

Combinação de Classificadores em Dois Níveis aplicada ao Reconhecimento de Espécies Florestais

RESUMO

A dificuldade de identificação da espécie florestal da qual a madeira foi extraída aumenta na medida em que a madeira é processada e seus derivados se distanciam do local de extração. Questões comerciais e ecológicas tornam tal identificação importante. Este trabalho foca a utilização de dois conhecidos descritores texturais na construção dos classificadores para distinguir as espécies florestais. Tais classificadores têm suas decisões combinadas em dois níveis para compor a decisão final do sistema. Os melhores resultados alcançados foram 93,03% ($\sigma = 0,54$) e são superiores aos alcançados em outros trabalhos realizados com a mesma base de imagens.

PALAVRAS-CHAVE: Visão computacional, descritores texturais, combinação de classificadores.

Thiago Auler Wideck
wideck@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

INTRODUÇÃO

Independente da forma (bruta ou beneficiada) em que a madeira se apresentar, o reconhecimento da espécie florestal, ou pelo menos de seu agrupamento mais próximo, é de grande importância devido às diferentes propriedades apresentadas por cada espécie e necessárias para cada diferente produto. A atual visão quanto à conservação e ao aproveitamento racional dos recursos naturais também se apresenta como fator importante no apoio à identificação das espécies florestais que originaram uma determinada peça de madeira e à otimização de tais recursos tal que se tenha o mínimo de desperdício possível, principalmente pelo fato de que esta matéria-prima constitui cerca de 40% dos custos de produção. Esta nova visão é fruto da escassez de recursos e consequente aumento de preços que, segundo Moody e Klinkhachorn (1980), foram quadruplicados entre 1955 e 1995.

Com o advento da globalização e a redução da disponibilidade de matéria-prima, a comercialização de madeira se destaca como uma importante área de negócios. Compradores devem se certificar de que estão comprando o material correto enquanto agências supervisoras precisam garantir que não haja madeira extraída irregularmente das florestas. Busca-se então evitar possíveis fraudes decorrentes de misturas de diferentes tipos de madeira e da tentativa de extração e exportação de madeira proveniente de espécies sujeitas à extinção. Ioannou et al. (2009) destacam a diversidade dos tipos de madeira existentes, a grande variação de sua aparência em decorrência de suas cores e texturas, além de propriedades químicas, físicas e mecânicas que as tornam próprias ou impróprias para certas aplicações e determinam seu valor comercial.

A identificação da espécie florestal da qual a madeira foi extraída se torna mais difícil à medida que a madeira se distancia do ponto de sua origem. Características (folhas, frutos, sementes, cores, odores, dentre outras) se perdem na medida em que os troncos são retirados das florestas e processados por meio de cortes. Além disso, o trabalho realizado por especialistas humanos pode ser influenciado por subjetividade e pelo processo ser repetitivo, monótono e demorado (RADOVAN *et al.*, 2001). Neste contexto, sistemas dotados de visão computacional tornam-se muito interessantes a esta área comercial devido a uma série de vantagens. Tou *et al.* (2007) empregaram 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 das espécies florestais ficaram entre 60% e 72% para cinco diferentes espécies. Weber e Martins (2017) e Wideck *et al.* (2017) empregaram diferentes estratégias para identificar as espécies florestais da base apresentada na Seção 2.2. Seus melhores resultados foram 85,25% ($\sigma = 1,21$) e 80,20% ($\sigma = 0,82$), respectivamente.

Este trabalho foca na identificação de espécies florestais por meio de imagens microscópicas de sua madeira e a combinação de decisões parciais de classificadores em dois níveis.

MATERIAL E MÉTODOS

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.

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 – Imagens obtidas a partir da madeira de diferentes espécies florestais e as caracterizações texturais em decorrência de suas propriedades químicas, físicas e mecânicas



(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*)

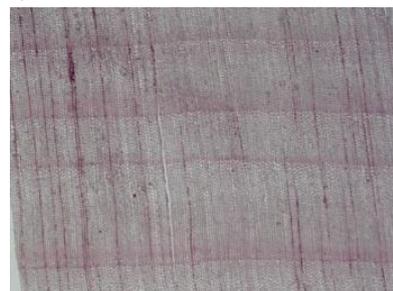
Fonte: Autoria própria

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.



(a)



(b)

Fonte: Martins (2014, p. 157)

GLCM

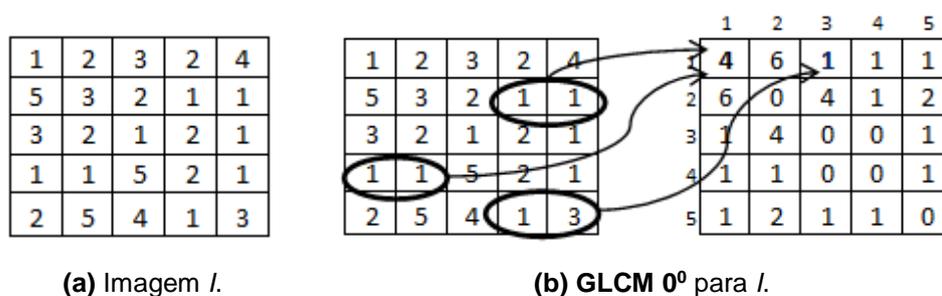
Matriz de Coocorrência de Níveis de Cinza (Gray Level Co-occurrence Matrix – GLCM) é um método estatístico proposto por Haralick para caracterizar a relação entre os níveis de cinza dos pixels das imagens e sua distribuição espacial. As repetições dos padrões proveem medidas quanto a propriedades como rugosidade, suavidade e regularidade sob diferentes perspectivas (HARALICK, 1979).

Formalmente, Haralick fundamenta GLCM pela seguinte definição: dada uma imagem I com dimensões $N_r \times N_c$, tal que $L_r = [1, N_r]$ e $L_c = [1, N_c]$ representam os possíveis valores para linhas e colunas, respectivamente; e $L = [1, N_g]$ o conjunto de N_g níveis de cinza quantizados de I . I pode ser representada como uma função que associa algum nível de cinza de G a uma célula ou par de coordenadas de $L_r \times L_c$. Ou seja, $I : L_r \times L_c \rightarrow G$. Haralick define o uso de uma matriz $N_g \times N_g$ para representar a frequência P_{ij} , tal que um pixel p_i possua nível

de cinza n_i e um pixel vizinho a p_j (p_j - a uma distância d e um ângulo α) possua nível de cinza n_j (HARALICK, 1979).

Servindo como ilustração das definições anteriores, a GLCM da Figura 3(b) foi gerada a partir da imagem da Figura 3(a) com $N_g = 5$, distância $d = 1$ e direção 0 grau. Embora a proposta inicial tenha definido 14 elementos, diferentes trabalhos consideram diferentes subconjuntos destes e afirmam haver correlações ou redundâncias entre as informações provenientes deles. Assim, aqui foram empregadas apenas seis das características propostas por Haralick (1979): energia, contraste, entropia, homogeneidade, probabilidade máxima e momento de terceira ordem. Cada um dos seis descritores citados foram extraídos para os quatro ângulos de 0, 45, 90 e 135 graus. Assim, o vetor de características final ficou com um total de 24 elementos (HARALICK, 1979). Nas Equações 1-6, N_g representa o número de diferentes níveis de cinza da imagem; i e j são os níveis de cinza e servem como índices da GLCM; e $P(i, j)$ é a probabilidade de co-ocorrência do par (i, j) de níveis de cinza.

Figura 3 – Geração de GLCMs



Fonte: Adaptado de Martins (2014, p. 47)

$$\text{Energia} = \sqrt{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \{P(i, j)\}^2} \quad (1)$$

$$\text{Contraste} = \sqrt{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} |i - j|^2 P(i, j)} \quad (2)$$

$$\text{Entropia} = - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j) \log(P(i, j)) \quad (3)$$

$$\text{Homogeneidade} = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{P(i, j)}{1 + |i - j|^2} \quad (4)$$

$$\text{Probabilidade Máxima} = \max_{i=0}^{N_g-1} P(i, j) \quad (5)$$

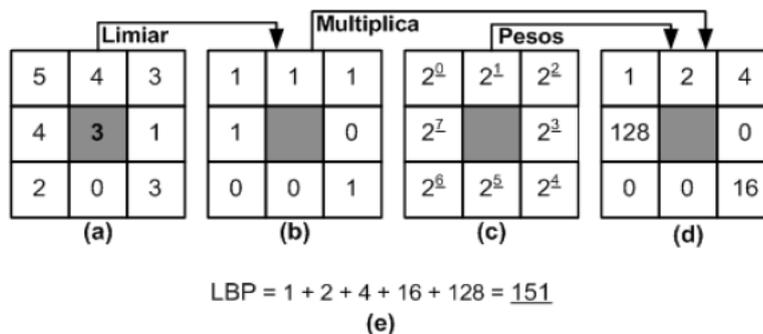
$$\text{Momento de Terceira Ordem} = \sqrt{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} |i-j|^3 P(i,j)} \quad (6)$$

LBP

Introduzido em 1996, o Padrão Binário Local (*Local Binary Pattern* – LBP) é um método estrutural e constitui uma medida complementar para contraste local de uma imagem em níveis de cinza. Invariante a mudanças monotônicas dos níveis de cinza, em sua versão original considera vizinhança-8 e distância um para o pixel central (x_c, y_c) de uma máscara com dimensões 3×3 (Figura 4 (a)) (MÄENPÄÄ et. al., 2000)

Cada ponto da imagem é tomado como sendo o ponto central (x_c, y_c), cujo valor serve como limiar na comparação com cada um de seus vizinhos (x_i, y_i). Desta comparação gera-se uma cadeia de zeros e uns (Figura 4 (b)), pois cada vizinho assume o valor um se seu conteúdo for maior ou igual ao do ponto central (x_c, y_c) e zero caso contrário. A organização dessa cadeia considera a posição relativa j de cada vizinho, iniciando do canto superior esquerdo com valor zero e circundando o ponto central no sentido anti-horário (Figura 4 (c)). Ao ser tomada como uma representação em base dois e convertida para a base dez, tem-se o padrão que representa a região sobreposta pela máscara (Figura 4 (d-e)) (MÄENPÄÄ et. al., 2000).

Figura 4 – Cálculo do padrão LBP



Fonte: Martins (2014, p. 34).

Após gerar os padrões para todos os pontos da imagem, as frequências destes padrões são contabilizadas por meio de um histograma com um total de 2^P padrões para P vizinhos. A consideração de $P = 8$ (Figura 4 (a)) gera um total de 256 padrões de transição de bits (Figura 4 (b)). Dentre estes padrões, apenas 58 atendem a definição de uniformidade, isto é, a ocorrência de, no máximo, duas transições do valor zero para um e vice-versa. Todos os demais padrões são contabilizados juntos, levando a um total de 59 valores para o descritor denominado LBP uniforme (LBP^{u2}). Os melhores resultados foram obtidos para vizinhança-8 e distância dois com LBP^{u2}

COMBINAÇÃO DE CLASSIFICADORES

A grande variedade de problemas, representações de dados e algoritmos de classificação geraram também diferentes alternativas de classificadores. Cada uma apresenta vantagens e desvantagens em diferentes situações. Mesmo diante do emprego de um conjunto de diferentes classificadores a um único problema, cada um poderá apresentar performance superior aos demais em diferentes momentos. Estes fatos impossibilitam a escolha e o emprego de um único classificador e conduzem aos sistemas com múltiplos classificadores (JAIN et al., 2000; KHREICH, 2011).

Dentre as regras de combinação das saídas dos classificadores, as mais conhecidas são: voto majoritário, borda count, soma, média, produto, máximo e mínimo. Em cada caso, a aplicação dessas regras poderá gerar resultados completamente diferentes de outra e influenciará nas taxas resultantes. Além disso, exceto para as duas primeiras regras, os classificadores devem fornecer saídas com probabilidades (JAIN et al., 2000; KITTLER et al., 1998).

As Equações 7 a 14 apresentam as fórmulas para as regras anteriormente mencionadas. Nelas, s_q é a amostra a ser classificada, V_q é o vetor de características extraídas para s_q e empregado por cada um dos K classificadores C_k ($k=[1,K]$), Cl_l representa cada uma das m classes ($l=[1,m]$) consideradas no domínio de aplicação, $p(V_q | Cl_l)$ é a função de densidade probabilidade, $P(Cl_l)$ é a probabilidade de ocorrência *a priori* de $p(V_q | Cl_l)$, $P(Cl_l | V_q)$ é a probabilidade *a posteriori*. Todas as regras consideram a teoria Bayesiana, associando s_q à classe predita Cl_p com o maior valor para a probabilidade *a posteriori* dentre todas as classes Cl_l (Equação 7) (JAIN et al., 2000; KITTLER et al., 1998).

$$s_q \rightarrow Cl_p \quad \text{Se} \quad P(Cl_p | V_q) = \max_{l=1}^m P(Cl_l | V_q) \quad (7)$$

O voto majoritário constitui a regra mais simples e conhecida para combinar classificadores, sendo que cada classificador representa um voto (Equação 8). Para cada amostra s_q , os votos são totalizados para cada classe Cl_l e a que obtiver o maior número de votos se torna a classe predita Cl_p para s_q . De acordo com a Equação 9, o voto do classificador C_k é atribuído à classe Cl_l com a maior probabilidade *a posteriori*. Sua principal vantagem está em sua simplicidade e facilidade em ser empregada, além de poder ser utilizada quando as saídas dos classificadores proveem apenas o rótulo das classes preditas por cada um (JAIN et al., 2000; KITTLER et al., 1998).

$$s_q \rightarrow Cl_p \quad \text{se} \quad \sum_{k=1}^K \Delta_{pk} = \max_{l=1}^m \sum_{k=1}^K \Delta_{lk} \quad (8)$$

$$\Delta_{lk} = \begin{cases} 1, & \text{se } P(Cl_{lk} | V_q) = \max_{j=1}^m P(Cl_{jk} | V_q) \\ 0, & \text{caso contrário} \end{cases} \quad (9)$$

A regra *Borda count* foi proposta por Black (1958) e necessita que as saídas dos classificadores forneçam uma lista ordenada com as possíveis classes e, possivelmente, as probabilidades (*ranking*) para cada uma destas classes. Para

cada posição da lista é determinado um valor ou pontuação, o qual será atribuído à classe que ficar posicionada naquele ponto da lista por um determinado classificador. Ao final do processo, a combinação se dá pela soma destes pontos e a classe que acumular mais pontos determinará a classe predita Cl_p . No caso de haver a determinação de um ranking com probabilidades pelos classificadores, estas probabilidades deverão ser totalizadas e a classe que obtiver maior valor será a classe predita Cl_p (BLACK, 1958).

Nesta regra de combinação a classe correta não necessariamente precisa aparecer como a primeira do *ranking*, mas apenas ocupar posições próximas à primeira na maioria das saídas dos classificadores. A Figura 5 apresenta um exemplo quanto à aplicação desta regra para cinco classes e três classificadores (sem probabilidades). Uma pontuação entre um e cinco, identificada pelas colunas 'Rank', é atribuída para cada classe de acordo com a posição determinada pelo classificador. Ao totalizar a pontuação destes classificadores nas Figura 5(a-c)), o maior número de pontos foi acumulado pela classe dois (Figura 5(d)). Esta é definida como "vencedora", mesmo com apenas um dos classificadores a identificando como tal Black (1958).

Figura 5 – Borda count

Classificador 1		Classificador 2		Classificador 3		Resultado	
Classe	Rank	Classe	Rank	Classe	Rank	Classe	Rank
1	5	4	5	2	5	2	13
2	4	2	4	4	4	4	11
3	3	5	3	3	3	1	9
4	2	1	2	1	2	3	7
5	1	3	1	5	1	5	5

Fonte: Martins (2014, p. 59).

A regra Produto combina as probabilidades finais para cada classe Cl_i por meio do produto das probabilidades associadas às saídas dos classificadores para esta classe (Equação 10) (JAIN *et al.*, 2000; KITTLER *et al.*, 1998).

$$s_q \rightarrow Cl_p \quad \text{se} \quad \prod_{k=1}^K P(Cl_{pk} | V_q) = \max_{l=1}^m \prod_{k=1}^K P(Cl_{lk} | V_q) \quad (10)$$

A Soma combina as probabilidades finais para cada classe Cl_i pelo somatório das probabilidades associadas às saídas dos classificadores C_k (Equação 11). De forma semelhante, a Média (Equação 12) calcula a média entre as probabilidades associadas às saídas dos classificadores para cada classe Cl_i . Estas regras geralmente apresentam bons resultados e semelhanças entre os mesmos (JAIN *et al.*, 2000; KITTLER *et al.*, 1998).

$$s_q \rightarrow Cl_p \quad \text{se} \quad \sum_{k=1}^K P(Cl_{pk} | V_q) = \max_{l=1}^m \sum_{k=1}^K P(Cl_{lk} | V_q) \quad (11)$$

$$s_q \rightarrow Cl_p \quad \text{se} \quad \frac{1}{K} \sum_{k=1}^K P(Cl_{pk} | V_q) = \max_{l=1}^m \frac{1}{K} \sum_{k=1}^K P(Cl_{lk} | V_q) \quad (12)$$

Máximo (Equação 13) é uma regra que define como vencedora a classe que apresentar a maior probabilidade dentre todos os classificadores. Uma classe poderá ser declarada vencedora mesmo que apresente bom desempenho apenas para um dos classificadores. Já a regra de combinação Mínimo (Equação 14), inicialmente obtém o menor valor atribuído por cada classificador para cada uma das classes. A partir destes valores, define-se a classe vencedora selecionando-se a que apresentar a maior probabilidade dentre todos os classificadores (JAIN et al., 2000; KITTLER et al., 1998).

Ao combinar classificadores há ainda o conceito de Oráculo. Oráculo indica o limite superior para as taxas de todo o conjunto de classificadores, pois seu cômputo considera que o melhor classificador sempre seja selecionado (KO et al., 2007).

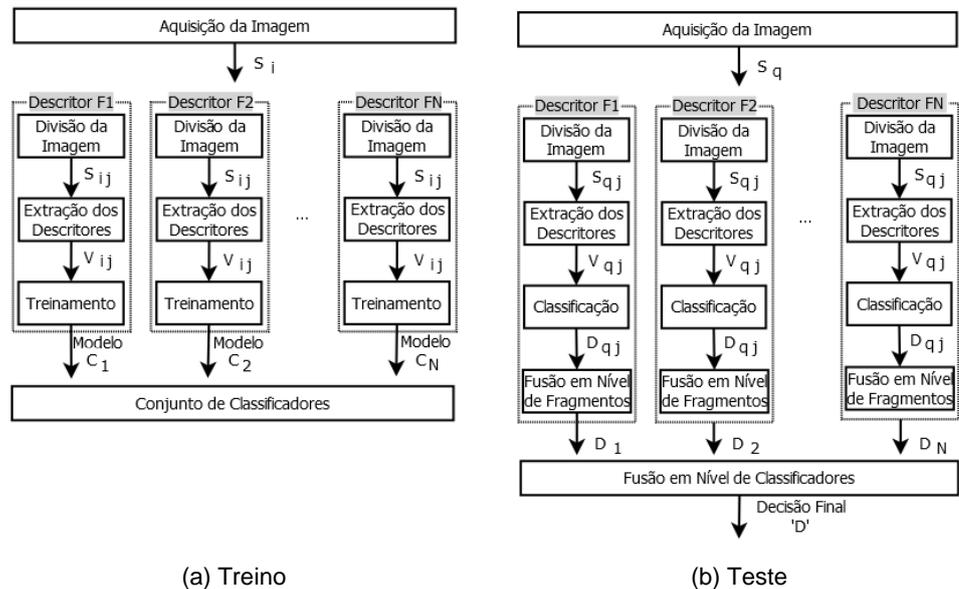
$$s_q \rightarrow Cl_p \quad \text{se} \quad \max_{k=1}^K P(Cl_{pk} | V_q) = \max_{l=1}^m (\max_{k=1}^K P(Cl_{lk} | V_q)) \quad (13)$$

$$s_q \rightarrow Cl_p \quad \text{se} \quad \min_{k=1}^K P(Cl_{pk} | V_q) = \max_{l=1}^m (\min_{k=1}^K P(Cl_{lk} | V_q)) \quad (14)$$

MODELO DE CLASSIFICAÇÃO PROPOSTO

A Figura 6 ilustra o modelo proposto, o qual considera que as imagens que compõem os conjuntos de treino e teste já estejam separadas. A criação dos modelos de classificação C_k para os descritores F_k ocorre segundo a Figura (6.a). Cada imagem S_i é recortada e seus recortes S_{ij} são utilizados na extração dos vetores de características V_{ij} . O conjunto de V_{ij} são utilizados na construção dos classificadores C_k . Efetivamente, tais modelos não classificam as imagens diretamente, mas seus fragmentos.

Figura 6 – Modelo Proposto: (a) construção dos modelos de classificação; (b) identificação da espécie florestal para uma nova imagem S_q

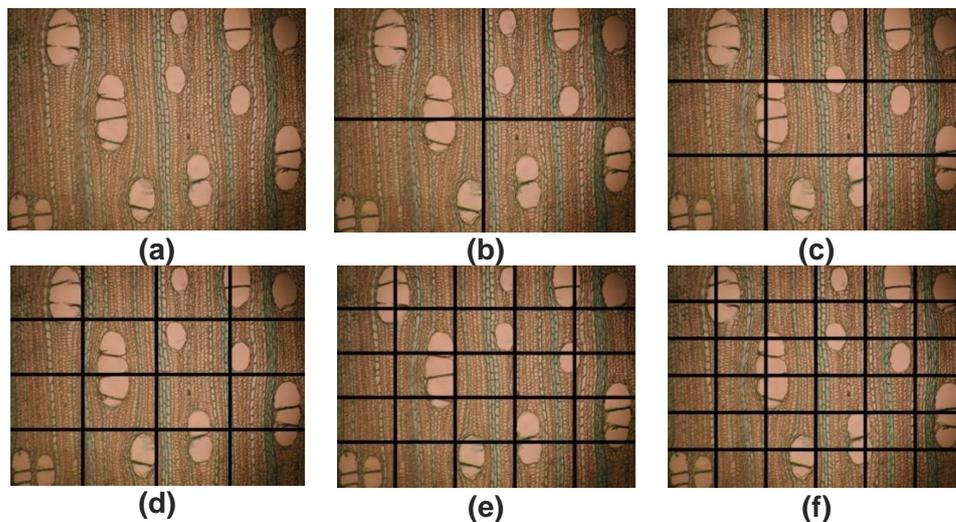


Fonte: Autoria própria

A Figura (6.b) apresenta o processo proposto para a classificação de uma imagem qualquer S_q . S_q é recortada e seus recortes S_{qj} são utilizados na extração dos vetores de características V_{qj} . O conjunto de V_{qj} são classificados pelos classificadores C_k , gerando uma decisão parcial D_{qj} em nível de fragmentos. As decisões parciais D_{qj} são combinadas. Como resultado, obtém-se novas decisões parciais D_k em nível de classificador. No segundo nível de fusão, as decisões D_k são combinadas para gerar a decisão final D para cada imagem original. A combinação dos classificadores em ambos os níveis empregou as regras voto majoritário, borda *count*, soma, média, produto, máximo e mínimo.

A Figura 6 apresenta um contexto genérico em termos do quantitativo de classificadores e fragmentos. Neste estudo, foram utilizados dois classificadores construídos a partir dos descritores GLCM e LBP, assim como seis diferentes configurações de tamanhos de fragmentos (Figura 7). No primeiro experimento tinha-se apenas um fragmento dado pela imagem original (Figura 7(a)). Especificamente para este caso, ocorre apenas uma fusão em nível de classificadores. Os outros cinco cenários consideraram 4, 9, 16, 25 e 36 fragmentos (Figura 7(b-f)). Nestes casos, conseqüentemente, houve fusões em nível de fragmentos e em nível de classificadores, conforme modelo da Figura 6. Destacase que os testes com a redução das dimensões dos fragmentos foram encerrados mediante a estabilização das taxas ou sua piora em relação aos obtidos com fragmentos maiores, conforme discutido adiante.

Figura 7 –. Diferentes recortes realizados para gerar os fragmentos a partir das imagens originais



Fonte: Autoria própria

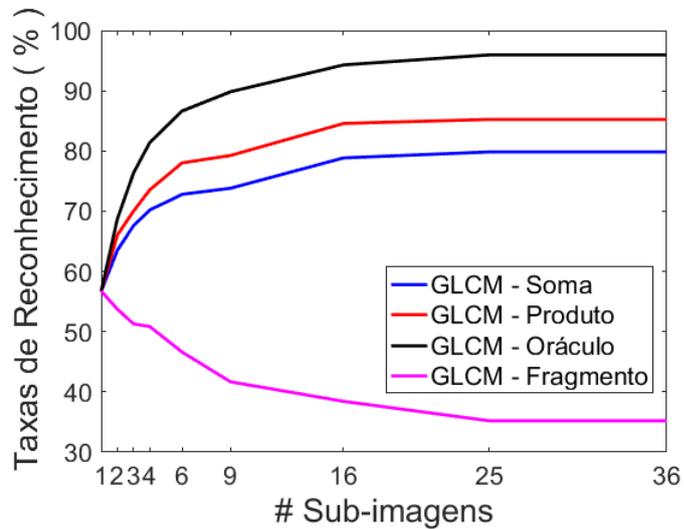
Para a classificação dos elementos foi empregado SVM (*Support Vector Machine*) por meio da implementação LibSVM 3.2 disponibilizada no endereço eletrônico <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>, pois o mesmo alcançou o melhor desempenho em experimentos anteriores. Dentre as possibilidades disponibilizadas 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 no intervalo $[-1,+1]$.

RESULTADOS E DISCUSSÃO

Para evitar divisões para os conjuntos de treino e teste que pudessem influenciar no processo e nos resultados, foram realizadas três repetições de cada experimento a partir das quais se obteve a média e o desvio padrão (σ) apresentados. Em cada repetição, os conjuntos para treino e teste eram compostos respectivamente por 14 e 6 imagens escolhidas aleatoriamente dentre as 20 existentes para cada uma das 112 espécies florestais, com totais de 1568 imagens para treino e 672 para teste.

A Figura 7 justifica esta abordagem e demonstra que à medida que os fragmentos ficam menores, seus padrões texturais ficam mais homogêneos em cada fragmento, mas também ficam mais heterogêneos entre os fragmentos. Diante disto, é esperada uma redução gradativa da taxa de reconhecimento dos fragmentos de forma individual (Figuras 8 e 9). Porém, os classificadores conseguem lidar melhor com tal situação e a combinação das decisões parciais dos fragmentos produz resultados finais bem superiores (Figuras 8 a 10).

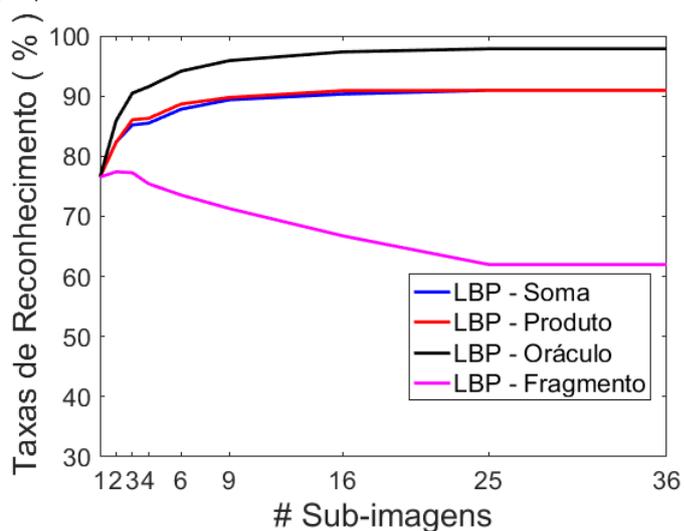
Figura 8 –. GLCM: taxas de reconhecimento obtidas para os fragmentos das imagens individualmente e as combinações de suas decisões no primeiro nível do modelo de classificação proposto



Fonte: Autoria própria

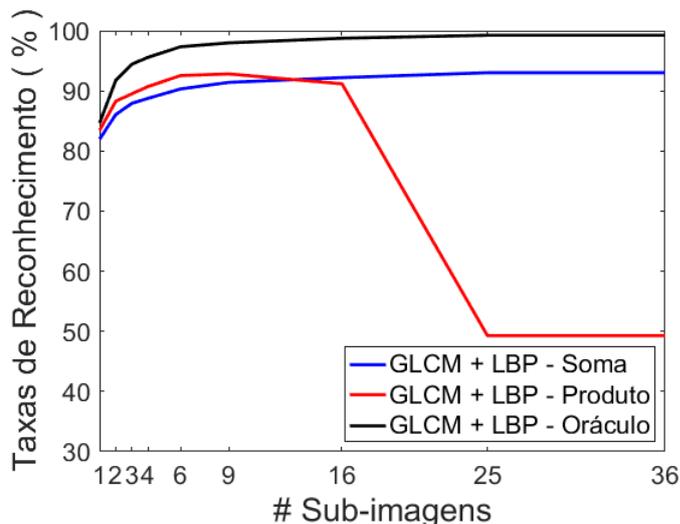
Para as imagens originais alcançou-se taxas de reconhecimento de 56,74% ($\sigma = 1,34$) e 76,54% ($\sigma = 1,11$) para GLCM e LBP, respectivamente, as quais são compatíveis com os resultados apresentados na literatura para esta base de imagens. Os melhores resultados decorrentes das combinações em primeiro nível chegaram a 85,25% ($\sigma = 1,21$) para GLCM com a regra Produto e 90,96% ($\sigma = 0,55$) para LBP com a regra Soma. Já neste ponto houve um salto nas taxas, obtendo-se melhoras significativas de mais de 28,5 e 14,4 pontos percentuais para GLCM e LBP, respectivamente.

Figura 9 – LBP: taxas de reconhecimento obtidas para os fragmentos das imagens individualmente e as combinações de suas decisões no primeiro nível do modelo de classificação proposto



Fonte: Autoria própria

Figura 10 – Taxas de reconhecimento obtidas para as combinações das decisões parciais dos classificadores GLCM e LBP no segundo nível do modelo de classificação proposto



Fonte: Autoria própria

As decisões parciais obtidas com a fusão das previsões para os fragmentos de cada imagem foram novamente combinadas no segundo nível (Figura 10). As melhores taxas de acerto chegaram a 93,03% ($\sigma=0,54$) para a regra Soma. Novamente houve melhoria das taxas anteriores. Considerando os resultados obtidos para as imagens inteiras, houve melhoras de cerca de 36,3 e 16,5 pontos percentuais com relação a GLCM e LBP, respectivamente. Ao se considerar os resultados obtidos no primeiro nível de fusão, as melhoras foram de cerca de 7,8 e 2,1 pontos percentuais com relação a GLCM e LBP, respectivamente.

A Tabela 1 apresenta um resumo de alguns dos resultados obtidos para esta base de imagens. Tomando os trabalhos de Weber e Martins (2017) e Wideck *et al.* (2017), os resultados apresentados são superiores em 7,78 e 12,83 pontos percentuais, respectivamente. Tal superioridade demonstra o potencial da estratégia proposta. Destaca-se aqui que o trabalho desenvolvido por Weber e Martins (2017) corresponde exatamente ao primeiro nível de fusão do trabalho corrente.

Tabela 1 – Resumo dos resultados obtidos

	Descritor	%	σ
Imagens inteiras	GLCM	56,74	1,34
	LBP	77,41	1,22
Primeiro nível de fusão	GLCM	85,25	1,21
	LBP	90,96	0,55
Segundo nível de fusão	GLCM + LBP	93,03	0,54
Weber e Martins (2017)	LBP	80,20	0,82
Wideck et al. (2017)	GLCM	85,25	1,21

CONCLUSÕES

Este trabalho avaliou a estratégia proposta para a combinação em dois níveis de classificadores construídos a partir dos descritores GLCM e LBP ao problema de reconhecimento de espécies florestas por meio de imagens microscópicas da madeira. As melhores taxas de reconhecimento obtidas com tal abordagem foram de 93,03% ($\sigma=0,54$) para a regra Soma.

As referidas taxas representam melhoras substanciais de cerca de 36,3 e 16,5 pontos percentuais com relação a GLCM e LBP, respectivamente, quando estes foram aplicados às imagens em seu tamanho original. Após o segundo nível de combinação do modelo proposto, ainda obteve-se um novo incremento nas taxas de reconhecimento de cerca de 7,8 e 2,1 pontos percentuais com relação a GLCM e LBP, respectivamente.

Os resultados obtidos demonstram a potencialidade do uso da estratégia proposta de combinação de classificadores em dois níveis. Na sequência busca-se por novos descritores, bem como estratégias de seleção de classificadores na tentativa de melhorar ainda mais os resultados obtidos.

Combination of Two-Level Classifiers applied to Recognition of Forest Species

ABSTRACT

The difficulty of identifying the forest species from which the wood was extracted increases as the wood is processed and its derivatives move away from the extraction site. Commercial and ecological issues make such an identification important. This work focuses on the use of two well-known textural descriptors in the construction of classifiers to distinguish forest species. Such classifiers have their decisions combined at two levels to produce a final decision of the system. The best results were 93.03% ($\sigma = 0.54$) and they are superior to those obtained in other studies with the same images database.

KEYWORDS: Computer vision, texture-based features, combination of classifiers.

AGRADECIMENTOS

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

REFERÊNCIAS

BLACK, D. "The Theory of Committees and Elections". 2.ed. London: Cambridge University Press, 1958.

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

HARALICK, R.M. (1979) "Statistical and structural approaches to texture". v. 67, n. 5, p. 786-804.

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.

JAIN, A.K.; DUIN, R P.W.; MAO, J. (2000) "Statistical pattern recognition: a review". Pattern Analysis and Machine Intelligence. v. 22, n. 1, p. 4-37.

KITTLER, J.; HATEF, M.; DUIN, R.P.W.; MATAS, J. (1998) "On combining classifiers". In Pattern Analysis and Machine Intelligence, v. 20, p. 226-239.

KO, A. H. R.; SABOURIN, R.; Britto, A.; Oliveira, L. S. (2007) Pairwise fusion matrix for combining classifiers. Pattern Recognition, v. 40, n. 8, p. 2198-2210.

KREICH, W. "Towards Adaptive Anomaly Detection Systems using Boolean Combination of Hidden Markov Models". Tese de Doutorado, École de Technologie Supérieure, Université du Québec, Montreal, 2011.

MÄENPÄÄ, T.; OJALA, T. PIETIKÄINEN, M.; SORIANO, M. (2000) "Robust texture classification by subsets of local binary patterns". In 15th International Conference on Pattern Recognition, p. 947-950.

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. "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, 2014.

MOODY, J.; KLINKHACHORN, P. "Automated Lumber Processing System (ALPS): an industrial prototype", In Thirtieth Southeastern Symposium on System Theory, Morgantown, WV, 1998, p. 476-479.

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.

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.

Recebido: 10 out. 2018.

Aprovado: 31 dez. 2018.

DOI: <http://dx.doi.org/10.3895/rcaa.v1n2.9165>.

Como citar:

WIDECK, T.A.; MARTINS, J.G. Combinação de Classificadores em Dois Níveis aplicada ao Reconhecimento de Espécies Florestais. **Revista de Computação Aplicada ao Agronegócio**, Medianeira, v. 1, n. 2, p. 27-43 ago./dez. 2018. Disponível em: <<https://periodicos.utfpr.edu.br/rcaa/article/view/9165>>. Acesso em: dez. 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.

