

Universidade Federal do Paraná
Setor de Ciências Exatas
Departamento de Estatística
Programa de Especialização em *Data Science* e *Big Data*

Deivison Venicio Souza

Reconhecimento de espécies florestais baseado em imagens macroscópicas de madeiras

**Curitiba
2019**

Deivison Venicio Souza

Reconhecimento de espécies florestais baseado em imagens macroscópicas de madeiras

Monografia apresentada ao Programa de Especialização em *Data Science* e *Big Data* da Universidade Federal do Paraná como requisito parcial para a obtenção do grau de especialista.

Orientador: Prof. Luiz Eduardo Soares de Oliveira

Curitiba
2019

Reconhecimento de espécies da flora brasileira baseado em imagens macroscópicas de madeiras

Recognition of Brazilian flora species based on macroscopic images of wood

Deivison Venicio Souza¹

¹Faculdade de Engenharia Florestal, Universidade Federal do Pará, Rua Coronel José Porfírio, 2515, Altamira, PA, Brasil*

Resumo

Avanços em tecnologias de reconhecimento de espécies podem contribuir para a conservação e proteção de espécies da flora, em especial aquelas ameaçadas de extinção. O objetivo desta pesquisa foi comparar as abordagens de fusão precoce de operadores conhecidos como "Padrões binários Locais - LBP" e fusão tardia, realizada ao nível de decisão dos classificadores, na construção de um sistema de reconhecimento automático de espécies florestais. Foram usadas 2550 imagens macroscópicas de madeiras de 46 espécies da flora brasileira. A extração de características das imagens foi feita com uso de duas variantes do descritor LBP, cobrindo diferentes aspectos da resolução espacial e angular. O conjunto de imagens foi dividido em aprendizado (80%) e teste (20%), usando de amostragem estratificada aleatória, cujos estratos foram as classes de previsão. O classificador RNA treinado com dados combinados de histogramas LBP uniformes e invariantes à rotação apresentou acurácia de 96,06%, e a fusão de classificadores, através de voto majoritário, foi capaz de melhorar a acurácia do sistema em 1,38%. O sistema de reconhecimento construído mostrou boa capacidade de prever a natureza, e se essa tecnologia for aliada aos ferramentais tradicionais de identificação e ao conhecimento empírico, pode-se minimizar os erros de identificação de espécies da flora brasileira, em especial as espécies ameaçadas de extinção, para as quais o sistema de classificação proposto mostrou alta acurácia.

Palavras-chave: padrões binários locais, aprendizado de máquina, espécies ameaçadas, fusão de classificadores

Abstract

Advances in species recognition technologies can contribute to the conservation and protection of flora species, especially those threatened with extinction. The aim of this research was to compare the early fusion approaches of operators known as "Local Binary Patterns-LBP" and late fusion, carried out at the level of the decision of classifiers, in the construction of an automatic recognition system of forest species. We used 2550 macroscopic images of wood from 46 species of the Brazilian flora. The extraction of image characteristics was made using two variants of the LBP descriptor, covering different aspects of spatial and angular resolution. The set of images was divided into learning (80%) and test (20%), using random stratified sampling, whose strata were the prediction classes. The trained RNA classifier with combined data from the uniform and rotation invariant LBP histograms presented accuracy of 96.06%, and the fusion of classifiers, through majority voting, improved the accuracy of the system by 1.38%. The recognition system showed good ability to predict nature, and if this technology is combined with traditional identification tools and empirical knowledge, it is possible to minimize errors in the identification of species of Brazilian flora, especially endangered species, for which the proposed classification system showed high accuracy.

Keywords: local binary patterns, machine learning, endangered species, fusion of classifiers

1. Introdução

O Brasil destaca-se no cenário mundial por possuir extensas áreas florestais nativas [8], resguardando uma expressiva fração da diversidade mundial de fungos e

plantas (entre 9,5 e 9,9%), com 18.932 espécies endêmicas, isto é, uma das maiores taxas de endemismo (46,2%) do planeta [5]. No entanto, a rica biodiversidade de espécie de plantas do Brasil está ameaçada pela destruição e fragmentação acelerada de habitat, alertando a sociedade para o risco de extinção de es-

*deivisonvs@ufpa.br

pécies [4]. Na Amazônia brasileira, por exemplo, [14] estimaram a existência de 87 espécies ameaçadas de extinção, 90 com dados insuficientes e 142 não ameaçadas, porém consideradas de interesse para conservação e pesquisa.

Dentre vários aspectos fundamentais para a conservação da flora destaca-se a correta identificação de espécies, pois é preciso conhecer para conservar. Na comunidade científica, os mecanismos tradicionais de identificação de espécies florestais incluem a caracterização botânica, dendrológica e/ou a análise de estruturas anatômicas macro e microscópicas do lenho das espécies [17, 2, 25]. O processo de reconhecimento é comumente guiado por chaves de identificação, a exemplo da disponibilizada pela Associação Internacional de Anatomistas da Madeira (do inglês, *International Association of Wood Anatomists*-IAWA) [7]. Apesar de bastante eficazes, esses mecanismos de identificação exigem um alto nível de qualificação, em termos de conhecimentos teóricos e experiência prática. Nas atividades práticas de inventários florestais (IF) esse profissional existe e é chamado de "Parabotânico", porém infelizmente esse especialista está cada vez mais raro. Para muito além disso, no contexto Amazônico, as atividades de identificação em IF não primam pela expertise de um Parabotânico, mas pelo conhecimento empírico de nativos (mateiros), que adquiriram experiência prática através de gerações, e usam de nomes vernaculares no processo de identificação. O uso de nome vulgar é problemático, pois agrupa espécies distintas, gerando risco de extinção de espécies, a destinação incorreta do uso da madeira e, por conseguinte, uma incredulidade na relação vendedor-consumidor [24].

Neste contexto, estudos direcionados à identificação correta de espécies da flora são cruciais para conservação e proteção da biodiversidade. Felizmente pesquisas atuais têm despertado para o potencial de abordagens modernas, como aprendizado de máquina e visão computacional, no reconhecimento de espécies vegetais (ex.: [15, 22, 13, 28]). Avanços em tecnologias de reconhecimento de espécies são importantes, e se aliado aos ferramentais tradicionais de identificação e ao conhecimento empírico, podem constituir uma estratégia eficaz para reduzir os erros de campo na atividade de identificação de espécies da flora brasileira.

Os estudos envolvendo visão computacional comumente enfocam o uso de imagens de folhas e do lenho da madeira (macro e microscópicas) para a extração de características e desenvolvimento de classificadores

automáticos. Um estudo relatado em [28] usou de características visuais de folhas sadias para construir um identificador automático para reconhecer 32 espécies vegetais, alcançando uma precisão de (92,91%) ao usar o algoritmo de Máquina de Vetores de Suporte (MVS). Em [15], foram utilizadas 2.240 imagens microscópicas de 112 espécies florestais, e o uso combinado do extrator de características conhecido como Padrão Binário Local e do classificador MVS garantiu melhor desempenho (98,6% e 86,0%) para os dois experimentos realizados. O estudo de [16] usou a mesma base de imagens microscópicas de [15] e encontrou taxa de reconhecimento de 93,03% usando um método de seleção dinâmica de classificadores. Pesquisas com reconhecimento de espécies a partir de imagens de carvão de madeiras nativas, com uso do descritor chamado Padrões Binários Locais (do inglês, *Local Binary Patterns* - LBP) associado à classificadores de aprendizado de máquina de última geração e de Redes Neurais Convolucionais, revelaram taxas de reconhecimento superiores à 90% [13]. A pesquisa publicada em [22] propôs a estratégia de dividir e conquistar, e obteve melhoria de 9% na taxa de reconhecimento usando de imagens macroscópicas de madeiras, e a melhor precisão foi de 97,77%.

Para a descrição da textura em imagens o método LBP tem ganhado bastante enfoque pela a comunidade científica [12], especialmente após introdução, no ano de 2002, dos operadores $LBP_{P,R}^{u2}$ (LBP uniforme) e $LBP_{P,R}^{riu2}$ (LBP uniforme e invariante à rotação) por Ojala, Pietikäinen e Mäenpää [21]. Portanto, o objetivo deste trabalho foi comparar estratégias de agregação de recursos LBP, extraídos sob diferentes realizações de seus parâmetros (P e R), e também a fusão de classificadores usando o voto majoritário como regra de decisão final, visando construir um acurado sistema de reconhecimento automático de espécies florestais.

2. Conjunto de dados

O conjunto de imagens (n=2550) foi cedido pelo Laboratório de Anatomia e Qualidade da Madeira (LANAQM) da Universidade Federal do Paraná (UFPR). As imagens macroscópicas foram obtidas através de um estereomicroscópio da marca Zeiss, modelo Discovery 12, possuindo resolução de 2080 × 1540 pixels. Comparado ao estudo realizado por [22], a base inclui novas espécies confundidas comercialmente, inclusive em substituição à algumas espécies ameaçadas de extinção da flora brasileira. No Brasil, diversas espécies

da flora estão sob ameaça de extinção, e a lista pode ser consultada no Livro Vermelho da Flora Brasileira [14]. As espécies ameaçadas foram integralmente incluídas na Portaria MMA nº 443 de 17 de dezembro de 2014, que estabeleceu uma "Lista Nacional Oficial de Espécies da Flora Ameaçadas de Extinção", regulamentando que as espécies constantes da Lista classificadas nas categorias Extintas na Natureza (EW), Criticamente em Perigo (CR), Em Perigo (EN) e Vulnerável (VU) deveriam ser protegidas de modo integral, incluindo a proibição de coleta, corte, transporte, armazenamento, manejo, beneficiamento e comercialização, dentre outras [3]. Das 46 espécies usadas neste estudo, 7 (15%) constam na lista oficial do Brasil de espécies em risco de extinção. A espécie *Araucaria angustifolia* e *Ocotea porosa* foram enquadradas na categoria "Em Perigo", *Bertholletia excelsa*, *Cedrela fissilis*, *Mezilaurus itauba* e *Swietenia macrophylla* fazem parte do grupo de espécies "Vulnerável" e *Euxylophora paraensis* foi considerada "Criticamente em Perigo". Na tab. 1 estão listadas as 46 espécies da flora brasileira e a quantidade de imagens por classe, e na fig. 1 estão amostras de imagens macroscópicas das madeiras.

3. Padrões Binários Locais

O processo de extração de características de imagens é fundamental para o sucesso da etapa de modelagem de classificadores automáticos. Bons dados discriminativos aumentam a chance de construir sistemas inteligentes de reconhecimento com boa capacidade de descrever a realidade. Nesta seção é apresentada uma breve descrição sobre o método conhecido como Padrões Binários Locais (do inglês, *Local Binary Patterns* - LBP), um descritor de textura de sucesso e amplamente usado na visão computacional. Aqui, o LBP foi usado para extração de características de imagens macroscópicas de madeiras em tons de cinza e, os histogramas de recursos LBP são usados como entradas para algoritmos de aprendizado supervisionado.

O manuscrito publicado por He & Wang [6] em 1990 constituiu um marco histórico, pois descreveu um novo método estatístico para a análise de textura de imagens denominado *espectro de textura*, baseado no conceito de *unidade de textura* (UT). A UT foi definida como a menor unidade completa que melhor caracteriza o espectro de textura local de um determinado pixel e sua vizinhança em todas as oito direções de uma varredura quadrada. A partir disso, a textura de uma imagem é caracterizada por seu espectro de textura, que descreve a

Tabela 1: Nome científico e número de imagens macroscópicas por espécie florestal.

Código	Família	Nome Científico	N	Categoria*
1	Fabaceae	<i>Acrocarpus fraxinifolius</i>	38	
2	Araucariaceae	<i>Araucaria angustifolia</i>	103	EN
3	Apocynaceae	<i>Aspidosperma polyneuron</i>	23	
4	Apocynaceae	<i>Aspidosperma</i> sp.	67	
5	Moraceae	<i>Bagassa guianensis</i>	57	
6	Rutaceae	<i>Balfourodendron riedelianum</i>	70	
7	Lecythidaceae	<i>Bertholletia excelsa</i>	54	VU
8	Fabaceae	<i>Bowdichia</i> sp.	95	
9	Moraceae	<i>Brosimum paraensis</i>	44	
10	Meliaceae	<i>Carapa guianensis</i>	24	
11	Lecythidaceae	<i>Cariniana estrellensis</i>	43	
12	Meliaceae	<i>Cedrela fissilis</i>	31	VU
13	Fabaceae	<i>Cedrelinga catenaeformis</i>	171	
14	Boraginaceae	<i>Cordia goeldiana</i>	55	
15	Lecythidaceae	<i>Couratari</i> sp.	57	
16	Fabaceae	<i>Dipteryx</i> sp.	60	
17	Vochysiaceae	<i>Erisma uncinatum</i>	71	
18	Myrtaceae	<i>Eucalyptus</i> sp.	49	
19	Myrtaceae	<i>Eugenia pyriformis</i>	38	
20	Rutaceae	<i>Euxylophora paraensis</i>	86	CR
21	Goupiaceae	<i>Goupia glabra</i>	40	
22	Proteaceae	<i>Grevillea robusta</i>	50	
23	Bignoniaceae	<i>Handroanthus</i> sp.	47	
24	Fabaceae	<i>Hymenaea</i> sp.	38	
25	Fabaceae	<i>Hymenolobium petraeum</i>	49	
26	Fabaceae	<i>Hymenolobium</i> sp.	29	
27	Fabaceae	<i>Inga vera</i>	40	
28	Lauraceae	<i>Laurus nobilis</i>	39	
29	Fabaceae	<i>Lonchocarpus campestris</i>	41	
30	Fabaceae	<i>Machaerium paraguayensis</i>	40	
31	Fabaceae	<i>Machaerium</i> sp.	15	
32	Sapotaceae	<i>Manilkara huberi</i>	45	
33	Meliaceae	<i>Melia azedarach</i>	89	
34	Lauraceae	<i>Mezilaurus itauba</i>	87	VU
35	Sapotaceae	<i>Micropholis venulosa</i>	82	
36	Fabaceae	<i>Mimosa scabrella</i>	41	
37	Fabaceae	<i>Myroxylon balsamum</i>	64	
38	Lauraceae	<i>Nectandra megapotamica</i>	32	
39	Lauraceae	<i>Ocotea indecora</i>	40	
40	Lauraceae	<i>Ocotea porosa</i>	61	EN
41	Fabaceae	<i>Peltogyne</i> sp.	61	
42	Pinaceae	<i>Pinus</i> sp.	48	
43	Sapotaceae	<i>Pouteria pachycarpa</i>	49	
44	Simaroubaceae	<i>Simarouba amara</i>	33	
45	Meliaceae	<i>Swietenia macrophylla</i>	102	VU
46	Vochysiaceae	<i>Vochysia</i> sp.	52	

*Espécies ameaçadas de extinção conforme categoria estabelecida pela Portaria MMA nº 443 de 17 de dezembro de 2014 [3]. CR = Criticamente em Perigo, EN = Em Perigo e VU = Vulnerável.

distribuição de todas as UTs dentro da imagem. Assim, uma UT pode ser representada por oito elementos situados em uma vizinhança quadrada de 3x3 pixels, onde cada elemento podem assumir três valores possíveis (0, 1 ou 2). Portanto, da combinação dos oito elementos são possíveis extrair $3^8 = 6561$ padrões de texturas locais [6].

Em 1994, Ojala, Pietikäinen e Harwood [19] propuseram uma versão adaptada de dois níveis para a abordagem proposta He & Wang, fornecendo uma maneira robusta de descrever padrões binários locais (LBP) da tex-




Figura 1: Amostras de imagens macroscópicas.

tura de imagens, sendo invariante na escala de cinza. Na versão de dois níveis (0, 1), o número de unidades de textura possíveis foi reduzido para $2^8 = 256$. As etapas de cálculo do operador LBP pode ser assim simplificadas: 1) vizinhança: estabeleça uma vizinhança de 3x3 no entorno de um pixel central; 2) limiarização: limiarize os valores de escala de cinza dos oito vizinhos pela comparação com a intensidade do pixel central. Quando o valor do pixel central for maior ou igual do que o valor do vizinho atribua "1", caso contrário "0". Fazendo isso, o resultado é um número binário de oito dígitos (10001011); 3) pesos: multiplique cada código binário (Fig. 2b) por pesos, observadas as respectivas posições na matriz (Fig. 2c), o resultado será conforme apresentado em Fig. 2d; 4) padrão LBP: o novo valor do pixel central será um decimal (0 a 255) resultante da soma dos valores em Fig. 2d, isto é, $LBP = 1 + 8 + 32 + 128 = 169$. Finalmente, usando os valores decimais calculados para cada pixel na imagem, um histograma de 256 padrões pode ser calculado e usado como uma representação da imagem. A LBP original é invariante contra qualquer transformação monótona à escala de cinza, isto é, desde que a ordem dos valores de pixel permaneça a mesma, a saída do operador de LBP permanece constante [19].

6	5	2
7	6	1
9	3	7

(a)

1	0	0
1		0
1	0	1

(b)

1	2	4
8		16
32	64	128

(c)

1	0	0
8		0
32	0	128

(d)

Figura 2: Um exemplo do método LBP original proposto em [19].




Figura 3: Uma representação do método LBP estendido proposto em [21]. Quando a localização dos vizinhos no círculo não coincide com os centros dos pixels, os valores de cinza são determinados por interpolação bilinear.

Apesar do poder de descrever texturas de imagens, o LBP proposto em [19] não é invariante à rotação, condição indesejável em certas aplicações [23]. A invariância à rotação implica que os mesmos recursos

da imagem ainda podem ser extraídos caso a imagem seja rotacionada para quaisquer ângulos. Em 2000, baseado na ideia de contornar o problema de invariância do LBP, Pietikäinen, Ojala e Xu propuseram uma primeira versão do LBP invariante à rotação denominada LBPROT [23]. Em 2002, Ojala, Pietikäinen e Mäenpää [21] introduziram uma generalização do LBP, em que a vizinhança quadrada 3x3 proposta em [19] foi substituída para uma vizinhança com P vizinhos uniformemente distribuídos em ângulo sob um círculo de raio R [12]. Na Fig. 3 está uma representação genérica do LBP estendido para situações com diferentes valores dos parâmetros P e R . A formalização matemática do operador está definida na Eq. (1).

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1)$$

Em que, R é a resolução espacial do operador; P é a quantidade de vizinhos circulares simétricos; g_c é intensidade do nível de cinza do pixel central; g_p representam os níveis de cinza dos pixels vizinhos dispostos no círculo; e $s(x)$ é a função de limiar. Considerando que o pixel central está situado na coordenada $g_c = (0,0)$, então as coordenadas da vizinhança são dadas por (x_p, y_p) , onde $x_p = -R \sin(2\pi p/P)$ e $y_p = -R \cos(2\pi p/P)$ [21, 1].

O operador não invariante à rotação ($LBP_{P,R}$) é similar ao LBP original [19]. Por exemplo, se definido $P=8$ e $R=1$ para o operador $LBP_{8,1}$ têm-se basicamente duas diferenças em relação ao LBP original: 1) Os pixels na vizinhança do pixel central são indexados para formar uma cadeia circular; e 2) Os valores de nível de cinza dos pixels diagonais são determinados por interpolação. Para essa situação, os quatro vizinhos nas diagonais do círculo não coincidem com os centros dos pixels, portanto justifica-se o uso da interpolação bilinear. Do mesmo modo, o operador $LBP_{8,1}^{riu2}$ equivale ao LBPROT, porém experimentos têm revelado que o operador não oferece uma boa discriminação [23, 21].

O grande destaque da pesquisa de [21] foi reconhecer que alguns padrões binários ocorrem com maior frequência do que outros, esses padrões foram denominados *uniformes*. Na prática, o operador chamado U é usado para calcular a quantidade de transições espaciais (0 a 1 ou vice versa) em uma sequência binária circular [1]. O padrão é “uniforme” se $U \leq 2$, caso contrário é não uniforme, e estes são agrupados sob um mesmo rótulo. Os padrões binários mais frequentes e uniformes correspondem a micro-características primitivas, como bordas, cantos e pontos. Experimentos

realizados reportam que padrões uniformes representam pouco menos de 90% dos padrões na vizinhança (8,1) e por cerca de 70% na vizinhança (16,2) [21].

Os operadores $LBP_{P,R}^{u2}$ e $LBP_{P,R}^{riu2}$ incorporam o conceito de padrões uniformes, e possuem a vantagem por reduzir a dimensionalidade do vetor de características, mantendo a capacidade discriminativa. Portanto, os operadores $LBP_{P,R}^{u2}$ e $LBP_{P,R}^{riu2}$ reduzem a dimensionalidade do vetor de características de 2^P (LBP padrão) para $P(P-1)+3$ e $P+2$, respectivamente. O operador $LBP_{P,R}^{riu2}$ é uniforme e invariante à rotação, e está formalmente definido nas Eq. (2) e Eq. (3) [21].

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) & \text{if } U(LBP_{P,R}) \leq 2 \\ P+1, & \text{caso contrário} \end{cases} \quad (2)$$

$$U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (3)$$

4. Metodologia

Neste estudo, para cobrir aspectos da resolução espacial e angular três configurações do operador LBP uniforme e invariante à rotação ($LBP_{8,1}^{riu2}$, $LBP_{16,2}^{riu2}$, $LBP_{24,3}^{riu2}$) e três do operador uniforme e não invariante à rotação ($LBP_{8,1}^{u2}$, $LBP_{16,2}^{u2}$, $LBP_{24,3}^{u2}$) foram consideradas. A extração de recursos foi feita com auxílio da função `local_binary_pattern()` da biblioteca `scikit-image`, disponível para a linguagem de programação Python. De cada configuração do descritor LBP, histogramas de ocorrências de padrões de textura foram obtidos e normalizados.

A primeira abordagem experimental consistiu em usar de histogramas de LBP individuais normalizados como recursos de entrada para os modelos de aprendizagem de máquina. Depois, dois esquemas de fusão foram considerados: a) fusão precoce (do inglês, *early fusion*); e b) fusão tardia (do inglês, *later fusion*). Basicamente, os esquemas diferenciam-se em relação ao nível em que a fusão é realizada. A fusão precoce envolve a estratégia de combinar os histogramas de múltiplos operadores, antes da fase de aprendizado, para criar um novo vetor de recursos permitindo uma análise multi-resolução. Por exemplo, a combinação $LBP_{8,1}^{riu2} + LBP_{16,2}^{riu2}$, resulta em um novo vetor com dimensionalidade: $10 + 18 = 28$. A fusão tardia é realizada ao nível de decisão dos classificadores. Primeiro,

os modelos são treinados separadamente para cada conjunto de recursos LBP, e as decisões individuais são tomadas. Em seguida, uma decisão comum é tomada a partir da fusão das decisões individuais. Aqui, usou-se o voto majoritário como regra de decisão final. Para o operador $LBP_{P,R}^{u2}$ a dimensionalidade do vetor de recursos aumenta em $P(P-1)+3$. Assim, portanto, a Análise de Componentes Principais (ACP) foi usada para reduzir a dimensionalidade do vetor de recursos (exceto para $LBP_{8,1}^{u2}$), mantendo os componentes principais que explicaram acumuladamente 95% da variância total dos dados originais ($thresh = 0,95$). Na Fig. 4 é apresentado um fluxograma simplificado das principais etapas deste estudo, e as estratégias de fusão precoce e tardia. O conjunto de imagens foi dividido em aprendizado (80%) e teste (20%). Para tanto, usou-se a função `createDataPartition()` do pacote "caret" para obter uma amostragem estratificada aleatória (*stratified random split*) em função das classes de previsão. Esse procedimento assegura a representatividade de todas as espécies nos conjuntos de aprendizado e teste, mantendo o perfil geral da distribuição. O conjunto de aprendizado foi usado para encontrar os hiperparâmetros de ótimo ajuste (*optimal hyperparameters tuning*) usando o método de validação cruzada (*10-fold cross-validation*), através da interface do pacote "caret" (*Classification and Regression Training*) [10], do ambiente estatístico R (versão 3.5.3). Aqui, foram testados três algoritmos de aprendizado supervisionado: a) Máquinas de Vetores de Suporte (MVS) - (método: `svmPoly`; pacote: `kernlab` [9]); b) Redes Neurais Artificiais (RNA) - (método: `nnet`; pacote: `nnet` [26]); e c) Floresta Aleatória (RF) - (método: `rf`; pacote: `randomForest` [11]). As métricas de desempenho dos classificadores foram extraídas usando a função `confusionMatrix()` do pacote "caret", que gera a matriz de confusão e inúmeras métricas usando a abordagem "um contra todos" (*"one versus all"*). A acurácia geral do sistema no conjunto de teste ($n = 508$) foi calculada pela Eq. (4). Devido ao desbalanceamento de classes, as métricas *Recall* (Eq. 5) e *F1-score* ($\beta = 1$) (Eq. 7) foram obtidas para maior confiabilidade da estimativa de desempenho. A precisão foi obtida pela Eq. 6. Em que: Verdadeiro positivo (VP) = número de amostras classificadas corretamente dentro da classe C_i ; Verdadeiro negativo (VN) = número de amostras corretamente classificadas como não pertencente a classe C_i ; Falso positivo (FP) = número de amostras erroneamente classificadas dentro da classe C_i ; Falso negativo (FN) = número de amostras errone-

amente classificadas como não pertencente a classe C_i .

$$Acurácia = \frac{VP + VN}{VP + FP + VN + FN} \quad (4)$$

$$Recall = \frac{VP}{VP + FN} \quad (5)$$

$$Precisão = \frac{VP}{VP + FP} \quad (6)$$

$$F1-score = (1 + \beta^2) \frac{Precisão \cdot Recall}{((\beta^2 \cdot Precisão) + Recall)} \quad (7)$$




Figura 4: Fluxograma simplificado das principais etapas do estudo, desde a etapa de extração de características com diferentes variantes do método LBP até a seleção do melhor modelo de reconhecimento de espécies. Onde: C_n : n -ésimo classificador treinado com recursos $LBP_{P,R}$.

5. Resultados e discussão

O estimador *k-fold cross-validation* foi usado para encontrar o ótimo ajuste de hiperparâmetros para os algoritmos de aprendizado supervisionado. As melhores configurações indicadas na reamostragem foram usadas para ajustar os classificadores a todo conjunto de treinamento ($n = 2042$). Em seguida, os modelos tiveram sua capacidade de generalização avaliada no conjunto de teste ($n = 508$). Os resultados encontrados com uso dos operadores $LBP_{P,R}^{u2}$ e $LBP_{P,R}^{riu2}$, revelaram que padrões de textura LBP individuais extraídos de imagens macroscópicas da madeira fornecem boas informações para a discriminação de espécies, e que quando combinados melhoram o desempenho dos classificadores. Em geral, o uso de redes neurais artificiais e máquinas de vetores de suporte apresentaram

melhores desempenho na distinção de espécies (Tab. 2 e 3).

Tabela 2: Desempenho dos classificadores com uso do método LBP uniforme e invariante à rotação ($LBP_{P,R}^{riu2}$), com e sem combinação de operadores.

P, R	Tamanho do Vetor	Teste (n = 508)					
		MVS *		RNA		FA	
		Acurácia	F1-Score	Acurácia	F1-Score	Acurácia	F1-Score
8,1	10	0,8937	0,8889	0,9016	0,8856	0,7894	0,7547
16,2	18	0,9213	0,9056	0,9055	0,8943	0,7539	0,7320
24,3	26	0,9134	0,9106	0,9094	0,9023	0,7303	0,7083
8,1 + 16,2	28	0,9449	0,9214	0,9469	0,9396	0,8169	0,8015
8,1 + 24,3	36	0,9429	0,9257	0,9449	0,9451	0,8248	0,7949
16,2 + 24,3	44	0,9311	0,9249	0,9232	0,9127	0,7657	0,7457
8,1 + 16,2 + 24,3	54	0,9528	0,9415	0,9606	0,9505	0,8406	0,8089

Em que: P = quantidade de vizinhos circulares simétricos; R = resolução espacial do operador.

*kernel Polinomial.

Tabela 3: Desempenho dos classificadores com uso do método LBP uniforme e não invariante à rotação ($LBP_{P,R}^{u2}$), com e sem combinação de operadores.

P, R	Tamanho do Vetor	Teste (n = 508)					
		MVS *		RNA		FA	
		Acurácia	F1-Score	Acurácia	F1-Score	Acurácia	F1-Score
8,1	59	0,8898	0,8672	0,8858	0,8730	0,8248	0,8048
16,2	243	0,9134	0,9006	0,8287	0,8102	0,8602	0,8543
24,3	555	0,9232	0,9161	0,8642	0,8480	0,8839	0,8788
8,1 + 16,2	302	0,9154	0,8978	0,8819	0,8605	0,8583	0,8639
8,1 + 24,3	614	0,9272	0,9201	0,8681	0,8535	0,8917	0,8825
16,2 + 24,3	798	0,9508	0,9436	0,8976	0,8797	0,8898	0,8772
8,1 + 16,2 + 24,3	857	0,9488	0,9403	0,8898	0,8833	0,8937	0,8800

Em que: P = quantidade de vizinhos circulares simétricos; R = resolução espacial do operador.

*kernel Polinomial.

A estratégia de combinar histogramas LBP uniformes e invariantes à rotação com diferentes resoluções ($LBP_{8,1}^{riu2} + LBP_{16,2}^{riu2} + LBP_{24,3}^{riu2}$) proporcionou os maiores ganhos no reconhecimento de espécies. Por exemplo, usando o classificador RNA obteve-se aumento de 4,82% e 5,12% nas métricas *F1-Score* e *Acurácia*, respectivamente, quando comparado ao melhor desempenho dos classificadores usando de histogramas LBP individuais.

Os melhores valores para a métrica *F1-Score* foram de 95,05% usando RNA (size=9, decay=0,003) e 94,15% com MVS (degree=3, scale=0,001, C=2¹¹). O *Recall* (taxa de verdadeiros positivos por espécie) no conjunto de teste está na Fig. 5. Aqui, o melhor classificador RNA garantiu taxa de reconhecimento de 100% para 33 espécies florestais. As espécies *Dipteryx* sp., *Carapa guianensis*, *Simarouba amara* e *Handroanthus* sp. revelaram taxas inferiores à 70%. Dentre as espécies ameaçadas de extinção[3], apenas a espécie *Araucaria angustifolia* teve uma imagem classificada incorretamente. Este fato revela que o sistema de classificação construído a partir da abordagem de fusão de operadores é eficaz para o reconhecimento de espécies ameaçadas de extinção a partir de imagens macroscópicas de madeiras.

O operador $LBP_{P,R}^{u2}$ tem sido escolhido nas pesquisas de reconhecimento de espécies a partir de imagens de madeiras (ver [15, 22]) sob o argumento de oferecer melhores características para a discrimina-




Figura 5: Recall (taxa de reconhecimento por espécie) usando o classificador RNA treinado com múltiplos operadores LBP.

ção. Porém, aqui, os padrões extraídos com o uso do operador $LBP_{P,R}^{riu2}$ também forneceram informações robustas para os classificadores, garantindo altas taxas de reconhecimento de espécies. Usar o descritor $LBP_{P,R}^{riu2}$ em detrimento ao $LBP_{P,R}^{u2}$ proporciona vantagem computacional, pois reduz a dimensionalidade do vetor de recursos LBP. Por exemplo, para $LBP_{8,1}^{u2}$ a dimensão do vetor de recursos é 59, porém diminui para 10 (P+2) usando o operador $LBP_{8,1}^{riu2}$. O aumento de P torna ainda maior a discrepância entre os operadores em relação ao tamanho do vetor. Para além disso, o $LBP_{P,R}^{riu2}$ é invariante à rotação, propriedade importante que aumenta a capacidade do sistema de classificação de prever a natureza. A estratégia de fusão de classificadores objetivou usar os pontos fortes inerentes a cada classificador, buscando melhorar o sistema de reconhecimento. Aqui, a combinação de três classificadores RNA treinados com LBP uniforme e invariantes à rotação ($LBP_{24,3}^{riu2}$, $[LBP_{8,1}^{riu2} + LBP_{24,3}^{riu2}]$ e $[LBP_{8,1}^{riu2} + LBP_{16,2}^{riu2} + LBP_{24,3}^{riu2}]$) e dois classificadores MVS treinados com dados do LBP uniforme e não invariante à rotação ($LBP_{16,2}^{u2}$ e $[LBP_{16,2}^{u2} + LBP_{24,3}^{u2}]$) garantiu ganho de 1,44% e 1,38% nas métricas *F-Score* e *acurácia*, comparado ao melhor classificador RNA obtido na fusão de operadores. A matriz de confusão para a melhor combinação de classificadores está na Fig. 6 e o Recall por espécie na Fig. 7. Com o uso da abordagem, 34 espécies florestais apresentaram 100% das amostras corretamente reconhecidas. Apenas as espécies *Simarouba amara* e *Handroanthus* sp. permane-

ceram com *Recall* abaixo de 70%. Porém, é importante considerar a pequena amostra de *Simarouba amara* no conjunto de teste, isto implica que uma classificação incorreta têm proporcionalmente maior impacto no valor da métrica *Recall*. A Fig. 8 mostra a similaridade de texturas das imagens macroscópicas para as espécies *Acrocarpus fraxinifolius* e *Handroanthus* sp., espécies confundidas pelo classificador combinado.




Figura 6: Matriz de confusão para o conjunto de teste ($n = 508$) usando fusão de classificadores.

6. Conclusão

O descritor de textura "Padrões Binários Locais" extraído a partir de imagens macroscópicas da madeira fornece excelentes informações para a discriminação de espécies. O uso de histogramas de operadores LBP simples junto a poderosos algoritmos de aprendizado supervisionado, como MVS e RNA, permitiu a construção de classificadores com acurácia superior a 90%.

A estratégia de fusão de operadores LBP possibilitou uma análise multi-resolução e, em geral, contribuiu para aumentar a acurácia dos classificadores, alcançando uma taxa de 96,06%. Do mesmo modo, a abordagem de fusão de classificadores, através de voto majoritário, foi capaz de melhorar a acurácia do sistema em 1,38%.

O uso da visão computacional para o reconhecimento de espécies florestais a partir de imagens ma-




Figura 7: Recall (taxa de reconhecimento por espécie) usando combinação de classificadores.




Figura 8: Similaridade de texturas das imagens macroscópicas para as espécies *Acrocarpus fraxinifolius* (1) e *Handroanthus* sp. (23).

croscópicas de madeiras foi considerado eficaz, e se aliada aos mecanismos tradicionais de identificação e conhecimentos empíricos, pode constituir uma importante ferramenta para minimizar os erros de identificação de espécies da flora brasileira, em especial as espécies ameaçadas de extinção, para as quais o sistema de classificação proposto mostrou alta acurácia.

Agradecimentos

Os autores agradecem ao Laboratório de Anatomia e Qualidade da Madeira (LANAQM) da Universidade Federal do Paraná (UFPR) pela disponibilização dos dados.

Referências

- [1] Ahonen, T., Matas, J., He, C., Pietikäinen, M. *Rotation invariant image description with local binary pattern histogram fourier features*. In Scandinavian conference on image analysis (pp. 61-70). Springer, Berlin, Heidelberg. (2009).
- [2] Bila, N. F., Luis, R., Gonçalves, T. A. P., de Muñiz, G. I. B., Nisgoski, S. *Wood anatomy of five species from Mozambique and its potential application*. BOSQUE, **39**, 2 (2018).
- [3] Brasil. *Portaria MMA nº 443, de 17 de dezembro de 2014*. Reconhece como espécies da flora brasileira ameaçadas de extinção aquelas constantes da "Lista Nacional Oficial de Espécies da Flora Ameaçadas de Extinção". Diário Oficial da República Federativa do Brasil, Brasília, DF (2014).
- [4] Costa, M. L. M. N. and Bajgielman, T. *Estratégia Nacional para a Conservação Ex Situ de Espécies Ameaçadas da Flora Brasileira*. Centro Nacional de Conservação da Flora-CNCFlora: Jardim Botânico do Rio de Janeiro, 2016, 24p.
- [5] Forzza, R. C., Baumgratz, J. F. A., Bicudo, C. E. M., Carvalho Jr., A. A., Costa, A., Costa, D. P., Hopkins, M., Leitman, P. M., Lohmann, L. G., Maia, L. C., Martinelli, G., Menezes, M., Morim, M. P., Coelho, M. A. N., Peixoto, A. L., Pirani, J. R., Prado, J., Queiroz, L. P., Souza, V. C., Stehmann, J. R., Sylvestre, L. S., Walter, B. M. T., Zappi, D. *Catálogo das Plantas e Fungos do Brasil*, Rio de Janeiro: Andrea Jakobsson Estúdio: Instituto de Pesquisas Jardim Botânico do Rio de Janeiro, v.1, 2010. 878p.
- [6] He, D. C., and Wang, L. *Texture unit, texture spectrum, and texture analysis*. IEEE transactions on Geoscience and Remote Sensing, **28**, (1990).
- [7] IAWA. *List of microscopic features for hardwood identification*. IAWA Bulletin **10**, 3 (1989).
- [8] IBÁ. *Indústria Brasileira de Árvores*. O Relatório Anual IBÁ. 2016. 100p.
- [9] Karatzoglou, A., Smola, A., Hornik, K., Zeileis, A. *kernlab - An S4 Package for Kernel Methods in R*. Journal of Statistical Software, **11**, 9 (2004).
- [10] Kuhn, M., Wing, J., Weston, S., Williams, A., Keefer, C., Engelhardt, A., ... Benesty, M. *caret: Classification and regression training*. R package version 6.0-73. Vienna, Austria: CRAN. (2016).
- [11] Liaw, A., Wiener, M. *Classification and Regression by randomForest*. R News **2**, 3 (2002).
- [12] Liu, L., Fieguth, P., Guo, Y., Wang, X., Pietikäinen, M. *Local binary features for texture classification: Taxonomy and experimental study*. Pattern Recognition, **62**, (2017).
- [13] Maruyama, T. M., Oliveira, L. E. S., Britto Jr., A. S., Nisgoski, S. *Automatic classification of native wood charcoal*, Ecological Informatics. **46**, (2018).
- [14] Martinelli, G. and Moraes, M. A. *Livro Vermelho da Flora do Brasil*. Instituto de Pesquisas Jardim Botânico do Rio de Janeiro, 1 ed., Rio de Janeiro, 2013. 1100p.
- [15] Martins, J., Oliveira, L. S., Nisgoski, S., Sabourin, R. *A database for automatic classification of forest species*. Machine vision and applications, **24**, 3 (2013).
- [16] Martins, J. G., Oliveira, L. S., Britto, A. S., Sabourin, R. *Forest species recognition based on dynamic classifier selection and dissimilarity feature vector representation*. Machine Vision and Applications, **26**, (2015).
- [17] Muñiz, G. I. B., Carneiro, M. E., Batista, R., Rodrigues, F., Zatt Schardosin, F., Nisgoski, S. *Wood and charcoal identification of five species from the miscellaneous group known in Brazil as "angelim" by near-ir and wood anatomy*. Maderas. Ciencia y tecnología, **18**, 3 (2016).
- [18] Nisgoski, S., Oliveira, A. A., Muñiz, G. I. B. (2017). *Artificial neural network and SIMCA classification in some wood discrimination based on near-infrared spectra*. Wood Science and Technology, **51**, 4 (2017).
- [19] Ojala, T., Pietikainen, M., Harwood, D. *Performance evaluation of texture measures with classification based on Kullback discrimination of distributions*. In Proceedings of 12th International Conference on Pattern Recognition, **1** (1994).
- [20] Ojala, T., Pietikäinen, M., Mäenpää, T. *Gray scale and rotation invariant texture classification with local binary patterns*. In European Conference on Computer Vision (pp. 404-420). Springer, Berlin, Heidelberg. (2000).
- [21] Ojala, T., Pietikäinen, M., Mäenpää, T. *Multiresolution gray-scale and rotation invariant texture classification with local binary patterns*. IEEE Transactions on Pattern Analysis & Machine Intelligence, **7** (2002).
- [22] Paula Filho, P. L., Oliveira, L. S., Nisgoski, S., Britto Jr. A. S. *Forest species recognition using macroscopic image*, Machine vision and applications. **25** (2014).
- [23] Pietikäinen, M., Ojala, T., Xu, Z. *Rotation-invariant texture classification using feature distributions*. Pattern Recognition, **33**, (2000).
- [24] Procópio, L. C. and Secco, R. S. *A importância da identificação botânica nos inventários florestais: o exemplo do "tauari" (Couratari spp. e Cariniana spp. - Lecythidaceae) em duas áreas manejadas no Estado do Pará*, Acta Amazônica, **38**, 1 (2008).
- [25] Soffiatti, P., Boeger, M. R. T., Nisgoski, S., Kauai, F. *Wood anatomical traits of the Araucaria Forest, Southern Brazil*. Bosque, **37**, 1 (2016).
- [26] Venables, W. N., Ripley, B. D. *Modern Applied Statistics with S*. Fourth Edition. Springer, New York. (2002).
- [27] Vieira, I. C. G., Silva, J. M. C., Toledo, P. M. *Estratégias para evitar a perda de biodiversidade na Amazônia*. Estudos Avançados, São Paulo, **19**, 54, (2005).
- [28] Yigit, E., Sabanci, K., Toktas, A., Kayabasi, A. *A study on visual features of leaves in plant identification using artificial intelligence techniques*, Computers and Electronics in Agriculture, **156** (2019).