

# IDENTIFICAÇÃO DE PLANTAS POR ANÁLISE DE TEXTURA FOLIAR

André R. Backes<sup>1</sup>, Dalcimar Casanova<sup>2</sup>, Odemir M. Bruno<sup>2</sup>

<sup>1</sup>Faculdade de Computação (FACOM), Universidade Federal de Uberlândia (UFU), Uberlândia, MG

<sup>2</sup>Instituto de Física de São Carlos (IFSC), Universidade de São Paulo (USP), São Carlos, SP

backes@facom.ufu.br; dalcimar@gmail.com; bruno@ifsc.usp.br

**Resumo** – A biodiversidade das espécies existentes no riquíssimo reino vegetal tornam os modelos tradicionais de taxonomia, na qual o processo de classificação é realizado manualmente, uma tarefa muito complexa e morosa. As dificuldades presentes nesse processo implicam na existência de poucas pesquisas de classificação vegetal utilizando métodos matemáticos e computacionais. Desta forma, visando contribuir com as técnicas de taxonomia manuais já desenvolvidas, esse estudo apresenta uma nova metodologia computacional de identificação de espécies vegetais por meio da análise da textura foliar. O método, chamado de Fractal Multi-Níveis, é baseado no cálculo da dimensão fractal de imagens binárias geradas a partir da textura. Os excelentes resultados obtidos demonstram como os métodos computacionais de análise de imagens, em especial análise de textura, podem contribuir facilitando e agilizando a tarefa de identificação de espécies vegetais.

**Palavras-chave** – Dimensão Fractal, Textura, Folhas, Herbário, BoxCounting

**Abstract** – The diversity of species in the plant kingdom become traditional models of taxonomy, in which the classification process is performed manually, a very difficult task. The present difficulties in this process imply in the existence of few studies of plant classification using mathematical and computational methods. Therefore, in order to contribute to the manual methods of taxonomy already developed, this study presents a new computational method for identifying plant species through analysis of leaf texture. The method, called Fractal Multilevel, is based on the calculation of fractal dimension of binary images generated from the texture. The excellent results show how the computational methods for image analysis, texture analysis in particular, can help the task of identifying plant species.

**Keywords** – Fractal Dimension, Texture, Leaves, Herbarium, BoxCounting

## 1 INTRODUÇÃO

A Taxonomia Vegetal é a ciência responsável pela síntese, organização, classificação e nomenclatura das espécies de plantas. Essencial ao conhecimento da biodiversidade e ao inventário da flora brasileira, fornece também subsídios para outras áreas relacionadas à Botânica (fisiologia vegetal, citologia, paleobotânica, etc.) e áreas do conhecimento afins (ciências agrárias, ecologia, etc.), além de embasar programas de conservação.

Neste contexto, os herbários vegetais são ferramentas imprescindíveis no trabalho dos taxonomistas na identificação de espécies arbóreas. Segundo [1], um herbário é uma *coleção* de plantas mortas, secas e montadas de forma especial, destinadas a servir como documentação para vários fins. Os herbários abrigam uma grande quantidade de informação e dados sobre a diversidade vegetal. Pela comparação manual pura e simples com outros espécimes da coleção herborizada é possível realizar, entre outras tarefas: 1) Identificar material desconhecido; 2) Realizar levantamento da flora de uma determinada área 3) Reconstituir o clima de uma região; 4) Avaliar a ação devastadora do homem ou da ação deletéria da poluição; 5) Reconstituir o caminho seguido por um botânico coletor.

Contudo, apesar da existência dos herbários e da alta tecnologia hoje existente, todo o trabalho de identificação e caracterização continua sendo realizado manualmente [2]. Este processo taxonômico, tradicionalmente realizado sobre ramos férteis, flores e frutos, acarreta em aferições não tão precisas, pois podem conter erros causados pela manipulação humana, além de não contemplar todas as possíveis informações contidas nas amostras, como por exemplo, características de textura foliar. Neste âmbito o uso de métodos de visão artificial e modelos matemáticos está permitindo o desenvolvimento de técnicas de aferição e extração de informações de forma automatizada da folha, contribuindo para uma análise mais criteriosa da morfologia, anatomia e até mesmo da fisiologia do vegetal. Em contrapartida, o estudo dos atributos visuais das folhas é um problema complexo e auxilia no aprimoramento dos métodos matemáticos utilizados nos problemas de visão computacional.

Visando contribuir com as técnicas de taxonomia já desenvolvidas, este estudo objetiva desenvolver e testar uma metodologia para identificação de espécies vegetais por meio da análise de textura foliar utilizando o método de Dimensão Fractal Multi-níveis [3]. Essa abordagem foi adotada em virtude de haver pouquíssimos trabalhos na literatura sobre classificação vegetal por folhas utilizando técnicas de visão computacional [4–6] e, dentro desse reduzido conjunto, nenhum faz uso do atributo textura para identificação.

A dimensão fractal utilizada aqui, é uma medida de o quão complexo o objeto é. Em texturas, esta complexidade é caracterizada pela organização dos pixels, i.e., a complexidade é relacionada com o aspecto da textura. Assim, a dimensão fractal é

uma técnica adequada para descrever a textura em termos de sua homogeneidade, tornando assim possível a comparação entre diferentes texturas [7, 8].

Nas próximas apresentaremos o método da Dimensão Fractal Multi-níveis. Em sequência o modelo de experimento proposto para a análise de textura foliar, bem como os métodos de análise de textura utilizados para comparação de resultados. Por fim os resultados e conclusões obtidas.

## 2 DIMENSÃO FRACTAL MULTI-NÍVEIS

Embora não possua uma definição formal na literatura, o termo complexidade está frequentemente relacionado as mais diversas características existentes na imagem como, por exemplo, forma, área ocupada, irregularidade da ocupação do espaço, distribuição e organização dos pixels e uniformidade da textura [7, 9]. Trata-se de uma característica de grande importância em processos de reconhecimento de padrões, especialmente naqueles que envolvem imagens biológicas.

A complexidade de um objeto pode ser facilmente quantificada utilizando métodos de estimativa da Dimensão Fractal. A dimensão fractal representa o nível de complexidade e de ocupação do espaço euclidiano por um objeto fractal. Trata-se de uma característica importante dos fractais, uma vez que um nível maior de ocupação do espaço implica em uma estrutura fractal mais complexa.

Essa ligação entre nível de ocupação de espaço e complexidade permite a utilização da dimensão fractal como ferramenta para análise de complexidade. Trata-se de um método de análise com aplicações nas mais diversas áreas do conhecimento, em especial, na área de processamento e análise de imagens [10, 11].

Vários são os métodos descritos na literatura para se estimar a dimensão fractal, sendo o de Box-Counting um dos mais utilizados devido, principalmente, a sua simplicidade e facilidade de implementação. Nele, um *grid* de caixas de aresta  $r$  é sobreposto a imagem  $A \in R^2$ , sendo a seguir realizada a contagem do número de quadrados que interceptam essa imagem,  $N(r)$  (Figura 1) [7, 9, 12]. A Dimensão Fractal é estimada a partir da relação entre o tamanho da caixa utilizada,  $r$ , e o número de caixas contadas,  $N(r)$ , obedecendo à seguinte equação:

$$D = - \lim_{r \rightarrow 0} \frac{\log(N(r))}{\log(r)}. \quad (1)$$




Figura 1: Divisão de uma imagem usando o método de Box-Counting para diferentes valores de  $r$ .

Como intuito de aplicar o método de Box-Counting em texturas de origem biológica, a versão multi-níveis do método foi utilizada [3]. Para tanto, diferentes limiares,  $L_i$ , foram aplicados sobre a textura original  $A \in R^2$  gerando, para cada limiar, uma versão binarizada da textura,  $A_{L_i}$ . Para cada imagem binarizada obtida, a Dimensão Fractal foi calculada:

$$D_{L_i} = - \lim_{r \rightarrow 0} \frac{\log(N_{L_i}(r))}{\log(r)}, \quad (2)$$

Considerando um conjunto de limiares  $L_i$ ,  $L_i \in L$ , é possível obter uma assinatura de textura  $\psi(A)$

$$\psi(A) = [D_{L_1}, \dots, D_{L_i}, \dots, D_{L_M}] \quad i \in 1 \dots M, \quad (3)$$

onde  $M$  é o número de limiares considerados para a caracterização da textura.

Para se obter uma discriminação eficiente das diferentes classes de imagens, é fundamental selecionar um conjunto de limiares que esteja relacionado de alguma forma com a variação dos níveis de cinza das imagens. Desse modo, foi aplicado neste trabalho o método de Otsu [13, 14], em sua versão multi-níveis, sobre o histograma médio das imagens para a seleção do conjunto de limiares, de acordo com as seguintes regras:

1. Para cada imagem  $j$  considerada no experimento, calcule o seu histograma  $h_j(i)$ ;
2. Calcule o histograma médio,  $\overline{h_j(i)}$  a partir dos histogramas calculados. Esse histograma médio representa a distribuição dos níveis de cinza ao longo das amostras;




Figura 2: Imagem binária obtida para 8 diferentes limiares em 3 diferentes texturas




Figura 3: Assinaturas de 3 diferentes espécies obtidas para um dado conjunto de limiares. Observar que cada espécie apresenta descritores bem definidos

- Utilizando o método de Otsu multi-níveis [13, 14], selecione  $M$  níveis de cinza distintos do histograma médio,  $\overline{h_j(i)}$ , calculado anteriormente.

A Figura 2 apresenta as imagens binárias obtidas para um conjunto de limiares dados pelo método de Otsu multi-níveis. Assim, para cada uma dessas imagens, calcula-se a DF, obtendo-se uma assinatura da forma apresentada na Figura 3.

### 3 EXPERIMENTOS

Para a realização desse experimento, foi considerado um conjunto de amostras de folhas contendo 10 espécies da flora brasileira (Figura 4). Para cada espécie, três amostras de folhas foram coletadas manualmente, *in vivo*. As amostras de folhas foram lavadas para evitar a presença de impurezas, o que poderia agir como o ruído nas amostras. Um scanner com resolução de 1200dpi foi utilizado. Durante o processo de digitalização, cada folha foi orientada de modo a manter o seu eixo central em posição vertical.




Figura 4: Exemplo de textura cada uma das 10 espécie de textura utilizada no experimento.

Um total de cinco amostras de textura de  $128 \times 128$  pixels de tamanho foi extraído de cada folha, resultando em um conjunto de 150 amostras de textura agrupados em 10 classes, este processo é representado pela Figura 5. A identificação de folhas de plantas é uma tarefa difícil devido à grande variação no padrão das suas características fundamentais. Estas variações são uma resposta a diferentes níveis de maturidade e de exposição ao sol bem como a outros fatores, como influência do solo, fungos, doenças, clima ou mesmo ambiente. Essa variação pode ser percebida pela observação da Figura 6, a qual apresenta 3 texturas distintas de cada folha (colunas) para 5 espécies diferentes. Além da similaridade intraclasses não ser adequada, a similaridade




Figura 5: Processo de extração das amostras de textura. Exemplo de janelas de tamanho  $128 \times 128$  extraídas aleatoriamente sem sobreposição.




Figura 6: Exemplo da variabilidade da textura por classe (colunas). Verifica-se a variabilidade da textura dentro de uma mesma espécie. Esse tipo de comportamento dificulta o processo de classificação uma vez que a obtenção de um modelo médio para cada espécie é uma tarefa imprecisa.

entre classes é consideravelmente alta. Podemos observar ainda na Figura 6 por exemplo, texturas muito similares entre as espécies 1, 3 e 4, e entre as espécies 2 e 5. Assim, a extração de várias janelas de textura é realizada a fim de diminuir a amostragem de padrões de textura que não representam a real textura daquela espécie de folha.

Para cada amostra de textura de folha, uma assinatura foi calculada utilizando o método de Dimensão Fractal Multi-níveis. Essas assinaturas foram avaliadas utilizando o método de classificação estatística supervisionado LDA (Linear Discriminant Analysis) [15, 16], no esquema de validação cruzada *leave-one-out*.

De modo a obter uma melhor avaliação do método, uma comparação com métodos tradicionais na área de análise de texturas também foi realizada. Para tanto, os seguintes métodos foram considerados:

**Matrizes de Co-ocorrência:** são matrizes que estimam propriedades de uma imagem relacionadas à estatística de segunda-ordem [17]. Cada matriz representa a distribuição de probabilidades entre pares de pixels separados por uma distância e direção. Para este trabalho, foram consideradas matrizes não-simétricas para as distâncias de 1 e 2 pixels e ângulos de  $(-45^\circ, 0^\circ, 45^\circ, 90^\circ)$ , sendo as medidas utilizadas a energia e entropia da distribuição [18].

**Descritores de Fourier:** a partir da aplicação da Transformada de Fourier sobre uma textura, os descritores de Fourier são calculados como sendo um vetor de características contendo a soma das energias dos 63 coeficientes dispostos a uma distância  $r$ ,  $r = 1 \dots 63$ , do centro da imagem (isso depois de ser realizada uma operação de *shifting*) [19, 20].

**Filtros de Gabor:** o Filtro de Gabor 2-D é, basicamente, uma função gaussiana bi-dimensional modulada por uma senoide orientada na direção  $\theta$  e frequência  $W$ . Os descritores foram obtidos a partir da convolução de uma família de filtros de Gabor

sobre uma imagem, onde cada filtro representa diferentes escalas e orientações obtidas a partir de uma configuração original [21–23]. Para este trabalho, foi considerado uma família de 40 filtros (5 rotações e 8 escalas), com frequências inferior e superior de 0.01 e 0.3, respectivamente, sendo a energia calculada de cada imagem resultante [21].

**Descritores de Wavelet:** a transformada de Wavelet é um conjunto de funções bases que representa um sinal em diferentes bandas de frequências, cada uma com uma escala de resolução. Essa abordagem permite a análise e representação de uma imagem de uma maneira multi-escala. Nesse trabalho, quatro níveis de decomposição da wavelet foram obtidos para cada imagem, resultando em 12 componentes de alta frequência. Os valores de energia e entropia foram obtidos de cada componente de alta frequência, totalizando 24 descritores [24, 25].

## 4 RESULTADOS E DISCUSSÃO

Os resultados mostram que, dentro do conjunto de métodos analisados, a Dimensão Fractal Multi-níveis é o melhor método para análise de texturas foliares (com probabilidade geral de acerto de 90.67%, ver Tabela 1). As demais medidas (Descritores de Fourier e Filtros de Gabor) apresentaram resultados inferiores (Tabela 1). Isso se deve principalmente a ausência de características direcionais significantes nas texturas (e.g., linhas horizontais, verticais ou diagonais). Como esses métodos salientam esse tipo de informação, não é possível obter resultados expressivos como os obtidos pela Dimensão Fractal Multi-níveis e pelas matrizes de co-ocorrência.

Diferentemente dos métodos de filtros de Gabor, descritores de Fourier e matrizes de co-ocorrência, o método de Dimensão Fractal Multi-níveis não possui parâmetros a serem escolhidos pelo usuário. Os parâmetros nele envolvidos (e.g.  $M$  limiares) são obtidos automaticamente através do método de Otsu multi-níveis considerando o histograma médio. Não há, portanto, a necessidade de uma pré-configuração dos parâmetros quando da aplicação em uma base de dados diferente. Para a base analisada, os melhores resultados são alcançados quanto um total de  $M = 126$  descritores são utilizados, ou seja, o método de Otsu multi-níveis retornou 126 limiares, obtendo-se assim 126 dimensões fractais.

Os bons resultados obtidos com a Dimensão Fractal Multi-níveis se devem principalmente a sua capacidade de quantificar a homogeneidade de uma textura a partir de sua complexidade. Neste caso, avalia-se a complexidade da textura ao longo dos níveis de cinza onde sua homogeneidade se altera. Temos, portanto, que a combinação da Dimensão Fractal de BoxCounting com o método de Otsu multi-níveis permite construir uma assinatura associada as mais relevantes mudanças de complexidade da textura.

Tendo em vista a utilização do método de Otsu, alterações no brilho ou contraste da imagem obtida poderia interferir negativamente nos resultados obtidos. Entretanto salienta-se que, para a aplicação proposta, o processo de aquisição de imagens é controlado, não interferindo significativamente no brilho e/ou contraste. Para demais tipos de aplicações, com aquisição não controlado, pode-se utilizar a equalização dos histogramas como forma de atenuar tal tipo de problema.

Método	Taxa de acertos (%)
Matriz de Co-ocorrência	86,66
Descritores de Fourier	62,66
Filtros de Gabor	73,33
Descritores de Wavelet	84,67
Dimensão Fractal Multi-níveis	90,67

Tabela 1: Comparação dos resultados obtidos para os diferentes métodos considerados.

A Tabela 2 apresenta a matriz de confusão para o método da Dimensão Fractal Multi-níveis. Observamos que, além das boas taxas de acerto obtidas, todas as classes foram bem discriminadas, não possuindo uma tendência a erro ou confusão com uma espécie somente. Assim, apesar da similaridade entre as espécies, o método se mostra robusto, qualidade desejável em algoritmo de visão computacional e aprendizado de máquina.

classe	1	2	3	4	5	6	7	8	9	10
1	15	0	0	0	0	0	0	0	0	0
2	1	13	0	0	0	0	0	0	0	1
3	0	0	15	0	0	0	0	0	0	0
4	0	0	0	15	0	0	0	0	0	0
5	0	0	0	0	15	0	0	0	0	0
6	1	0	0	0	1	13	0	0	0	0
7	0	0	0	0	1	1	11	0	0	2
8	0	0	0	0	0	0	0	15	0	0
9	0	0	0	0	0	0	0	0	14	1
10	0	3	0	0	1	0	1	0	0	10

Tabela 2: Matriz de confusão obtida para o método da Dimensão Fractal Multi-níveis.

## 5 CONCLUSÕES

A identificação de espécies vegetais é uma importante, porém difícil tarefa, principalmente devido à biodiversidade das espécies. Desde o processo de aquisição do espécime até a morosa comparação com as amostras já catalogadas em um herbário exigem um grande esforço dos taxonomistas e/ou profissionais de áreas correlatas.

Nesse contexto, este trabalho apresentou como o método de Dimensão Fractal Multi-níveis pode contribuir para identificação de espécies vegetais. Também foi realizada uma comparação entre diferentes abordagens de extração de características de textura foliar. A comparação entre os métodos foi realizada a partir de experimentos com imagens de texturas, as quais foram extraídas da superfície de diferentes espécies de folhas da flora brasileira. A análise estatística das características extraídas foi realizada utilizando o método de LDA.

Os melhores resultados de classificação foram obtidos quando aplicado o método de Dimensão Fractal multi-níveis sobre as amostras. Esse método permite descrever uma amostra de textura a partir da variação do nível de complexidade existente nas diferentes distribuições de níveis de cinza da amostra. Os resultados, superiores a métodos estado da arte (e.g. filtros de Gabor wavelets), levam a acreditar que esta abordagem pode vir a se tornar uma importante ferramenta na área de visão computacional e indicam que a análise de complexidade oferece excelentes características para a caracterização de uma determinada espécie, viabilizando, portanto, a sua identificação. Certamente mais testes, com maiores bases de dados, são necessários, mas os resultados aqui obtidos são encorajadores.

Associado aos métodos manuais, os bons resultados obtidos pelo método apresentado, pode complementar as metodologias empregadas pelos taxonomistas, facilitando e agilizando a tarefa de identificação de espécies.

## 6 AGRADECIMENTOS

Odemir M. Bruno agradece ao CNPq (Procs. #303746/2004-1 e #504476/2007-6) e à FAPESP (Proc. #06/54367-9). André R. Backes agradece à FAPESP (Proc. #06/54367-9) pelo apoio financeiro ao doutorado. Dalcimar Casanova agradece à Fapesp (Proc. #2008/57313-2) pelo apoio financeiro ao doutorado.

## REFERÊNCIAS

- [1] M. Sakane. *Técnicas de coleta, preservação e herborização de material botânico*. Instituto Botânico, 1984.
- [2] A. C. A. Vicente, E. G. Macedo, J. U. M. dos Santos, R. C. de V. Potiguara and M. N. do C. Bastos. “Flórula fanerogâmica das restingas do estado do Pará, Ilha do Algodão”. *Boletim do Museu Paraense Emílio Goeldi*, vol. 15, pp. 173–198, 1999.
- [3] A. R. Backes and O. M. Bruno. “A New Approach to Estimate Fractal Dimension of Texture Images”. In *International Conference on Image and Signal Processing*, pp. 136–143, 2008.
- [4] C. L. Lee and S. Y. Chen. “Classification of leaf images”. *International Journal of Imaging Systems and Technology*, vol. 16, no. 1, pp. 15–23, 2006.
- [5] P. Tzionas, S. Papadakis and D. Manolakis. “Plant Leaves Classification Based on Morphological Features and a Fuzzy Surface Selection Technique”. In *5th International Conference on Technology and Automation*, pp. 365–370, 2005.
- [6] Z. Wang, Z. Chi and D. D. Feng. “Shape based leaf image retrieval”. *IEEE Proceedings on Vision Image and Signal Processing*, vol. 150, no. 1, pp. 34–43, 2003.
- [7] C. Tricot. *Curves and Fractal Dimension*. Springer-Verlag, 1995.
- [8] G. D. Lange and W. B. Marks. “Fractal methods and results in cellular morphology - dimensions, lacunarity and multifractals”. *Journal of Neuroscience Methods*, vol. 69, no. 2, pp. 123–136, November 1996.
- [9] M. Schroeder. *Fractals, Chaos, Power Laws: Minutes From an Infinite Paradise*. W. H. Freeman, 1996.
- [10] R. de O. Plotze, J. G. Pádua, M. Falvo, L. C. B. , G. C. X. Oliveira, M. L. C. Vieira and O. M. Bruno. “Leaf shape analysis by the multiscale minkowski fractal dimension, a new morphometric method: a study in passiflora L. (Passifloraceae)”. *Canadian Journal of Botany-Revue Canadienne de Botanique*, vol. 83, no. 3, pp. 287–301, 2005.
- [11] Carlin. “Measuring the Complexity of Non-fractal Shapes by a Fractal Method”. *PRL: Pattern Recognition Letters*, vol. 21, 2000.
- [12] R. C. Coelho and L. F. Costa. “The Box-Counting Fractal Dimension: Does it provide an Accurate Subsidy for Experimental Shape Characterization? If So, How to Use It?” In *Anais do Sibgrapi 95*, pp. 183–191, 1995.
- [13] P.-S. Liao, T.-S. Chen and P.-C. Chung. “A Fast Algorithm for Multilevel Thresholding”. *Journal of Information Science and Engineering*, vol. 17, no. 5, pp. 713–727, 2001.
- [14] N. Otsu. “A threshold selection method from gray level histograms”. *IEEE Transactions on Systems, Man and Cybernetics*, vol. 9, pp. 62–66, March 1979. minimize intra and inter class variance.

- [15] B. S. Everitt and G. Dunn. *Applied Multivariate Analysis*. Arnold, 2001.
- [16] K. Fukunaga. *Introduction to Statistical Pattern Recognition*. Academic Press, 1990.
- [17] C. H. Chen, L. F. Pau and P. S. P. Wang. *Handbook of Pattern Recognition and Computer Vision*. World Scientific, 1992.
- [18] R. M. Haralick. “Statistical and Structural Approaches to Texture”. *Proceedings of IEEE*, vol. 67, no. 5, pp. 786–804, 1979.
- [19] R. Azencott, J.-P. Wang and L. Younes. “Texture Classification Using Windowed Fourier Filters”. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 19, no. 2, pp. 148–153, 1997.
- [20] E. O. Brigham. *The Fast Fourier Transform and its applications*. Prentice Hall, 1988.
- [21] B. S. Manjunath and W.-Y. Ma. “Texture Features for Browsing and Retrieval of Image Data”. *IEEE Transactions Pattern Analysis and Machine Intelligence*, vol. 18, no. 8, pp. 837–842, 1996.
- [22] M. Idrissa and M. Acheroy. “Texture classification using Gabor filters”. *Pattern Recognition Letters*, vol. 23, no. 9, pp. 1095–1102, 2002.
- [23] A. K. Jain and F. Farrokhnia. “Unsupervised texture segmentation using Gabor filters”. *Pattern Recognition*, vol. 24, no. 12, pp. 1167–1186, 1991.
- [24] A. Sengür, I. Türkoglu and M. C. Ince. “Wavelet packet neural networks for texture classification”. *Expert Syst. Appl*, vol. 32, no. 2, pp. 527–533, 2007.
- [25] P. W. Huang, S. K. Dai and P. L. Lin. “Texture image retrieval and image segmentation using composite sub-band gradient vectors”. *J. Visual Communication and Image Representation*, vol. 17, no. 5, pp. 947–957, 2006.