

Utilização dos Descritores SIFT e SURF para a Identificação de Espécies Florestais

RESUMO

Juliano Wunsch Dias
juliano.2016@alunos.utfpr.edu.br
Universidade Tecnológica Federal
do Paraná, Toledo, Paraná, Brasil

Jefferson Gustavo Martins
martins@utfpr.edu.br
Universidade Tecnológica Federal
do Paraná, Toledo, Paraná, Brasil

Diferentes tipos de madeira são providos por espécies florestais específicas. A correta identificação das espécies florestais é de suma importância, pois diferentes espécies produzem madeiras com diferentes propriedades que determinam suas possíveis aplicações e seu valor comercial. Além disso, é necessário garantir que não haja o uso de madeiras extraídas de espécies florestais em risco de extinção. Este trabalho foca a classificação de espécies florestais por meio de imagens microscópicas de sua madeira. Para isso, descritores baseados em pontos de atenção são extraídos e utilizados na construção dos classificadores. As taxas de reconhecimento alcançadas foram 87,13% ($\sigma = 0,54$) e 92,46% ($\sigma = 0,73$) para SIFT e SURF, respectivamente. Estas são superiores às alcançadas em outros trabalhos realizados com a mesma base de imagens e descritores clássicos de textura.

PALAVRAS-CHAVE: Visão computacional, textura, descritores baseados em pontos de atenção.

INTRODUÇÃO

Segundo Marchiori (1996), há uma permanente crise no setor florestal brasileiro, diante da devastação da vegetação nativa e extinção de madeiras nobres. O autor afirma que as florestas plantadas não atendem às necessidades e contemplam apenas uma parte muito pouco exigente que compreende a produção de lenha, carvão, chapas, celulose e assemelhados. Diante disto, exploram-se matas nativas, cada vez mais distantes dos grandes centros urbanos industrializados, o que justifica a necessidade de reconhecer os tipos de madeira e, conseqüentemente, sua origem no decorrer do processo de extração e transformação. Ou seja, é necessário que haja uma possibilidade de rastreamento entre o momento em que a planta é derrubada e o momento em que o produto final é obtido e comercializado (IOANNOU et al., 2009).

A diversidade dos tipos de madeira e conseqüente variação de sua aparência em termos de cores e texturas, além de propriedades químicas, físicas e mecânicas que as tornam próprias ou impróprias para certas aplicações e implicam em grandes diferenças em seu valor comercial (IOANNOU et al., 2009). Diante disto, a correta identificação de espécies florestais é de grande importância para comerciantes e para garantir que não haja extração irregular das florestas (MARTINS, 2014).

As principais características (folhas, frutos, cores e odores) se perdem ao se retirar os troncos das florestas e o reconhecimento se torna ainda mais difícil, principalmente devido à subjetividade dos especialistas humanos e ao processo repetitivo, monótono e demorado. Neste contexto, sistemas dotados de visão computacional tornam-se interessantes devido a uma série de vantagens providas por estes quando comparados ao processo realizado por especialistas humanos, principalmente devido a sua subjetividade, demanda de altos níveis de concentração, dentre outros (RADOVAN et al., 2001).

Alguns estudos têm focado a identificação de defeitos decorrentes de irregularidades externas aos troncos (CARON-DECLOQUEMENT, 2010), detecção e classificação de defeitos em placas de madeira (RADOVAN et al., 2001) e otimização de cortes de peças de madeira (CHAPLIN, 1999). Assim como este, outros trabalhos ainda focam a classificação de espécies florestais. Em seu trabalho, Tou et al. (2007) empregaram características extraídas de Matriz de Co-ocorrência em Níveis de Cinza (Gray-Level Co-occurrence Matrix - GLCM) para treinar um classificador baseado em Multi-layer Perceptron (MLP). As taxas de reconhecimento ficaram entre 60% e 72% para 5 diferentes espécies. Khalid et. al. (2008) trabalharam com 20 espécies florestais da Malásia e classificador baseado em GLCM e MLP (back-propagation). Foram utilizadas 1753 imagens (90% do total) para o treinamento dos classificadores e apenas 196 para o conjunto de testes, com taxas de até 95%. Weber e Martins (2017) e Wideck et al. (2017) empregaram diferentes estratégias para identificar as espécies da base apresentada na Seção 2.2. Suas taxas foram 85,25% ($\sigma=1,21$) e 80,20% ($\sigma=0,82$), respectivamente.

Especificamente no que se refere ao reconhecimento de madeira, a maior parte dos estudos focam imagens macroscópicas obtidas da seção transversal do tronco das plantas. O uso de imagens macroscópicas pode ser um fator limitante devido à riqueza das estruturas microscópicas invisíveis a olho nu ou com o auxílio de lupas e lentes com capacidade de ampliação limitada em cerca de 10 a 15 vezes. Neste sentido, a base de imagens empregada neste estudo possui imagens

microscópicas com aproximação ótica de 100 vezes, capturadas com o auxílio de um microscópio Olympus CX40. Este ponto também apoia-se na afirmação de Burger e Richter (1991) quanto ao fato de que muitos aspectos anatômicos da madeira, mesmo podendo ser identificados macroscopicamente, podem ter suas estruturas melhor identificadas sob um contexto microscópico.

Inserido neste tema, procura-se identificar espécies florestais utilizando imagens microscópicas da madeira e características baseadas em pontos de atenção.

MATERIAL E MÉTODOS

Este trabalho foca sistemas computacionais para reconhecimento de padrões, mais especificamente a construção de classificadores a partir de características texturais de imagens microscópicas de madeira. Os descritores considerados são amplamente empregados em sistemas dotados de visão computacional com objetivo de rastreamento de objetos em ambientes monitorados por câmeras.

RECONHECIMENTO DE PADRÕES

Um sistema para reconhecimento de padrões contempla as seguintes etapas: aquisição, pré-processamento, segmentação, extração de características e classificação. Cada etapa constitui um diferente contexto, possui diferentes níveis de complexidade e envolve conhecimentos específicos próprios, além daqueles inerentes ao domínio da aplicação.

Durante a aquisição, a imagem é capturada e armazenada utilizando sistemas de cores, resolução e quantização específicos. Devido à possibilidade de problemas decorrentes da aquisição, o pré-processamento foca a melhoria da qualidade da imagem. A segmentação constitui a etapa em que se extrai e identifica as áreas de interesse em uma imagem. A partir deste ponto, a extração de características permite identificar uma abstração (descriptor ou conjunto de características) adequada para a representação e a descrição das áreas de interesse. A classificação utiliza as representações anteriores para diferenciar os objetos nas imagens, atribuindo-lhe um identificador e um significado de acordo com suas características e descritores (PEDRINI e SCHWARTZ, 2008).

Este trabalho foca características extraídas de pontos de atenção. Os pontos de atenção são amplamente empregadas na identificação de objetos em problemas focados no rastreamento de objetos, principalmente no monitoramento de ambientes como aeroportos. No estudo aqui apresentado, as características extraídas dos pontos de atenção detectados possuem alto potencial devido aos padrões texturais decorrentes dos diferentes tipos celulares e suas frequências nas diversas espécies florestais (Figura 1).

BASE DE IMAGENS

A base de imagens foi produzida pelo Laboratório de Anatomia da Madeira, do curso de Engenharia Florestal da Universidade Federal do Paraná (UFPR) e publicada por Martins et. al. (2012), podendo ser requisitada para o

desenvolvimento de pesquisas no endereço eletrônico <http://web.inf.ufpr.br/vri/forest-species-database>. Esta base composta por 112 espécies florestais, cada uma com 20 amostras, num total de 2240 imagens. Considerando a divisão baseada no mais alto nível possível tem-se os 2 filios, Gimnospermas e Angiospermas. As imagens de espécies pertencentes a Gimnospermas ainda estão divididas em 2 classes, 2 ordens, 8 famílias, 23 gêneros e 37 espécies. Já as imagens de espécies pertencentes a Angiospermas estão divididas em 2 classes, 13 ordens, 22 famílias, 62 gêneros e 75 espécies.

As imagens (Figuras 1) foram adquiridas da seguinte maneira (MARTINS, 2014):

1. Extração de blocos com aproximadamente 2cm³ extraídos de peças maiores de tronco;
2. Cozimento dos blocos de madeira, por tempo variado de acordo com a espécie florestal, para seu amolecimento;
3. Realização de cortes histológicos (pequenas amostras) de madeira, com espessura aproximada de 0,025 milímetros de forma paralela à seção transversal ao tronco da planta, com o emprego de um micrótomo de deslizamento;
4. Coloração dos cortes histológicos de madeira pelo processo de tripla coloração com as substâncias acridina vermelha, crisoidina e azul de astra;
5. Desidratação em série alcoólica ascendente;
6. Montagem da lâmina para observação com a fixação dos cortes histológicos de madeira entre lâmina e lamínula; e
7. Coleta das imagens com microscópio Olympus modelo CX40, produzindo imagens com aproximação ótica de 100 vezes e resolução de 1024×768 pixels (Figura 1).

Figura 1 – Exemplos de texturas presentes em imagens da madeira



(a) *Cephalotaxus drupacea* Siebold & Zucc. (Taxodiaceae)



(b) *Chamaecyparis pisifera* (Siebold & Zucc.) Endl. (Cupressaceae)



(c) *Keteleeria fortunei* (A. Murray bis) Carrière (Pinaceae)



(d) *Copaifera trapezifolia* Hayne (Fabaceae)



(e) *Eschweilera coriacea* (DC.) S.A. Mori (Lecythidaceae)




(f) *Melia azedarach* L. (Maliaceae)


Fonte: Autoria própria

A Figura 2 apresenta exemplos de imagens microscópicas e macroscópicas de uma mesma espécie, nas quais pode-se perceber diferenças substanciais em seus padrões texturais. Neste sentido, Burger e Richter (1991) destacam que muitos aspectos anatômicos da madeira podem ser identificados macroscopicamente, mas que a observação de imagens microscópicas permite melhor identificação das estruturas apresentadas. Neste contexto, a abordagem baseada em padrões texturais permite que sejam utilizados os mesmos descritores (conjunto de características) empregados nos trabalhos com foco em imagens macroscópicas.

Figura 2 – Amostras de madeira de Araucária angustifolia (Bertol.) Kuntze (Araucariaceae)



(a) Microscópica



(b) Macroscópica


Fonte: Martins (2014).

SIFT

Transformação de Características Invariantes à Escala (Scale Invariant Feature Transform - SIFT) foi proposta por Lowe (1999), com o objetivo de identificar regiões de interesse e extrair características que permitam a comparação de imagens de objetos ou cenas capturadas de diferentes perspectivas. A detecção das regiões de interesse é realizada por um processo de filtragem em cascata tomando uma mesma imagem sob diferentes escalas (Figura 3). A cada iteração são tomadas novas amostras dos pixels da imagem, as quais são geradas pela interpolação bilinear dos pontos contidos numa vizinhança de raio 1,5 da escala imediatamente anterior. Este processo garante a estabilidade do descritor, pois tenta correlacionar uma região detectada em uma iteração com aquelas identificadas nas demais iterações. Conforme ilustra a Figura 3, cada ponto é comparado com oito vizinhos da escala corrente e nove vizinhos nas escalas imediatamente anterior e imediatamente posterior (LOWE, 1999; LOWE, 2004).

As regiões identificadas são caracterizadas por pontos que apresentam diferenças máximas e mínimas da função Gaussiana. Estas altas variações das regiões e escalas constituem as principais garantias para a estabilidade do descritor e para a invariância a translação, escala e rotação, além de invariância parcial a mudanças de iluminação e projeções 3D (LOWE, 1999; LOWE, 2004; VEDALDI e FULKERSON, 2008). Maiores detalhes quanto ao descritor SIFT podem ser obtidos em Martins (2014).

Figura 3 – Descritor SIFT: detecção das regiões de interesse




Fonte: Autoria própria

Embora o descritor SIFT considere um conjunto de 4×4 descritores computados em uma vizinhança 16×16 , a Figura 4(b) mostra apenas 2×2 descritores computados em uma vizinhança 8×8 (Figura 4(a)), o que não prejudica o entendimento. Os gradientes da Figura 4(a) são ponderados pela Gaussiana e acumulados em um histograma de orientação que sumariza os conteúdos em 4×4 sub-regiões (Figura 4(b)). O comprimento das arestas correspondendo à soma das magnitudes dos gradientes que pertencem àquela sub-região e que possuem a mesma direção (LOWE, 1999; LOWE, 2004; VEDALDI e FULKERSON, 2008).

Considerando os histogramas das 4×4 regiões e que cada um acumula a avaliação dos gradientes nas oito direções possíveis, cada ponto é representado por um vetor de características com 128 elementos. Além disso, geralmente são detectados centenas ou até milhares de pontos para cada imagem, todos potencialmente candidatos a compor o conjunto de suas características (LOWE, 1999; LOWE, 2004; VEDALDI e FULKERSON, 2008)

Figura 4 – Descritor SIFT: (a) aplicação da máscara na imagem e obtenção dos gradientes para cada direção na região sobreposta; (b) acúmulo dos gradientes para cada sub-região para as oito direções



Fonte: Martins (2014)

SURF

Proposto por Bay et al. (2006), o descritor Características Robustas Aceleradas (Speed-Up Robust Feature - SURF) apresenta semelhanças com relação ao SIFT e também permite detecção e descrição de regiões de interesse. Os autores afirmam que SIFT apresentou o melhor desempenho dentre os descritores analisados. Dentre suas vantagens, estão a capacidade de representar informações dos padrões espaciais e robustez a pequenas deformações e erros de localização das regiões detectadas. Porém, SIFT apresenta alta dimensionalidade em seu descritor e seu custo computacional dificulta seu uso para aplicações on-line (BAY et al., 2008).


Seguindo esta linha de raciocínio, Bay et al. (2006) propuseram um descritor com a metade do número de elementos do SIFT e baseado em matrizes Hessianas, as quais garantem maior estabilidade que detectores de cantos de Harris, além de apresentar boa performance em termos de tempo computacional e taxas de acerto. A proposta ainda inclui o uso de determinantes da matriz Hessiana, devido a sua robustez quanto a estruturas mal localizadas e alongadas. Basicamente, as estruturas detectadas pelo SURF estão situadas em regiões que maximizam o determinante da matriz Hessiana (BAY et al., 2006; BAY et al., 2008).

O uso do conceito de imagens integrais reduz drasticamente o tempo de computação devido aos filtros de convolução baseados em caixas (Figura 5). Por definição, cada elemento de uma imagem integral $I_{\Sigma(x,y)}$ representa a soma de todos os pixels da imagem original I contidos na região retangular situada entre a origem e (x, y) , conforme definição na equação a seguir. Diante disto, o cálculo da soma dos pixels contidos em uma região qualquer requer apenas três operações de adição (Figura 5), o tempo necessário para aplicar qualquer filtro à imagem permanece constante (independente de suas dimensões), todos os filtros são aplicados na imagem integral sem a necessidade da criação de novas imagens por meio de interpolações, os componentes de alta frequência são preservados e poderão ser recuperados independentemente da escala corrente (BAY et al., 2006; BAY et al., 2008). Maiores detalhes quanto ao descritor SURF podem ser obtidos em Martins (2014).

Semelhante à informação do gradiente extraída pelo SIFT, o descritor SURF representa a distribuição dos níveis de cinza na vizinhança do ponto de interesse (x, y) . Para isso, SURF considera a derivada de primeira ordem da wavelet de Haar. Uma vez detectada uma região de interesse, sua orientação é determinada pelas respostas da wavelet de Haar nas direções 'x' e 'y' para cada ponto contido na vizinhança do ponto de interesse. Tais respostas, após serem multiplicadas por pesos definidos pela função Gaussiana centrada no ponto de interesse, são representadas como pontos no espaço (Figura 6) e acumuladas considerando as direções horizontal e vertical e uma janela deslizante de orientação que abrange um ângulo de $\pi/3$. Por fim, o maior valor (vetor), considerando todas as possibilidades geradas durante o deslocamento da janela deslizante de orientação, determina a orientação do ponto de interesse (BAY et al., 2006; BAY et al., 2008).

$$I_{\Sigma(x,y)} = \sum_{i=0}^{i \leq x} \sum_{j=0}^{j \leq y} I(i,j) \quad (1)$$

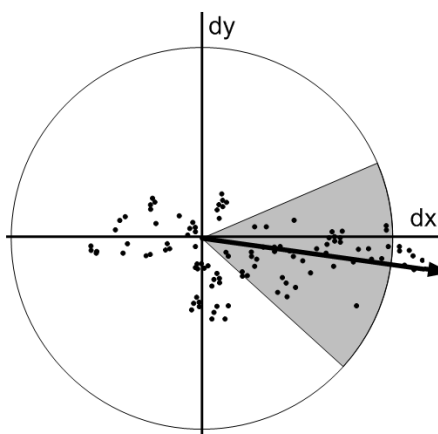
Figura 5 – Imagem integral: ilustração do cálculo da soma dos pixels contidos em uma sub-região DBCA da imagem com apenas três operações de adição



Fonte: Martins (2014)

Após identificar a região de interesse e sua orientação, o próximo passo consiste em calcular os valores do descritor. Para isso, define-se uma região quadrada (8×8) centrada no ponto de interesse e alinhada com a orientação previamente identificada. Para cada um dos 64 elementos, obtém-se a resposta da *wavelet* de Haar direções 'x' e 'y', denominadas respectivamente d_x e d_y . Para cada sub-região 2×2 , d_x , d_y , $|d_x|$ e $|d_y|$ são acumuladas separadamente, gerando 16 conjuntos com as quatro características ($\sum d_x$, $\sum d_y$, $\sum |d_x|$ e $\sum |d_y|$), num total de 64 elementos. Ao final, como SIFT, geralmente são detectados centenas ou até milhares de pontos para a imagem. Todos estes pontos são invariantes à translação, escala e rotação, além de ser parcialmente invariante a mudanças de iluminação e projeções 3D e potencialmente candidatos a compor o conjunto de características que descreve a imagem (BAY et al., 2006; BAY et al., 2008).

Figura 6 – Janela deslizante de orientação que com ângulo $\pi/3$



Fonte: Martins (2014)

Os autores também apresentaram a variante SURF-128, a qual duplica o número de características que compõem o vetor final. Esta variante acumula d_x e $|d_x|$ separadamente para $d_y < 0$ e $d_y \geq 0$, sendo o mesmo considerado para d_y e $|d_y|$ de acordo com o sinal de d_x . Embora esta variação garanta descritores mais

discriminantes, a maior dimensionalidade do vetor de características exige maiores recursos computacionais (BAY *et al.*, 2006; BAY *et al.*, 2008).

RESULTADOS E DISCUSSÃO

A extração dos descritores para SIFT e SURF empregou a implementação disponível no software MatLab 2016. Para SIFT foram testadas as implementações de Lowe (1999) e Vedaldi e Fulkerson (2008), seguindo exatamente a mesma metodologia e gerando vetores com 128 elementos para ambas. Para SURF foram consideradas as versões com 64 e 128 elementos. Como é de sua natureza, os detectores SIFT e SURF identificaram de dezenas a milhares de pontos de interesse em cada imagem. Diante da necessidade de se padronizar a quantidade de elementos que compunham os vetores de características utilizados no processo de treino e classificação, optou-se por utilizar momentos estatísticos. Esta abordagem é comumente utilizada com filtros de Gabor devido à criação de diferentes quantidades de imagens resultantes das convoluções dos filtros (YANG e NEWSAM, 2008; ZHU *et al.*, 2008).

Foram calculadas média, variância, obliquidade e curtose para cada coluna dos vetores gerados pelos descritores, dando origem a vetores com dimensões de 64 ou 128 elementos para cada um dos quatro momentos estatísticos utilizados. A partir dos vetores obtidos para os momentos estatísticos, foram analisadas diferentes combinações de concatenação entre eles, além do número de pontos de interesse identificados em cada imagem. Assim, para SIFT obteve-se vetores de características com dimensões entre 128 e 513 elementos. Já para SURF, os vetores gerados tiveram dimensões entre 64 e 257 para a versão original, enquanto que para SURF-128 estas variaram de 128 à 513.

Após a extração de características, realizou-se 3 repetições de cada experimento, sendo os resultados são expressos em termos de acurácia média e desvio padrão (σ) no intervalo [0..100]. Em cada repetição, criou-se aleatoriamente os conjuntos para treino e teste, os quais foram mantidos para todos os descritores. Estes eram compostos respectivamente por 14 e 6 imagens dentre as 20 existentes para cada uma das 112 espécies florestais que compõem a base empregada, com totais de 1568 imagens para treino e 672 para teste. O algoritmo de classificação utilizado foi SVM (Support Vector Machine), por meio da implementação LibSVM 3.2 disponibilizada no endereço eletrônico <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>. Dentre as possibilidades disponibilizadas pela biblioteca, os melhores resultados foram obtidos com a função de base radial Gaussiana e uma busca gulosa para encontrar os melhores parâmetros C e γ . A normalização dos dados considerou a escala linear de cada atributo dos vetores de dissimilaridade no intervalo [-1,+1].

A combinação com o número de pontos detectados em cada imagem e o momento média, num total de 129 elementos no vetor final de características, gerou os melhores resultados para as duas implementações testadas para SIFT. Porém, a versão disponibilizada por Vedaldi e Fulkerson (2008) garantiu resultados superiores de 87,13% ($\sigma=0,54$), com 5,25 pontos percentuais de diferença. Para SURF, as melhores taxas, 92,46% ($\sigma=0,73$), foram alcançadas com a versão SURF-128, com a combinação do número de pontos de interesse identificados na

imagem e dos momentos média, variância e obliquidade, num total de 385 elementos no vetor de características.

A análise das matrizes de confusão indicou que a maior parte das confusões ocorre entre espécies próximas entre si, mas sem que haja concentração de erros de classificação para espécies específicas ou entre pares de espécies. Neste sentido, quando há erros de classificação entre amostras de duas espécies, normalmente tais erros não se mantêm no nível taxonômico de gênero. Esta característica se apresenta de forma generalizada nas transições entre cada nível e seu(s) nível(is) superior(es), conforme sequência espécie, gênero, família, ordem, classe e filo.

Considerando os trabalhos de Weber e Martins (2017) e Wideck, Silva e Martins (2017) com a mesma base de imagens e metodologias semelhantes para a composição dos conjuntos de treino e teste, os melhores resultados apresentados são superiores em 7,21 e 12,26 pontos percentuais, respectivamente, o que demonstra o potencial dos descritores baseados em pontos de atenção SIFT e SURF.

CONCLUSÕES

Este trabalho avaliou a aplicação de classificadores construídos a partir dos descritores baseados em pontos de atenção SIFT e SURF ao problema de reconhecimento de espécies florestas por meio de imagens microscópicas de sua madeira. Os resultados obtidos são superiores aos alcançados em outros trabalhos realizados com a mesma base de imagens utilizando descritores texturais clássicos. Nossos melhores resultados foram 87,13% ($\sigma=0,54$) e 92,46% ($\sigma=0,73$) para SIFT e SURF, respectivamente.

Na sequência busca-se por novos descritores e algoritmos de seleção e combinação de classificadores na tentativa de melhorar os resultados obtidos, bem como sua aplicação e validação em outros problemas que demandem por sistemas dotados de visão computacional. Uma alternativa para a concatenação dos vetores de características realizada neste trabalho, poderia ser a construção de modelos independentes a partir dos vetores de características de cada momento estatístico. A partir destes, poder-se-ia selecionar e combinar alguns destes modelos. Um estudo comparativo de ambas as abordagens foi apresentada por Martins et al. (2012), o qual demonstrou a superioridade desta nova abordagem.

Use of SIFT and SURF Descriptors for the Identification of Forest Species

ABSTRACT

There are different types of wood, each one provided by a different forest specie. Identifying forest species is an important issue because of their different wood properties and commercial values, as well as to avoid the use of wood extracted from a range of species in extinction risk. This paper uses microscopic images and applies descriptors based on keypoint-features to build classifiers to distinguish forest species. Our best recognition rates are 87.13% ($\sigma = 0.54$) and 92.46% ($\sigma = 0.73$), achieved by using SIFT and SURF, respectively. They are superior to those achieved by using traditional-texture-feature-based classifiers.

KEYWORDS: Computer vision, texture, keypoint-based features.

AGRADECIMENTOS

À Universidade Tecnológica Federal do Paraná e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro.

REFERÊNCIAS

BAY, H.; TUYTELAARS, T.; e VAN GOOL, L. (2006) "SURF: Speeded up robust features". In ECCV, p. 404-417.

BAY, H.; ESS, A.; TUYTELAARS, T.; e VAN GOOL, L. (2008) "Speeded-up robust features (SURF)". *Compute Vision. Image Understanding*, v. 110, n. 3, p. 346-359.

BURGER, L.M.; RICHTER, H.G. "Anatomia da Madeira". São Paulo: Nobel, 1991.

CARON-DECLOQUEMENT, A. (2010) "Extractives from Sitka spruce". Tese de Doutorado, Department of Chemistry, University of Glasgow.

CHAPLIN, R.I.; HODGSON, R.M.; GUNETILEKE, S. (1999) "Automatic wane detection in the images of planks using a neural network". In 5th Intern. Symposium on Signal Processing and its Applications, v. 2, p. 657-659.

IOANNOU, K.; BIRBILIS, D.; LEFAKIS, P. (2009) "A pilot prototype decision support system for recognition of greek forest species". In *Operational Research*, v. 3, n. 9, p. 141-152.

KHALID, M.; LEE, E.L.Y.; YUSOF, R.; NADARAJ, M. (2008) "Design of an intelligent wood species recognition system". In *International Journal of Simulation Systems, Science & Technology Special Issue on: Artificial Intelligence*, p. 9-17.

LOWE, D.G. (1999) "Object recognition from local scale-invariant features". In *Proc. of the Int. Conference on Computer Vision*, v. 2, p. 1150-, Washington, DC, USA.

LOWE, D.G. (2004) "Distinctive image features from scale-invariant keypoints". In *Int. Journal of Computer Vision*, v. 60, n. 2, p. 91-110.

MARCHIORI, J. N. C. "Dendrologia das Gimnospermas". Santa Maria - RS: Editora da UFSM, 1996.

MARTINS, J.G.; OLIVEIRA, L.E.S.; NISGOSKI, S.; SABOURIN, R. (2012) "A database for automatic classification of forest species". In Machine Vision and Applications, v. 24, p. 567-578.

MARTINS, J.G.; OLIVEIRA, L.E.S.; SABOURIN, R. (2012) "Combining textural descriptors for forest species recognition". In IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society, p. 1483-1488.

MARTINS, J.G. (2014) "Identificação de Espécies Florestais utilizando Seleção Dinâmica de Classificadores no Espaço de Dissimilaridade". Tese de Doutorado, Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, Curitiba-PR.

PEDRINI, H.; SCHWARTZ, W.R. (2008) "Análise de Imagens Digitais: princípios, algoritmos e aplicações". São Paulo: Thomson Learning.

RADOVAN, S.; GEORGE, P.; PANAGIOTIS, M.; MANOS, G.; ROBERT, A.; IGOR, D. (2001) "An approach for automated inspection of wood boards". In Int. Conference on Image Processing, n. 1, p. 798-801.

TOU, J.Y.; LAU, P.Y.; TAY, Y.H. (2007) "Computer vision-based wood recognition system". In Intern. Workshop on Advanced Image Technology, p. 197-202.

VEDALDI, A.; FULKERSON, B. (2008) "VLFeat: An Open and Portable Library of Computer Vision Algorithms". URL: <http://www.vlfeat.org/>.

YANG, Y.; NEWSAM, S. (2008) "Comparing SIFT descriptors and gabor texture features for classification of remote sensed imagery". In 15th IEEE International Conference on Image Processing, p. 1852-1855.

WEBER, E.F.; MARTINS, J.G. (2017) "Descritores de Textura aplicados ao Reconhecimento de Espécies Florestais". In V ENDICT - Encontro de Iniciação Científica, Toledo, p. 1-12.

WIDECK, T.A.; SILVA, U.S. MARTINS, J.G. (2017) "Reconhecimento de Espécies Florestais baseado em uma Estratégia 'Dividir para Conquistar'". In V ENDICT - Encontro de Iniciação Científica, Toledo, p. 1-12.

ZHU, J.; HOI, S.C.H.; LYU, M.R.; YAN, S. (2008) "Near-duplicate keyframe retrieval by nonrigid image matching", In 16th ACM Int. Conference on Multimedia, p. 41-50.

Recebido: 01 out. 2018.

Aprovado: 31 dez. 2018.

DOI: <http://dx.doi.org/10.3895/rcaa.v1n2.9166>.

Como citar:

DIAS, J. W.; MARTINS, J. G. Utilização dos Descritores SIFT e SURF para a Identificação de Espécies Florestais. **Computação Aplicada ao Agronegócio**, Medianeira, v. 1, n. 2, p. 13-26, ago./dez. 2018. Disponível em: <<https://periodicos.utfpr.edu.br/rcaa/article/view/9166>>. Acesso em: dezembro/2018.

Correspondência:

Jefferson Gustavo Martins

Rua Cristo Rei, 19, Vila Becker, Toledo, PR, Brasil.

Direito autoral:

Este artigo está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.

