + a$ , onde o termo  $b$  é o coeficiente angular da reta e  $a$  o termo independente, ou constante. A reta agora é estimada através do método dos mínimos quadrados, onde seus parâmetros são calculados por

$$b = \frac{(\sum \ln d \ln \Delta g) - (\sum \ln d \sum \ln \Delta g)}{(n \sum \ln d^2) - (\sum \ln d)^2}$$

$$a = \frac{\sum \ln \Delta g}{n} - b \frac{\sum \ln d}{n}$$

onde  $d$  é a distância entre os pixels,  $\Delta g$  a diferença de nível de cinza e  $n$  a quantidade de iterações (quantidade de grupos de pixels de acordo com suas distâncias). São usados os somatórios de cada logaritmo natural das distâncias e das variações de cada distância. Após definida a reta, podemos entendê-la como um descritor do nível de variação tonal através dos grupos de pixels correspondentes à cada distância. A inclinação  $b$  desta reta é o coeficiente de Hurst e pode ser usado para representar a textura presente na imagem.

## 2.2. Coeficiente de Variação Espacial

Na literatura, uma medida bastante utilizada para caracterização de texturas é o Coeficiente de Variação Espacial (CVE). O CVE caracteriza a textura de uma imagem

a partir de medidas estatísticas referentes às variações de intensidade e cor. Duas medidas são empregadas para isso: uma medida de posição (média) e uma medida de dispersão (coeficiente de variação). O coeficiente de variação é uma medida de dispersão relativa que permite comparar qualquer conjunto de dados quanto à sua variabilidade. Então, após obtida a média e o coeficiente de variação para cada classe de distâncias euclidianas, as medidas de posição e de dispersão são empregadas em conjunto para quantificar a textura. A média pode ser obtida por

$$x' = \frac{\sum_{i=1}^n I(p_i)}{n}$$

onde  $n$  é a quantidade total de pixels em análise e  $I(p_i)$  a intensidade de cada pixel. A medida de dispersão utilizada é o coeficiente de variação do conjunto de pixels, obtido pela razão entre o desvio padrão e a média

$$CV = \frac{\sigma}{x'} 100$$

onde  $\sigma$  representa o desvio padrão e  $x$  a média do conjunto. Depois de obtidas essas medidas, a seguinte equação define o CVE

$$CVE = \arctan\left(\frac{x'}{CV + 1}\right) \sqrt{(x')^2 + (CV + 1)^2}$$

### 3. Método Proposto

O método apresentado nesse trabalho aplica técnicas inspiradas na combinação dos cálculos do coeficiente de Hurst e Coeficiente de variação espacial. A hipótese é que, aplicadas em conjunto, as técnicas apresentem melhores resultados do que se utilizadas individualmente. Isso ocorre pelo fato de que cada técnica possui características interessantes para certos aspectos. Por exemplo, o CVE apresenta melhor descrição considerando as cores da imagem, enquanto que o coeficiente de Hurst descreve melhor imagens em tons de cinza. Neste contexto, o método proposto calcula as duas técnicas em paralelo, com intuito de extrair medidas relevantes para cada aspecto das imagens e manter o custo computacional. Isso foi possível porque as duas técnicas utilizam as mesmas regiões de pixels para realizar os cálculos dos coeficientes, portanto, podem ser calculados ao mesmo tempo. Após extração das medidas, os resultados obtidos são combinados em um vetor de características e repassados a um algoritmo classificador baseado em aprendizado supervisionado.

A primeira etapa do método proposto, assim como na maioria dos sistemas de reconhecimento de imagens, é o pré-processamento dos exemplos que serão utilizados. Ruídos possuem grande influência na análise de variação das intensidades dos pixels (principal característica dos coeficientes de Hurst e variação espacial), por isso, a primeira etapa consiste na filtragem Gaussiana para remoção de ruídos, utilizando núcleo de convolução da média ponderada com  $\sigma = 0.7$  e dimensão  $3 \times 3$ . Os valores de  $\sigma$  e da dimensão do núcleo definidos como padrão foram obtidos experimentalmente, através de vários testes com valores distintos em diferentes imagens da base usada.

Após o pré-processamento, a segunda etapa é a extração das características. Os coeficientes de Hurst e de variação espacial são calculados paralelamente para cada

grupo de pixels determinados por uma distância  $d$ . A imagem foi tratada como um texton de 128x128 pixels e, após a remoção de ruídos, foram perdidos pixels das bordas que foram descartados com intuito de manter as características originais da imagem. A imagem foi ajustada para 125x125 para melhor se enquadrar à distância Euclidiana utilizada na análise da vizinhança dos pixels.

Com as distâncias para todos os pixels calculadas, o método inicia os cálculos a partir do pixel central da imagem. Portanto, são agrupados e analisados os pixels correspondentes a cada grupo de distância  $d$ . O uso de alguma janela ou área de alguma forma é necessário, pois a textura só faz sentido em regiões, e não em pixels individualmente [14]. É construída uma matriz com informações das distâncias euclidianas para cada ponto da imagem (veja a Tabela 1, na Seção 2.1.), que será usada como referência no agrupamento dos pixels.

A partir da matriz de referência, construída de acordo com a dimensão da imagem, é possível calcular os coeficientes de Hurst e de variação espacial. Para o cálculo do Coeficiente de variação espacial, primeiramente é necessário o cálculo da média, variância e desvio padrão de cada conjunto de pixels, e a partir desses dados o método calcula as variações espaciais de intensidade. Portanto, é obtido um conjunto de CVEs, ou seja um coeficiente para cada classe de distância diferente e paralelamente os parâmetros necessários para traçar a reta do coeficiente de Hurst são obtidos. A idéia agora é calcular o CVE total da região, que consiste em aplicar o mesmo método, porém, tendo agora como conjunto os coeficientes de cada classe de distância. O resultado final é um valor de coeficiente para toda a imagem, que corresponde à variação dos coeficientes calculados, e os parâmetros  $a$  e  $b$  da reta do coeficiente de Hurst.

Os cálculos do CVE e do coeficiente de Hurst são aplicados a cada dimensão de cor da imagem (RGB) e em tons de cinza, gerando assim um vetor de características com 12 valores numéricos

$$\varphi = [CVE_R, a_R, b_R, CVE_G, a_G, b_G, CVE_B, a_B, b_B, CVE_{cinza}, a_{cinza}, b_{cinza}]$$

que correspondem, respectivamente, ao CVE, o escalar  $a$  que é a constante que soma à equação da reta e o escalar  $b$  que representa a declividade da reta de variação textural (o coeficiente de Hurst). É importante ressaltar que no método de Hurst original considera-se apenas o valor do coeficiente, ou seja, a declividade da reta. Neste trabalho, a constante  $a$  calculada também foi considerada como característica e apresentou grande influência no resultado final de classificação.

Após a extração de características para cada exemplo do banco de imagens, é montado um arquivo que será utilizado como entrada para o classificador. Os classificadores utilizados foram uma Rede neural multi-layer perceptron [15] e também o algoritmo K-Vizinhos mais próximos (K-Nearest neighbours, ou KNN) [16]. Esta escolha foi feita devido à diferença no paradigma de inteligência artificial de cada algoritmo, de forma a analisar mais precisamente os resultados.

## 4. Experimentos e Resultados

O processo de classificação, em um sistema de visão computacional, é dividido em duas etapas principais: treinamento e classificação. Na primeira etapa, é necessário selecionar um conjunto de imagens que servirá como base de exemplos para o treinamento

do classificador. Tal tarefa é de extrema importância, uma vez que ela pode influenciar drasticamente o processo de aprendizado e conseqüentemente a capacidade de predição do modelo. Neste contexto, faz-se necessária a escolha de um conjunto adequado, onde existam exemplos diversos de cada classe e que possam oferecer um conjunto de características relevantes que venham a definir uma boa representação das espécies.

A base de folhas utilizada neste trabalho foi disponibilizada em [9], e é composta por folhas de 40 espécies. As folhas foram coletadas e lavadas manualmente, com o intuito de remover impurezas, e em seguida escaneadas com resolução de 1200 dpi. Em seguida, 30 amostras de 128x128 pixels de cada uma das espécies foram extraídas de regiões aleatórias da folha, sem sobreposição. Para informações sobre todas espécies usadas e o conjunto de imagens para cada classe, o leitor pode consultar [9]. Na Figura 1, são mostradas amostras de textura de 12 das 40 espécies presentes na base.




Figura 1: Exemplos de amostras de 12 classes presentes na base de imagens. Cada amostra possui 128x128 pixels.

Nos experimentos foram avaliados dois classificadores: Redes neurais - multi-layer perceptron, usando taxa de aprendizado = 0.3 e momentum = 0.2, e o algoritmo K-vizinhos mais próximos (K-Nearest neighbors, ou KNN), com  $K = 1$  vizinho como parâmetro. A avaliação do classificador, após o treinamento, pode influenciar diretamente o resultado. Dessa forma, é preciso determinar uma forma eficaz tanto para treinamento quanto para testar o aprendizado do classificador. Por exemplo, se um mesmo conjunto for apresentado ao classificador em ambas as etapas (treinamento e teste), este pode ter uma grande capacidade de acerto, o que seria uma análise errônea. Portanto, o ideal é dividir o conjunto de exemplos em grupos mutuamente exclusivos, denominados Pastas ou Dobras (folds), e separá-los em conjuntos de treinamento e teste. Esta abordagem denomina-se Validação Cruzada (Cross-validation), e consiste em dividir os exemplos em uma quantidade específica de dobras e a partir disso realizar vários treinamentos e testes, cada um utilizando diferentes dobras, e ao final estimar uma média do acerto do classificador. Neste trabalho, a validação cruzada com 20 dobras foi usada para avaliar ambos os classificadores.

A Tabela 2 apresenta os resultados de classificação utilizando o método proposto, o Coeficiente de variação espacial e o coeficiente de Hurst. São mostradas as taxas de acerto e seus respectivos desvios padrão (em parênteses), e também é feito um teste de hipóteses (Teste t de Student com nível de significância 5%), em que cada método foi

comparado com o método proposto. Através da comparação dos extratores de características, é possível perceber que o CVE apresenta resultados superiores aos resultados obtidos pelo coeficiente de Hurst, embora, ele resulte em apenas 53,83% de acerto. Por outro lado, o método proposto apresenta uma porcentagem de 71,41%, o que é bem superior aos demais métodos. O método proposto também venceu os outros métodos no Teste t de Student em ambos os classificadores, o que o torna estatisticamente superior. Esses resultados corroboram que a união das características apresenta resultados interessantes. Além disso, é possível notar que o classificador Redes neurais apresentou resultados superiores ao KNN.

	Método Proposto	CVE	HUSRT
Redes Neurais	71.41% ( $\pm 6.17$ )	53.83% ( $\pm 6.95$ ) *	20.41% ( $\pm 2.78$ ) *
KNN	52.00% ( $\pm 5.69$ )	46.67% ( $\pm 6.82$ ) *	15.25% ( $\pm 1.89$ ) *

Tabela 2: Porcentagem de acerto e desvio padrão para cada método no banco de imagens de plantas, usando os 2 classificadores. O asterisco representa derrota do método em questão no Teste t de Student, comparado com o método proposto.

De acordo com os resultados dos experimentos e a matriz de confusão da Figura 2, é possível notar que o método de Hurst apresenta bons resultados apenas em algumas classes específicas de texturas, além de não apresentar bons resultados quando as imagens possuem variação de cores. O CVE demonstrou melhores resultados se comparado com o método de Hurst, mas da mesma forma apresenta deficiência para certas classes quando não há variações de cores diferentes nas texturas. A Figura 3 representa a matriz de confusão para o método do CVE.

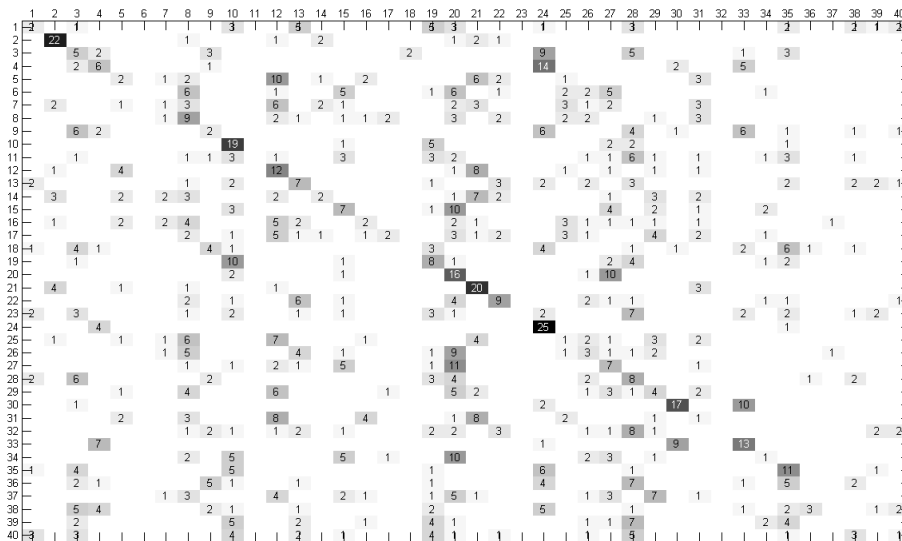


Figura 2: Matriz de confusão para o banco de folhas usando o coeficiente de Hurst e redes neurais.






Figura 3: Matriz de confusão para o banco de folhas usando o método CVE e redes neurais.

Por fim, a aplicação do método proposto demonstrou resultados superiores. A matriz de confusão da Figura 4 demonstra os resultados de classificação. Nesta matriz, podemos observar que os erros (valores fora da diagonal principal) foram reduzidos. O caso com maior quantidade de erros (valor indicado pela seta vermelha) acontece na classe 22, que foi confundida com a classe 6. Exemplos destas classes podem ser observados na Figura 1. Nestes casos, a semelhança torna difícil a identificação até para os seres humanos.

## 5. Conclusão

A dificuldade encontrada na tarefa de classificação de espécies é evidente. Mesmo os seres humanos podem se confundir muito na hora de analisar e diferenciar características entre duas espécies parecidas. Considerando ainda a grande quantidade de espécies existentes no meio ambiente, é notável que o processo de taxonomia vegetal se torna complexo e trabalhoso.

O objetivo desta pesquisa foi apresentar métodos computacionais automatizados para análise e classificação de espécies vegetais, e mostrar que estes podem contribuir fortemente para a área, facilitando e agilizando o processo de identificação. Este trabalho abordou o conceito de textura, atributo que não é utilizado na taxonomia vegetal manual e pouco utilizado em métodos computacionais, e demonstrou ser uma metodologia nova e promissora.

Da aplicação dos métodos do coeficiente de Hurst e CVE na análise de texturas para classificação de plantas, notou-se que é mais viável a utilização dos dois métodos em conjunto do que individualmente. Uma vez que os cálculos podem ser feitos pa-

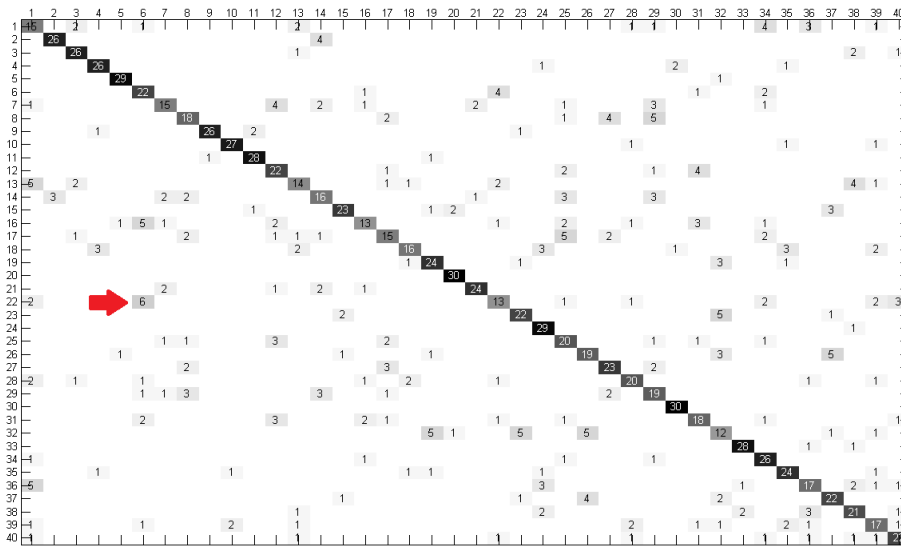


Figura 4: Matriz de confusão para o banco de folhas usando o método proposto e redes neurais.

ralelamente e combinados sem afetar o custo computacional, além de produzir melhor resultado. Como o CVE tem um maior poder de descrição em relação as diferentes cores das imagens e o coeficiente de Hurst é melhor aplicado nas imagens em tons de cinza, a combinação de ambos tanto em tons de cinza quanto nas imagens coloridas demonstrou combinar as boas características de ambos. Entre os tópicos relacionados a futuras pesquisas, estão inclusos adoção de mais características para melhorar o poder de descrição, como formato das folhas, e aplicação do método para cada pixel da imagem, não apenas para o pixel central. Também estuda-se a possibilidade de abordar outros métodos de extração de características de imagens.

## Referências

- [1] A. S. ROSÁRIO, R. S. SECCO, D. D. AMARAL, J. U. M. SANTOS, and M. N. C. BASTOS, “Flórula Fanerogâmica das Restingas do Estado do Pará. Ilhas de Algodoad e Maiandeuá-2. Myrtaceae A.L. de Jussieu,” *Boletim do Museu Paraense Emílio Goeldi, Série Ciências Naturais*, vol. 1, pp. 31–42, set./dez. 2005.
- [2] B. JULESZ, “Visual Pattern Discrimination,” *Information Theory, IRE Transactions on*, vol. 8, no. 2, pp. 84–92, 1962.
- [3] B. JULESZ, E. N. GILBERT, L. A. SHEPP, and H. L. FRISCH, “Inability of Humans to Discriminate between Visual Textures that Agree in Second-Order Statistics-Revisited,” *Perception*, vol. 2, no. 4, pp. 391–405, 1973.
- [4] K. R. STERN, S. JANSKY, and J. E. BIDLACK, *Introductory Plant Biology*. New York: McGraw-Hill, 2003.

- [5] J. X. DU, D. S. HUANG, X. F. WANG, and X. GU, “Computer-Aided Plant Species Identification (CAPSI) based on Leaf Shape Matching Technique,” *Transactions of the Institute of Measurement and Control*, vol. 28, no. 3, pp. 275–285, 2006.
- [6] J. X. DU, X. F. WANG, and G. J. ZHANG, “Leaf Shape based Plant Species Recognition,” *Applied Mathematics and Computation*, vol. 185, no. 2, pp. 883–893, 2007.
- [7] R. O. PLOTZE and O. M. BRUNO, “Automatic Leaf Structure Biometry: Computer Vision Techniques and their Applications in Plant Taxonomy,” *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 23, no. 2, pp. 247–262, 2009.
- [8] B. B. MACHADO, D. CASANOVA, W. N. GONÇALVES, and O. M. BRUNO, “Partial Differential Equations and Fractal Analysis to Plant Leaf Identification,” in *Journal of Physics: Conference Series*, vol. 410, p. 12066, IOP Publishing, 2013.
- [9] D. CASANOVA, *Identificação de Espécies Vegetais por Meio da Análise de Textura Foliar*. Dissertação de Mestrado, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Paulo, SP, Brasil, 2008.
- [10] W. N. GONÇALVES, A. R. BACKES, A. S. MARTINEZ, and O. M. BRUNO, “Texture Descriptor based on Partially Self-Avoiding Deterministic Walker on Networks,” *Expert Systems with Applications*, vol. 39, no. 15, pp. 11818–11829, 2012.
- [11] H. E. HURST, R. P. BLACK, and Y. M. SIMAIKA, *Long-Term Storage: an Experimental Study*. Constable, 1965.
- [12] E. OLIVEIRA NUNES and A. CONCI, “Texture Segmentation and Edge Location of Regions in Multiband Images,” *Latin America Transactions, IEEE (Revista IEEE America Latina)*, vol. 5, no. 3, pp. 184–191, 2007.
- [13] K. FALCONER, *Fractal Geometry: Mathematical Foundations and Applications*. John Wiley & Sons, 2004.
- [14] A. CONCI, E. AZEVEDO, and F. R. LETA, *Computação Gráfica*, vol. 2. Rio de Janeiro: Elsevier, 2007.
- [15] M. A. ARBIB, *The Handbook of Brain Theory and Neural Networks*. The MIT Press, 1995.
- [16] T. M. MITCHELL, *Machine Learning*, vol. 45. Burr Ridge, IL: McGraw Hill, 1997.