### JEFFERSON GUSTAVO MARTINS

## IDENTIFICAÇÃO DE ESPÉCIES FLORESTAIS UTILIZANDO SELEÇÃO DINÂMICA DE CLASSIFICADORES NO ESPAÇO DE DISSIMILARIDADE

Tese apresentada ao Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Ciência da Computação. Orientador: Luiz Eduardo S. Oliveira, Dr. Co-orientador: Robert R. Sabourin, Dr.

### CURITIBA - PR



Ministério da Educação Universidade Federal do Paraná Programa de Pós-Graduação em Informática

#### PARECER

Nós, abaixo assinados, membros da Banca Examinadora da defesa do aluno de Doutorado em Ciência da Computação, Jefferson Gustavo Martins, avaliamos a tese de doutorado intitulada *"Identificação de espécies florestais utilizando seleção dinâmica de classificadores no espaço de dissimilaridade*", cuja defesa pública foi realizada no dia 12 de março de 2014, às 09:30 horas, no Departamento de Informática do Setor de Ciências Exatas da Universidade Federal do Paraná. Após avaliação, decidimos pela: (Xaprovação do candidato. ()reprovação do candidato.

Curitiba, 12 de março de 2014.

Prof. Dr. Luiz Eduardo Soares de Oliveira

DINF/UFPR - Orientador

Prof. Dr. George Darmiton da Cunha Cavalcanti

UFPE – Membro Externo

Prof. Dr. Alceu de Souza Britto Jr. PUC/PR – Membro Externo

Prof. Dr. Vilson Luiz Dalle Mole UTFPR – Membro Externo

Prof. Dr. Daniel Weingaertner DINF/UFPR – Membro Interno



### RESUMO

A progressiva escassez dos recursos naturais tem conduzido a um uso cada vez mais racional destes materiais, independente de sua origem e aplicação. Dentre tais recursos, a madeira e sua exploração têm despertado grande interesse, principalmente por ser, muitas vezes, extraída de florestas nativas e da influência que estas têm sobre o planeta. Além disso, as transações comerciais de madeira envolvem grandes montantes e são suscetíveis a fraudes. Estes logros decorrem da entrega de madeira extraída de espécies com menor valor comercial do que o acordado entre as partes e tentativas de exploração de espécies em iminente extinção. Garantir a autenticidade de madeiras constitui uma necessidade tanto de seus compradores quanto das agências fiscalizadoras. Fatores como o elevado número de espécies, a falta de profissionais capacitados, o exaustivo processo de reconhecimento e a perda de características naturais (folhas, casca e cor) tornam ainda mais difícil garantir a autenticidade das madeiras. Inserido neste contexto, este trabalho focou a construção de um sistema robusto para a classificação de espécies florestais utilizando as características texturais presentes nas imagens microscópicas de madeira, a representação no espaço de dissimilaridade e os sistemas compostos por múltiplos classificadores. Para isso, explorou-se diferentes alternativas para representar as características texturais. Para permitir a aplicação dos modelos de classificação a espécies não consideradas durante seu treinamento, buscou-se definir os melhores valores para os parâmetros inerentes ao processo de construção dos classificadores no espaço de dissimilaridade. Buscando ainda melhorar o desempenho do sistema, também foram propostos e avaliados métodos para seleção e/ou combinação de classificadores, além da avaliação das taxas de reconhecimento em diferentes níveis da Botânica, visto que nem sempre é preciso chegar à classificação em nível de espécie. Testados em uma base de imagens construída para o desenvolvimento deste trabalho, as estratégias e os métodos de seleção dinâmica de classificadores propostos demonstraram sua efetividade e superioridade com relação tanto aos classificadores individualmente quanto aos demais métodos testados.

**Palavras-Chave:** reconhecimento de padrões, seleção dinâmica de classificadores, dissimilaridade, imagem microscópica, espécie florestal, madeira.

### ABSTRACT

The exploitation of natural resources and their scarcity have led to a rational use of these materials, regardless of their origin and application. Among these resources, wood has attracted great interest, mainly because it is often extracted from native forests and the influence of these forests on the planet. Commercial transactions involve large amounts of wood and are susceptible to fraud where a wood trader might mix a noble species with cheaper ones, or even try to export wood whose species is endangered. Buyers must certify they are buying the correct material while supervising agencies have to certify that wood has been not extracted irregularly from forests. Identifying a log or a piece of timber outside its natural environment (the forest) is not an easy task. The high number of species, the lack of well-trained specialists, the exhaustive process of recognition and loss of natural features such as leaves, bark and color make it even more difficult to ensure the authenticity of the woods. In this context, this work is focused on building a robust system for classification of forest species using the textural features present in wood microscopic images, a representation in the dissimilarity space and multiple classifier systems. To do that, different representations for the textural characteristics were tried out. We also attempted to define the best values for the parameters used to build the classifiers in the dissimilarity space, which would allow the use of the classification models for species not considered during their training. Intending to increase recognition rates, we proposed and evaluated different methods to select and/or combine classifiers. In this context, we also evaluate all obtained results at different levels defined by botany, as sometimes it is not necessary to do it at the species classification level. We tested the proposed strategies and all methods on a database of images built for the development of this work. Finally, the proposed strategies and methods for dynamic classifier selection have demonstrated theirs effectiveness and superiority over individual classifiers and the other tested methods.

**Keywords:** pattern recognition, dynamic classifier selection, dissimilarity, microscopic image, forest specie, wood.

## LISTA DE FIGURAS

1.1	Semelhanças entre plantas de espécies diferentes: (a) <i>Cedrus libani</i> , (b) <i>Melia azedarach</i> , (c) <i>Pseudotsuga macrolepsis</i> e (d) <i>Simaruba amara</i> ,	21
1.2	Amostras da Madeira de <i>Taxodium distichum</i> : (a) Brasil e (b) EUA	22
2.1	Sistema para o reconhecimento de padrões (Baseado em Duda et al. [25])	26
2.2	Texturas decorrentes da Anatomia da Madeira: (a) <i>Cephalotaxus drupacea</i> , (b) <i>Chamaecyparis pisifera</i> , (c) <i>Larix sp</i> , (d) <i>Keteleeria fortunei</i> , (e) <i>Tsuga sp</i> , (f) <i>Eschweilera matamata</i> , (g) <i>Copaifera trapezifolia</i> , (h) <i>Lonchocar</i> -	
	pus subglaucencens, (i) Parapiptadenia rigida, (j) Tabebuia rosea alba, (k) Murcia racemulosa, (l) Rhamnus frangula, (m) Prunus sellowii, (n) Melia	
	azedarach e (o) Swietenia macrophylla.	27
2.3	Pontos de observação: (a) planos de corte; (b) estruturas macroscópicas no	
	plano de corte X	28
2.4	Gimnosperma: Pinus elliottii	30
2.5	Angiosperma: Porcelia macrocarpa	31
2.6	Exemplos de textura da base Brodatz [11]: (a) ráfia; (b) areia; (c) cerca de	
	madeira; (d) tijolos; (e) casca de árvore	32
2.7	Cálculo do padrão LBP para a região sobreposta por uma máscara $3{\times}3$	
	([90], p. 2).	34
2.8	Operador $LBP_{P,R}$ extendido para $P$ vizinhos e raio $R$ ([90], p. 2)	35
2.9	Diferentes primitivas detectadas pelo operador LBP ([79], p. 4)	35
2.10	$LBP_{P,R}^{ri}$ : a rotação das imagens em $\alpha$ graus é refletida nas vizinhanças	
	circulares de seus pontos (x,y) ([1], p. 65). $\dots \dots \dots \dots \dots \dots \dots$	36
2.11	Descritor SIFT: (a) aplicação da máscara na imagem e obtenção dos gradi- entes para cada direção na região sobreposta; (b) acúmulo dos gradientes	
	para cada subregião para as oito direções.	40
2.12	Imagem integral: ilustração do cálculo da soma dos pixels contidos em uma	
	subregião DBCA da imagem com apenas três operações de adição	42
2.13	Janela deslizante de orientação que com ângulo $\pi/3$	42
2.14	Descritor SURF: (a) aplicação da máscara $8 \times 8$ alinhada com a orientação iden-	
	tificada e obtenção dos gradientes para cada direção na região sobreposta da	
	imagem; (b) acúmulo dos gradientes para cada subregião	43
2.15	Processo de definição das regiões extremas. Considere a imagem original	
	em (a) Porcelia macrocarpa. Após esta ser convertida para níveis de cinza,	
	diferentes limiares são aplicados e diferentes imagens binarizadas são gera-	
	das para a identificação das regiões extremas. As imagens (b) a (h) il ustram	
	os resultados para os limi ares 31, 62, 93, 124, 155 e 186 $\ldots$ $\ldots$ $\ldots$ $\ldots$	44

2.16	Geração de GLCMs: (a) fragmento considerado da imagem com apenas cinco níveis de cinza; (b) GLCM para $0^{0}$ ; e (c) GLCM para $45^{0}$	47
2.17	Bancos de Filtros de Gabor: imagens das partes reais considerando cinco escalas ( $\nu = [0, 4]$ ) e oito orientações ( $\mu = [0, 7]$ ), $\sigma = 2\pi$ , $k_{max} = \pi/2$ e	
	$f = \sqrt{2}$ .	49
2.18	Cálculo dos vetores de dissimilaridade $Z_{i,j}$ : (a) amostras positivas; (b)	
	amostras negativas (Baseado em Hanusiak <i>et al.</i> [43])	51
2.19	Transformação de um problema $n$ -dimensional (a) e (c) para bidimensional	
	(b) e (d) $[124, 125]$	52
2.20	Invariância à distribuição das amostras entre as classes: (a) curvas ROC	
	idênticas para 'taxa de erro igual' ( <i>Equal Error Rate</i> - EER, Equação 2.45);	
	(b) curvas para a relação precisão e $taxa tp$ (Baseado em [31], p. 865)	54
2.21	Matriz de confusão bidimensional representando os acertos (diagonal prin-	
	cipal) e os erros (diagonal secundária) de cada classificador ([31], p. 862).	54
2.22	Possíveis fases para MCSs	56
2.23	Borda <i>count</i>	59
2.24	Alternativas para a seleção de classificadores [64]: (a) seleção estática de agrupamento; (b) seleção dinâmica de classificador; e (c) seleção dinâmica	
	de agrupamento.	62
2.25	KNOBA [64, 65]: (a) ELIMINATE: $e$ (b) UNION	68
-		
4.1	Modelo proposto com base na seleção dinâmica de classificadores no espaço	
4.1	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	81
4.1 4.2	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	81
4.1 4.2	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	81
4.1 4.2	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	81 90
<ul><li>4.1</li><li>4.2</li><li>4.3</li></ul>	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	81 90
<ul><li>4.1</li><li>4.2</li><li>4.3</li></ul>	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	81 90
<ul><li>4.1</li><li>4.2</li><li>4.3</li></ul>	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	81 90 92
<ul><li>4.1</li><li>4.2</li><li>4.3</li><li>4.4</li></ul>	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	81 90 92
<ul><li>4.1</li><li>4.2</li><li>4.3</li><li>4.4</li></ul>	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	<ul><li>81</li><li>90</li><li>92</li><li>94</li></ul>
<ul> <li>4.1</li> <li>4.2</li> <li>4.3</li> <li>4.4</li> <li>4.5</li> </ul>	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	<ul><li>81</li><li>90</li><li>92</li><li>94</li></ul>
<ul> <li>4.1</li> <li>4.2</li> <li>4.3</li> <li>4.4</li> <li>4.5</li> </ul>	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	<ul><li>81</li><li>90</li><li>92</li><li>94</li><li>96</li></ul>
<ul> <li>4.1</li> <li>4.2</li> <li>4.3</li> <li>4.4</li> <li>4.5</li> <li>4.6</li> </ul>	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	<ul><li>81</li><li>90</li><li>92</li><li>94</li><li>96</li></ul>
<ul> <li>4.1</li> <li>4.2</li> <li>4.3</li> <li>4.4</li> <li>4.5</li> <li>4.6</li> </ul>	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	<ul><li>81</li><li>90</li><li>92</li><li>94</li><li>96</li></ul>
<ul> <li>4.1</li> <li>4.2</li> <li>4.3</li> <li>4.4</li> <li>4.5</li> <li>4.6</li> </ul>	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	<ul> <li>81</li> <li>90</li> <li>92</li> <li>94</li> <li>96</li> <li>97</li> </ul>
$ \begin{array}{c} 4.1 \\ 4.2 \\ 4.3 \\ 4.4 \\ 4.5 \\ 4.6 \\ 4.7 \\ \end{array} $	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	<ul> <li>81</li> <li>90</li> <li>92</li> <li>94</li> <li>96</li> <li>97</li> </ul>
<ul> <li>4.1</li> <li>4.2</li> <li>4.3</li> <li>4.4</li> <li>4.5</li> <li>4.6</li> <li>4.7</li> </ul>	Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação	<ul> <li>81</li> <li>90</li> <li>92</li> <li>94</li> <li>96</li> <li>97</li> </ul>

5.1	Avaliação da influência dos cantos escuros: (a) microscópio Olympus modelo
	CX40, (b) imagem original e (c) imagem em escala de cinza com a identificação
	dos recortes utilizados
5.2	Avaliação da influência do número de amostras por espécie florestal e re-
	ferências por amostra nas taxas de reconhecimento
5.3	Avaliação da influência do número de espécies florestais do conjunto de
	treinamento nas taxas de reconhecimento. $\ldots$
5.4	Avaliação da influência do número de espécies florestais candidatas do con-
	junto de teste nas taxas de reconhecimento. $\ldots$
5.5	Distância média e desvio padrão entre as instâncias questionadas $\mathbb{Z}_{q,j}$ e os
	centróides $(C+$ ou $C-)$ das classes selecionadas nos diferentes espaços de
	representação
5.6	Distância média e desvio padrão entre as instâncias questionadas e os
	centróides das classes selecionadas, considerando todos os espaços de re-
	presentação
5.7	Distância média e desvio padrão entre as instâncias questionadas $Z_{q,j}$ e as
	fronteiras dos modelos $f$ nos diferentes espaços de representação 117
5.8	Distância média e desvio padrão entre as instâncias questionadas $Z_{q,j}$ e as
	fronteiras dos modelos $f,$ considerando todos os espaços de representação 118
5.9	Dispersão média das referências $Z_{u,v}$ e desvio padrão nos diferentes espaços
	de representação
5.10	Dispersão média e desvio padrão das referências considerando todos os
	espaços de representação
5.11	Taxas de reconhecimento alcançadas pelos métodos OLA e LCA para a
	regra de fusão máximo e as vizinhanças entre um e 75 elementos 122
5.12	Gráfico ROC para as vizinhanças com os melhores resultados para os
	métodos OLA e LCA e regra de fusão máximo
5.13	Taxas de reconhecimento alcançadas pelos métodos <i>a priori</i> e <i>a posteriori</i>
F 1 4	para a regra de fusao máximo e as vizinhanças entre um e 75 elementos 123
5.14	Gráfico ROC para as vizinhanças com os melhores resultados para os
F 1F	metodos <i>a priori</i> e <i>a posteriori</i> e regra de fusao maximo
5.15	Taxas de reconhecimento alcançadas pelos metodos MCB OLA e MCB
F 10	LCA para a regra de fusao maximo e as vizinhanças entre um e 75 elementos. 125
5.10	Grafico ROC para as vizinhanças com os melhores resultados para os $(1 + 1) = MCD = O[A] + MCD = O[A]$
F 17	metodos MCB OLA e MCB LCA e regra de rusao maximo
0.17	Taxas de reconnecimento alcançadas pelos metodos MCB <i>a priori</i> e MCB
	<i>a posteriori</i> para a regra de iusao maximo e as vizinnanças entre um e 75
510	Créfico POC para as vizinhances com os molheres resultados para es
0.18	mátodos MCB a priori o MCB a nosteriori o rorro do fueño márimo
	metodos mod <i>a priori</i> e mod <i>a posteriori</i> e regra de lusão maximo 120

5.19	Taxas de reconhecimento alcançadas pelos métodos KNORA-E e KNORA-	
	U para as regras de fusão máximo e média e as vizinhanças entre um e 75	
	elementos.	128
5.20	Gráfico ROC para as vizinhanças com os melhores resultados para os	
	métodos KNORA-E e KNORA-U e as regras de fusão máximo e média,	
	respectivamente.	128
5.21	Taxas de reconhecimento alcançadas pelo métodos baseados no critério	
	LCA para a delimitação da vizinhança da instância questionada, a regra	
	de fusão máximo e as vizinhanças entre um e 75 elementos	130
5.22	Gráfico ROC para as vizinhanças com os melhores resultados para os	
	métodos baseados no critério LCA para a delimitação da vizinhança da	
	instância questionada e a regra de fusão máximo	131
5.23	Taxas de reconhecimento alcançadas pelos métodos $a\ posteriori$ e MCB $a$	
	posterioripara a regra de fusão máximo, com diferentes subconjuntos com	
	10, 7 e 5 classificadores e as vizinhanças entre um e 75 elementos. $\ldots$ .	132
5.24	Taxas de reconhecimento alcançadas com as regras de fusão máximo e	
	média para as vizinhanças entre um e 75 elementos: (a) OLA e LCA, (b)	
	<i>a priori</i> e <i>a posteriori</i> , (c) MCB OLA e MCB LCA, e (d) MCB <i>a priori</i> e	
	MCB a posteriori	134
5.25	Exemplos de erros de classificação ocorridos por espécies florestais: (a)	
	Pinus caribaea; (b) Tibouchiana sellowiana; (c) Erisma uncinatum	137
A.1	Amostras da Base de Imagens: (a) Gimnosperma; (b) Angiosperma	157

A.2 Amostras de 'Araucaria angustifolia': (a) Microscópica; (b) Macroscópica. . 157

## LISTA DE TABELAS

3.1	Síntese dos resultados apresentados para classificação de madeira	79
4.1	Descritores utilizados, dimensões de seus vetores de características, tempo médio de extração e complexidade algorítmica	86
$5.1 \\ 5.2$	Resultados individuais dos classificadores e oráculo acumulado Dimensões das faixas excluídas das imagens originais e dimensões das ima-	105
5.3	gens finais (em pixels) ilustradas na Figura 5.1(c)	107
5.4	originais com o descritor LPQ	108
5.5	tribuídos pelas imagens com o descritor SURF-128	109
5.6	sultados foram apresentadas nas Tabelas 5.1 e 5.4	109
5.7	do algoritmo SURF disponibilizada pela ferramenta MatLab [89] Melhores taxas de reconhecimento obtidas para as variações dos experi-	109
5.8	mentos desta seção	110
5.0	dores, sendo todos alcançados pela regra de combinação máximo. $\dots$	113
0.9	derados nos experimentos com seleção dinâmica de classificadores baseada	
5.10	nas distâncias $d(Z_{q,j}, C)$	115
5.11	nos diferentes espaços de representação	116
	mente classificadas e os centróides $(C+ \text{ ou } C-)$ das classes selecionadas nos diferentes espaços de representação	116
5.12	Taxa de seleção de cada classificador para os diferentes subconjuntos consi- derados nos experimentos com seleção dinâmica de classificadores baseada	
5.13	nas distâncias $d(Z_{q,j}, f)$	117
	mente classificadas e as fronteiras $f$ nos diferentes espaços de representação	. 118
5.14	Estatísticas das distâncias entre as instâncias questionadas $Z_{q,j}$ incorreta-	

mente classificadas e as fronteiras fnos diferentes espaços de representação. 119

5.15	Taxa de seleção de cada classificador para os diferentes subconjuntos consi-	
	derados nos experimentos com seleção dinâmica de classificadores baseada	
	na dispersão das referências $Z_{u,v}$	120
5.16	Estatísticas das dispersões das referências $Z_{u,v}$ nos diferentes espaços de	
	representação para os classificadores corretamente selecionados. $\ .\ .\ .$ .	121
5.17	Estatísticas das dispersões das referências $Z_{u,v}$ nos diferentes espaços de	
	representação para os classificadores incorretamente selecionados. $\ .\ .$ .	121
5.18	Taxas de seleção dos classificadores para o método KNORA-E, conside-	
	rando os 30 e os 90 vizinhos dos conjuntos de validação mais próximos às	
	instâncias questionadas.	129
5.19	Caracterização dos métodos segundo os critérios: (a) definição da vizi-	
	nhança, (b) delimitação da vizinhança e (c) seleção do classificador	129
5.20	Taxas de seleção dos classificadores para cada um dos métodos baseados	
	no critério LCA para a delimitação da vizinhança de $s_q$	131
5.21	Taxas de seleção dos classificadores para os métodos $a \ posteriori$ e MCB	
	$a\ posteriori,$ considerando os oito vizinhos dos conjuntos de validação mais	
	próximos às instâncias questionadas, além de subconjuntos com os 10, 7 e	
	5 melhores classificadores. $\ldots$	133
5.22	Taxas de reconhecimento para os níveis definidos pela Botânica espécie,	
	gênero, família e filo com, respectivamente, 112, 85, 30 e 2 classes 'reais'. $% \left( 1,1,2,2,2,2,2,2,2,2,2,2,2,2,2,2,2,2,2,2$	135
5.23	Comparação dos resultados obtidos pelos modelos de classificação cons-	
	truídos para distinguir as 112 espécies florestais e do processo de classi-	
	ficação hierárquica seguindo os níveis definidos pela Botânica. $\ldots\ldots\ldots$	136
5.24	Síntese dos erros de classificação ocorridos para as espécies florestais da	
	Figura 5.25	137
A 1	Gimnospermas: classificação Botânica das espécies	158
A 2	Angiospermas: classificação Botânica das espécies	150
11.4		103

## LISTA DE ABREVIATURAS

AUC	Area Under a ROC Curve
CAIRO	Centre for Artificial Intelligence and Robotics
DBI	Davies-Bouldin Index
$\mathrm{DFT}$	Discrete Fourier Transform
DRIFT	Diffuse Reflectance Infrared Fourier Transform
DWT	Discrete Wavelet Transform
EER	Equal Error Rate
$\mathbf{ER}$	Extremal Region
EUA	United States of America
FN	False Negative
FP	False Positive
FRIM	Forest Research Institute of Malaysia
GLCM	Gray Level Co-occurrence Matrix
HSV	Hue, Saturation and Value
IAWA	International Association of Wood Anatomists
$k \mathrm{NN}$	k-Nearest Neighbors
KNORA	K-Nearest-ORAcle
K-NPFDA	functional Nadaraya-Watson kernel nonparametric method
LBP	Local Binary Pattern
LBP-HF	LBP Histogram Fourier Features
$LBP^{ri}$	LBP with rotation invariant
$LBP^{riu2}$	LBP with rotation invariant uniform 2 pattern code
LBP-TOP	LBP from Three Orthogonal Planes
$LBP^{u2}$	LBP with uniform 2 pattern code
LCA	Local Class Accuracy
LDC	Linear Discriminant Classifier
LPQ	Local Phase Quantization
LPQ-TOP	LPQ from Three Orthogonal Planes
MC	Confusion Matrix
MCB	Multiple Classifier Behaviour
MCS	Multiple Classifier Systems
MLP	Multilayer Perceptron
MSER	Maximally Stable Extremal Regions
NIR	Near-Infrared
OLA	Overall Local Accuracy
OpenCV	Open Source Computer Vision Library
PCA	Principal Component Analysis
PLS	Partial Least Squares
РО	Ponto de Operação
QDC	Quadratic Discriminant Classifier
RGB	Red, Green, Blue
RNA	Artificial Neural Network
	Continua na próxima página

	continuação da página anterior
ROC	Receiver Operator Characteristics
SIFT	Scale Invariant Feature Transform
SOM	Self-Organizing Maps
STFT	Short-Term Fourier Transform
SVM	Support Vector Machine
SURF	Speed-Up Robust Feature
TEXTEL	TEXture ELement
TN	True Negative
TP	True Positive
UFPR	Federal University of Parana
VLBP	Volume Local Binary Pattern

# SUMÁRIO

RI	ESUI	МО		iv
$\boldsymbol{A}$	BST	RACT		$\mathbf{v}$
$\mathbf{LI}$	STA	DE FI	IGURAS	ix
$\mathbf{LI}$	STA	DE T	ABELAS	xi
$\mathbf{LI}$	STA	DE A	BREVIATURAS	xii
1	INT	RODU	JÇÃO	17
	1.1	Motiva	ıção	17
	1.2	Desafie	DS	20
	1.3	Objeti	vos	22
	1.4	Contri	buições	23
	1.5	Estrut	ura do Trabalho	24
<b>2</b>	FUI	NDAM	ENTAÇÃO TEÓRICA	26
	2.1	Anator	mia da Madeira	27
		2.1.1	Principais Estruturas definidas pela Anatomia da Madeira $\ .\ .\ .$	28
		2.1.2	Grupos Vegetais produtores de Madeira	29
	2.2	Extraç	ão e representação de características texturais $\ldots \ldots \ldots \ldots \ldots$	32
		2.2.1	Métodos Estruturais	33
		2.2.2	Métodos Estatísticos	45
		2.2.3	Métodos Espectrais	48
	2.3	Repres	sentação das relações entre objetos por meio do conceito de dissimi-	
		laridad	le	50
		2.3.1	Vetores de dissimilaridade e a mudança na representação dos pro-	
			blemas de espaços $n$ -dimensionais para o espaço bidimensional $\ . \ .$	51
		2.3.2	Características de Receptor-Operador	53
	2.4	Sistem	as compostos por Múltiplos Classificadores	56
		2.4.1	Combinação de Classificadores	57
		2.4.2	Seleção de Classificadores	61
	2.5	Consid	lerações Finais	69
3	ESI	ADO	DA ARTE EM RECONHECIMENTO DE MADEIRA	70
	3.1	Revisã	o da Literatura	70
	3.2	Consid	lerações Finais	78

4	METODOLOGIA						
	4.1	Visão	geral da arquitetura proposta	80			
	4.2	Extra	ção de características e avaliação dos descritores	82			
		4.2.1	Família de descritores LBP	83			
		4.2.2	Família de descritores LPQ	83			
		4.2.3	SIFT	83			
		4.2.4	SURF	. 84			
		4.2.5	MSER-SURF	. 84			
		4.2.6	GLCM	85			
		4.2.7	Filtros de Gabor	85			
		4.2.8	Resumo dos descritores utilizados	85			
	4.3	Classi	ficação: avaliação dos parâmetros inerentes à representação baseada				
		em ve	tores de dissimilaridade	. 86			
	4.4	Seleçã	o de Classificadores	89			
		4.4.1	Métodos de seleção dinâmica de classificadores baseados na distri-				
			buição das instâncias no espaço de dissimilaridade	91			
		4.4.2	Métodos de seleção dinâmica de classificadores baseados nas de-				
			cisões para as vizinhanças das instâncias questionadas	95			
	4.5	Comb	inação de Classificadores	99			
	4.6	Avaliação de Resultados					
		4.6.1	Avaliação das taxas de reconhecimento nos diferentes níveis defini-				
			dos pela Botânica	102			
		4.6.2	Uso de meta-classes para a abordagem de classificação hierárquica .	102			
	4.7	Consie	derações Finais	104			
<b>5</b>	RE	SULTA	ADOS	105			
	5.1	Avalia	ações dos descritores: melhores resultados individuais $\ldots \ldots \ldots$	105			
		5.1.1	Avaliação da influência dos cantos escuros das imagens nas taxas				
			de reconhecimento	107			
		5.1.2	Avaliação quanto ao uso de pontos fixos para os descritores baseados				
			em pontos de atenção	108			
	5.2	Classi	ficação: avaliação dos parâmetros inerentes à representação baseada				
		em ve	tores de dissimilaridade	110			
	5.3	Seleçã	o e Combinação de Classificadores	112			
		5.3.1	Combinação de agrupamentos de classificadores	112			
		5.3.2	Métodos de seleção dinâmica de classificadores baseados na distri-				
			buição das instâncias no espaço de dissimilaridade	113			
		5.3.3	Métodos de seleção dinâmica de classificadores baseados nas de-				
			cisões para as vizinhanças das instâncias questionadas	121			
		5.3.4	Combinação dos classificadores selecionados	133			

	5.4	Perspectivas empregadas durante a avaliação dos resultados	134
		5.4.1 Avaliação dos resultados nos diferentes níveis definidos pela Botânica	134
		5.4.2 Uso de meta-classes para a abordagem de classificação hierárquica .	135
	5.5	Análise dos Erros de Classificação	136
	5.6	Considerações Finais	138
(	6 CO	NSIDERAÇÕES FINAIS	139
	6.1	Discussão	139
	6.2	Trabalhos Futuros	142
	REFE	RÊNCIAS	155
	A BA	SE DE IMAGENS	156

## CAPÍTULO 1

## INTRODUÇÃO

A progressiva escassez dos recursos naturais tem conduzido a um uso cada vez mais racional destes materiais, independente de sua origem e aplicação. Dentre tais recursos, a madeira e sua exploração têm despertado grande interesse, principalmente por ser, muitas vezes, extraída de florestas nativas e da influência que estas florestas têm sobre o planeta. Diante da importância deste tema, o presente trabalho foca a construção de um sistema robusto para a identificação de espécies florestais por meio do reconhecimento de imagens microscópicas de sua madeira, da representação no espaço de dissimilaridade e da seleção dinâmica de classificadores. O presente capítulo apresenta a motivação do trabalho, focando diversos aspectos e perspectivas quanto ao tema. Destaca-se também os desafios a serem transpostos, os objetivos que delimitam o escopo do trabalho, seus resultados e contribuições, além da estrutura geral deste relatório.

### 1.1 Motivação

A madeira é um dos materiais mais amplamente utilizados pelo ser humano, tanto em termos de volume quanto de finalidades. Neste sentido, Ioannou *et al.* [55] 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 [49, 50, 55, 95, 140].

Como resultado de tais influências, algumas espécies produzem madeiras mais resistentes a diversos agentes externos e ao tempo, possuem valores comerciais superiores e são empregadas na fabricação de produtos que demandam maior vida útil. De outra forma, há espécies cujas madeiras são empregadas para auxiliar a execução de tarefas, tal como palanques e tábuas para caixarias e suporte, possuem vida útil curta e são bem mais baratas.

A exploração de matas nativas distantes dos grandes centros urbanos industrializados justifica a necessidade de reconhecer os tipos de madeira e, consequentemente, sua origem no decorrer do processo de extração e transformação [55]. 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. A otimização deste recurso também se deve por esta matéria-prima constituir cerca de 40% dos custos de produção de muitos produtos industrializados, bem como pela elevação de seus preços devido à crescente escassez [93].

Tomando o fato das negociações alcançarem grandes volumes financeiros e extrapolarem fronteiras em todo o globo, fraudes podem decorrer de misturas de diferentes tipos de madeira, das mais nobres às menos valorizadas, e da tentativa de extração e exportação de madeira proveniente de espécies sujeitas à extinção. Estas fraudes, relacionadas à entrega de materiais diferentes daqueles acordados previamente, podem implicar em grandes prejuízos para os envolvidos e comprometer a qualidade do produto final devido às diferentes características apresentadas por cada espécie.

A correta identificação de espécies florestais para garantir a autenticidade de peças de madeira é de grande importância para vários segmentos da sociedade, desde os produtores, passando por indústrias, governo e culminando no consumidor final. Compradores devem se certificar de que estão recebendo o material correto, enquanto agências supervisoras precisam garantir que não haja madeira extraída irregularmente das florestas.

Ao se considerar as divisões da Botânica sob um contexto mais amplo, Angiospermas e Gimnospermas constituem basicamente os dois principais grupos em que se encontram as espécies produtoras de madeira. Estas espécies podem ser classificadas de acordo com suas características anatômicas, estruturais e botânicas (*vide* seção 2.1). Porém, além destas características, o número de variáveis envolvidas na formação da planta e de sua estrutura é bastante vasto. Pode-se encontrar, inclusive, diferenças muito sutis em estruturas apresentadas em amostras de diferentes espécies e também diferenças maiores em estruturas apresentadas em amostras de uma mesma espécie [14].

Embora exista uma série de características (folhas, frutos, sementes, cores, odor, dentre outras), ao se retirar os troncos das florestas e processá-los por meio de cortes perde-se a maioria delas. Assim, o reconhecimento torna-se mais difícil, senão inviável a olho nu, sendo necessário especialistas com conhecimento quanto a características não tão aparentes, tais como as estruturas celulares presentes em cada espécie.

Também tem-se claro que o número de especialistas não é suficiente para atender o mercado e que o treinamento de novos profissionais consome tempo, pois estes precisam alcançar um nível mínimo de maturidade. Para agravar ainda mais esta situação, a inserção de etapas executadas manualmente pode influenciar nos resultados finais do processo de classificação, mesmo com especialistas que dominem os conhecimentos da área e que tal processo esteja padronizado. Além da subjetividade, tais influências decorrem de vários fatores inerentes ao processo, o qual é caracterizado como repetitivo, monótono e demorado, além de requerer alto grau de concentração [22, 115, 119].

De forma geral, os aspectos identificados têm despertado a atenção de muitos estudiosos das áreas de Ciência da Computação, Ciências Biológicas e Engenharia Florestal, bem como das indústrias que empregam madeira em seu processo de produção. Independente dos aspectos focados pelos interessados, a dificuldade do ser humano em alcançar e/ou manter elevadas taxas de reconhecimento de madeira durante longos períodos de trabalho justifica a necessidade de sistemas que automatizem ao menos algumas partes do processo.

Sistemas dotados de visão computacional certamente já beneficiam este amplo público e são uma opção interessante para identificação de defeitos decorrentes de irregularidades externas aos troncos, mas ainda ocultas pela casca [15, 16, 72, 123, 134]; detecção e classificação de defeitos em placas de madeira [13, 22, 30, 41, 74, 119]; otimização de cortes de peças de madeira [19, 93, 115]; e inspeção de produtos finais [58, 92]. No entanto, estas aplicações ainda sofrem restrições devido à deficiência de pesquisas na área e à falta de bases de dados com imagens de madeiras [4, 55, 59].

Além dos focos anteriormente identificados, pesquisas também têm sido desenvolvidas com o intuito de identificar espécies florestais (*vide* capítulo 3). No entanto, tais pesquisas geralmente empregam classificadores tradicionais baseados em múltiplas classes e bases de imagens com um número muito reduzido de espécies florestais, visto a grande diversidade existente [12, 55, 59, 67, 71, 73, 95, 97, 98, 99, 102, 107, 110, 111, 116, 133, 135, 137, 138, 139, 147]. Tais soluções geralmente não são adequadas a problemas como o abordado neste trabalho devido a seu elevado número de classes, o qual chega a milhares de espécies florestais [128].

Os fatores citados no parágrafo anterior limitam a aplicação dos modelos de classificação às espécies utilizadas durante o treinamento dos classificadores. Assim, diante da necessidade de incluir uma única espécie àquelas previamente utilizadas, deve-se descartar os modelos construídos e reconstruí-los, justamente a fase de classificação que demanda maior custo [128]. A partir das considerações anteriores e da inviabilidade de se construir modelos que contemplem todas as espécies florestais existentes, o presente trabalho investiga a robustez propiciada por sistemas baseados em seleção dinâmica de classificadores construídos no espaço de dissimilaridade.

A representação no espaço de dissimilaridade (*vide* Seção 2.3) transforma problemas com n classes em problemas com apenas duas classes e reduz suas complexidades originais. Também se tem a independência que esta representação propicia ao modelo com relação às classes empregadas nas fases de treinamento e classificação, além dos resultados obtidos por diversos estudos em variados domínios de aplicação [27, 26, 38, 57, 113, 114, 129], dentre os quais se destacam o reconhecimento de assinaturas [7, 28, 29, 70], manuscritos [43, 132], faces [117] e bio-criptografia [28].

Assim como a representação no espaço de dissimilaridade, sistemas compostos por múltiplos classificadores (*Multi-Classifier Systems* - MCSs) têm sido utilizados para alcançar maior robustez e melhorar as taxas individuais de reconhecimento dos classificadores. MCSs são apresentados em maiores detalhes na Seção 2.4. Estes exploram a ideia de conjuntos formados por diferentes classificadores, os quais podem oferecer informações complementares para aumentar a efetividade geral do processo de reconhecimento [66, 128]. Tal contexto tem levado à crença de que, com a aplicação em conjunto e simultânea de características e classificadores de diferentes tipos, as taxas de classificação poderiam ser melhoradas [35, 146, 37, 36].

Basicamente, combinação de classificadores e seleção dinâmica de classificadores são as duas principais abordagens para MCSs. Na primeira, as amostras questionadas são submetidas aos classificadores, de forma individual e em paralelo. A partir disso, as decisões individuais são combinadas seguindo alguma regra para alcançar uma decisão global [25, 56, 60, 61]. Dentre suas desvantagens, destaca-se o fato da maioria de seus métodos assumirem que os classificadores do conjunto cometem erros de classificação independentes entre si. Embora esta premissa seja necessária para garantir o aumento da acurácia da classificação com relação às acurácias individuais dos classificadores, ao se considerar aplicações reais, geralmente é difícil projetar e treinar um conjunto de classificadores independentes [35, 62, 65, 63, 64].

A seleção dinâmica de classificadores, por sua vez, tenta identificar o classificador com maior probabilidade de classificar corretamente uma amostra questionada qualquer. Dado que apenas um classificador é selecionado, automaticamente sua predição será assumida como a decisão final para a amostra em questão [33, 35, 65, 63, 64, 146]. Como principal vantagem, os métodos baseados na seleção dinâmica de classificadores não precisam assumir a premissa quanto à independência dos erros dos classificadores. Contudo, precisam que sejam estabelecidos os critérios utilizados para a seleção dos classificadores [33].

Mesmo diante da inviabilidade de se construir um modelo totalmente genérico para a identificação das milhares de espécies florestais existentes, o presente trabalho busca responder a seguinte questão: É possível construir um sistema robusto para a classificação de espécies florestais utilizando as características texturais presentes nas imagens microscópicas de madeira, a representação no espaço de dissimilaridade e MCSs? Diante desta questão também surgem as seguintes questões secundárias: Quais são as melhores representações para as características texturais utilizadas na construção de tal modelo de classificação? Para os classificadores construídos no espaço de dissimilaridade, qual a influência da quantidade de classes, amostras por classe e referências por amostra no processo de classificação? Quais as vantagens e desvantagens quanto ao uso de MCSs no processo de classificação? Ao se considerar o elevado número de espécies florestais existentes, qual a influência de se avaliar as taxas de reconhecimento do sistema nos diferentes níveis filo, família, gênero e espécie, definidos pela Botânica?

### 1.2 Desafios

O principal desafio deste trabalho compreende a construção de um sistema robusto para a identificação de espécies florestais utilizando as características texturais presentes nas imagens microscópicas de madeira, a representação no espaço de dissimilaridade e MCSs. Tal problema é caracterizado pela existência de um elevado número de classes, cada qual com um reduzido número de amostras. Embora tal situação ocorra com frequência para problemas reais, não foram encontradas referências a bases de imagens com tais características para madeira e/ou espécies florestais. Neste sentido, destaca-se ainda que não foi encontrada qualquer referência a bases de imagens microscópicas de madeira. Diante da falta de recursos disponíveis para o desenvolvimento do trabalho, a construção da base de imagens utilizada já caracterizou um desafio, principalmente quando se compara a quantidade e variedade de espécies nela compreendida (*vide* Tabelas A.1 e A.2, no Apêndice A) com as demais bases encontradas na literatura (vide Tabela 3.1, no Capítulo 3).

A base empregada compreende 112 espécies florestais diferentes, cada uma com 20 imagens, num total de 2.240 imagens. Algumas destas espécies tiveram sua origem no decorrer do processo de evolução das plantas, situam-se nos limites entre os grupos de Gimnospermas e Angiospermas e apresentam características comuns a ambos. Adicionando maior grau de complexidade a este cenário, a combinação dos diferentes tipos de células em diferentes proporções (*vide* Seção 2.1) com fatores internos e externos às plantas (geralmente não passíveis de serem controlados) influenciam profundamente a formação das estruturas celulares da madeira. Tais influências estão representadas na base de imagens construída e algumas delas podem ser percebidas nas ilustrações deste trabalho.

Dentre os fatores internos, tem-se a localização da amostra no tronco, os defeitos, a composição química e o volume da matéria lenhosa. Para os fatores externos, destacamse as condições ecológicas e climáticas do ambiente em que a planta cresce, as pragas e doenças, bem como a concorrência por espaço e demais recursos para o desenvolvimento das plantas. Assim, podem haver pequenas variações entre amostras de diferentes espécies e também variações maiores entre amostras pertencentes a uma mesma espécie. Tal influência pode até mesmo conduzir a situações em que diferentes partes de uma mesma amostra (planta e/ou espécie) não sejam idênticas e, consequentemente, não possuam as mesmas possibilidades de aplicação [14].

Comparando as quatro imagens da Figura 1.1, identifica-se semelhanças entre as Figuras 1.1(a) e 1.1(b) e entre as Figuras 1.1(c) e 1.1(d), como se tais pares pertencessem às mesmas espécies. Porém, 1.1(a) e 1.1(c) são classificadas como Gimnospermas, enquanto 1.1(b) e 1.1(d) são classificadas como Angiospermas. No outro extremo, as Figuras 1.2(a) e 1.2(b) ilustram a presença de diferenças nas estruturas celulares de plantas pertencentes a uma mesma espécie. A primeira foi obtida de uma planta que cresceu no Brasil e a segunda de uma planta que cresceu nos Estados Unidos da América (EUA) e, possivelmente, tais diferenças são decorrentes de fatores geográficos e climáticos.



**Figura 1.1:** Semelhanças entre plantas de espécies diferentes: (a) *Cedrus libani*, (b) *Melia azedarach*, (c) *Pseudotsuga macrolepsis* e (d) *Simaruba amara*.

Além dos fatores identificados anteriormente, frequentemente há um número muito reduzido de exemplares por espécie florestal disponível para serem tomados como re-



Figura 1.2: Amostras da Madeira de Taxodium distichum: (a) Brasil e (b) EUA.

ferências. Tal restrição limita a capacidade de generalização dos modelos elaborados e suas aplicações a diferentes configurações. Neste sentido, tem-se claro que o corte de plantas pertencentes a espécies em iminente extinção apenas para a coleta de tais amostras não é plausível. Ao mesmo tempo, mesmo que se sacrificasse uma única planta para coletar algumas amostras, diante do conjunto de fatores que influenciam na composição da madeira e em seu padrão textural, provavelmente não se alcançaria o grau de generalização necessário.

Outro desafio durante a construção do sistema compreende a definição dos parâmetros utilizados para gerar os vetores de dissimilaridade durante a mudança da representação do espaço de características para o espaço de dissimilaridade (*vide* Seção 2.3.1). Mesmo diante do limitado número de exemplares, o processo de avaliação dos parâmetros consumiu grande esforço para identificar as melhores alternativas para a quantidade de classes, amostras por classe e referências por amostra a serem utilizadas nas fases de treinamento e classificação. As Seções 4.3 e 5.2 apresentam a metodologia empregada e os resultados obtidos.

Por fim, destaca-se ainda a definição dos critérios para a seleção dinâmica de classificadores. De forma geral, a maioria dos métodos de seleção dinâmica de classificadores utiliza critérios de vizinhança e medidas de distância. No entanto, alguns testes foram realizados tomando medidas de distância entre a instância questionada e seus vizinhos do conjunto de validação como critério de seleção do espaço de representação a ser utilizado para a classificação. Todas as estratégias avaliadas mostraram-se inviáveis, visto que os classificadores aqui considerados foram construídos em espaços *n*-dimensionais diferentes. Ou seja, os testes realizados demonstram a impossibilidade quanto à realização de comparações que envolvam as medidas de distância direta ou indiretamente entre os diferentes espaços de representação, até mesmo quando normalizadas.

### 1.3 Objetivos

O objetivo geral deste trabalho consiste na construção de um sistema robusto para classificação de espécies florestais a partir de características texturais extraídas de imagens microscópicas de sua madeira. Para isso, tal sistema teve como base as técnicas de seleção dinâmica de classificadores, os quais foram construídos no espaço de dissimilaridade.

Para o cumprimento do objetivo geral previamente definido, identificou-se os seguintes objetivos específicos:

- Confeccionar uma base com imagens microscópicas de madeira para o desenvolvimento de pesquisas em classificação de espécies florestais;
- Analisar e testar descritores para o uso em reconhecimento de espécies florestais, considerando as taxas de reconhecimento alcançadas por cada um;
- Analisar a influência dos parâmetros utilizados durante a mudança da representação do espaço de características para o espaço de dissimilaridade, isto é, número de classes, amostras por classe e referências por amostra;
- Propor, analisar e testar métodos de seleção dinâmica de classificadores, considerando os critérios empregados e as taxas de reconhecimento alcançadas para cada uma;
- Analisar as taxas de reconhecimento nos níveis definidos pela Botânica espécies, gênero, família e filo, tendo em vista sua maior representatividade em termos de diferenciação do conjunto de classes existentes na base de imagens construída.

### 1.4 Contribuições

As contribuições deste trabalho podem ser relacionadas aos contextos científico, social e tecnológico.

Sob o contexto científico, a principal contribuição deste trabalho constitui uma nova abordagem para a identificação de espécies florestais por meio de imagens microscópicas de sua madeira. Tal identificação está baseada em descritores texturais e na seleção dinâmica de classificadores construídos no espaço de dissimilaridade. Tal combinação garantiu um modelo de classificação mais robusto que aqueles construídos com a abordagem de classificadores tradicionais e que pode ser utilizado para classificar amostras de espécies inexistentes na base de imagens durante o treinamento dos classificadores. Esta flexibilidade é interessante principalmente por permitir, pelo menos teoricamente, que a base de imagens cresça constantemente sem a necessidade de reconstrução do modelo de classificação.

É importante destacar que não foram encontradas referências quanto à seleção dinâmica de classificadores no espaço de dissimilaridade na literatura, o que faz desta abordagem um importante diferencial para o presente trabalho. Enquanto a seleção no espaço de características ocorreria uma única vez para cada amostra questionada, no espaço de dissimilaridade esta ocorre para cada vetor de dissimilaridade criado para esta amostra questionada e suas referências.

Além do modelo de classificação, foram apresentados e validados três novos métodos para seleção dinâmica de classificadores. Tais métodos apresentaram taxas de reconhecimento equivalentes ou superiores àqueles previamente apresentados por Woods *et al.* [146] e Giacinto e Roli [33]. Embora os três métodos propostos tenham sido aplicados e validados no espaço de dissimilaridade, eles também podem ser aplicados para a seleção dinâmica de classificadores no espaço de características, sem quaisquer alterações.

Diante da dificuldade de acesso às bases de imagens existentes, também foi necessário construir uma base de imagens para o desenvolvimento de pesquisas em classificação de espécies florestais. Esta possui número e variedade de espécies muito superior a qualquer outra encontrada na literatura da área, sendo a única com imagens microscópicas que se tem conhecimento. Publicada em [85], a base de imagens pode ser requisitada para o desenvolvimento de pesquisas no endereço eletrônico http://web.inf.ufpr.br/vri/forest-species-database.

Ainda no contexto científico, destaca-se a proposta quanto à avaliação das taxas de reconhecimento do modelo para diferentes níveis definidos pela Botânica. Esta possibilidade se mostrou interessante ao se considerar que nem todas as situações de identificação obrigam que se chegue ao nível de espécie. Como previamente suposto, confirmou-se a tendência de se obter taxas de reconhecimento melhores nos níveis superiores, devido à redução gradativa do número de espécies e à reunião de agrupamentos menores dos níveis inferiores que apresentam características comuns. Ao mesmo tempo, mostrou-se que o uso destes níveis num processo hierárquico de classificação não contribui para a melhoria das taxas, embora agregue maior complexidade ao processo.

Sob o contexto social, garantiu-se a identificação da espécie florestal, independente de fatores que se perdem com o decorrer do tempo, tais como folhas, frutos, casca, cor e odor, dentre outros. Este foco, considerando características texturais da madeira, permite a identificação da espécie florestal a qualquer momento após a derrubada da árvore. Tal facilidade provê melhores condições de fiscalização para os órgãos governamentais e de certificação dos produtos negociados por particulares, pois estes dependem do auxílio de especialistas que, muitas vezes, não estão presentes ou disponíveis.

Por fim, sob o contexto tecnológico, a principal contribuição é a criação de um sistema robusto para a classificação de espécies florestais. Tal sistema contempla os elementos previamente descritos nesta seção, o que lhe provê importantes diferenciais com relação àqueles propostos por Woods *et al.* [146], Giacinto e Roli [35, 36] e Ko *et al.* [64, 65].

### 1.5 Estrutura do Trabalho

A presente tese está organizado em seis capítulos. O primeiro compreende sua motivação, os desafios enfrentados, os objetivos gerais e específicos, bem como as contribuições desta pesquisa. O Capítulo 2 contempla a fundamentação teórica, os conceitos e os ferramentais empregados. Neste sentido, tem-se uma explanação quanto às espécies florestais e sua classificação pela Botânica. Neste capítulo também são apresentados os descritores utilizados, a representação no espaço de dissimilaridade e dos sistemas baseados em múltiplos classificadores, com seus métodos para seleção e combinação de classificadores.

O Capítulo 3 apresenta uma breve contextualização do atual estado da arte em reconhecimento de madeira. O Capítulo 4 compreende a descrição da metodologia utilizada durante o desenvolvimento do trabalho, dos métodos de seleção dinâmica de classificadores propostos, bem como dos testes realizados e das configurações que geraram as melhores taxas de reconhecimento. O Capítulo 5 contém os resultados alcançados e sua discussão. As considerações finais e os trabalhos futuros são apresentados no Capítulo 6.

## CAPÍTULO 2

# FUNDAMENTAÇÃO TEÓRICA

Um sistema para reconhecimento de padrões (Figura 2.1) contempla as seguintes etapas: aquisição; pré-processamento; segmentação; extração de características; e classificação. Por si só, cada etapa constitui um diferente contexto, possui diferentes níveis de complexidade e envolve conhecimentos específicos próprios, além daqueles inerentes ao domínio de aplicação abordado [21, 39, 112].



Figura 2.1: Sistema para o reconhecimento de padrões (Baseado em Duda et al. [25]).

Considerando os objetivos delimitados no Capítulo 1, o presente trabalho compreende cada uma das etapas identificadas na definição anterior. Neste sentido, este capítulo apresenta brevemente os conteúdos necessários para uma melhor compreensão do escopo envolvido. Inicialmente apresenta-se uma visão quanto à Anatomia da Madeira (Seção 2.1), destacando-se os níveis de classificação definidos pela Botânica, os principais tipos celulares e suas ocorrências. Tais ocorrências e suas frequências produzem padrões visuais distintos (Figura 2.2) e conduzem ao emprego do conceito de textura, bem como das técnicas para extração, representação e descrição das características texturais (Seção 2.2).

A representação de relações entre objetos baseada no conceito de dissimilaridade e *Receiver Operator Characteristics* (ROC) são apresentados na Seção 2.3, sendo importantes diferenciais para o presente trabalho. Por fim, a Seção 2.4 define os sistemas compostos por múltiplos classificadores e destaca as abordagens empregadas para seleção e combinação de classificadores.



Figura 2.2: Texturas decorrentes da Anatomia da Madeira: (a) Cephalotaxus drupacea, (b) Chamaecyparis pisifera, (c) Larix sp, (d) Keteleeria fortunei, (e) Tsuga sp, (f) Eschweilera matamata, (g) Copaifera trapezifolia, (h) Lonchocarpus subglaucencens, (i) Parapiptadenia rigida, (j) Tabebuia rosea alba, (k) Myrcia racemulosa, (l) Rhamnus frangula, (m) Prunus sellowii, (n) Melia azedarach e (o) Swietenia macrophylla.

### 2.1 Anatomia da Madeira

A International Association of Wood Anatomists (IAWA) coordena os trabalhos para a descrição da anatomia da madeira. Tais trabalhos incluem a padronização quanto à descrição e aos testes físicos e mecânicos aplicados na identificação da madeira, além da proposição de normas que englobam observações qualitativas e medições macro e microscópicas. Estas definições auxiliam a identificação das espécies florestais por meio dos padrões texturais da madeira, os quais são decorrentes das estruturas anatômicas distintas, com células de tipos, funções e características físicas diferentes [14].

Apesar da contribuição dos padrões texturais para a identificação das espécies florestais, alguns aspectos tornam esse processo mais complexo. As espécies florestais são classificadas de acordo com as definições da Botânica (*vide* Seção 2.1.2) e não da Anatomia da Madeira. Como consequência, espécies relativamente próximas na estrutura definida pela Botânica podem apresentar anatomias mais distintas entre si que outras mais distantes. Além disso, as características climáticas, concorrência por recursos e agentes nocivos à planta possuem grande influência na caracterização textural da madeira.

### 2.1.1 Principais Estruturas definidas pela Anatomia da Madeira

Devido às diferentes formas, disposições e organizações das células, o aspecto e o comportamento físico-mecânico da madeira variam à medida que se altera o ponto de observação. Neste sentido, os estudos anatômicos consideram (Figura 2.3(a)) três planos de corte [4, 14, 68, 144]:

- Transversal (X): perpendicular ao eixo longo do tronco da árvore, expondo os anéis de crescimento e demais componentes definidos à diante;
- Longitudinal Radial (R): divide o tronco ao meio, sendo paralelo aos raios ou perpendicular aos anéis de crescimento; e
- Longitudinal Tangencial (T): tangencia os anéis de crescimento e é perpendicular aos raios.

Barker destaca que os textos referentes à identificação de madeira sempre consideram superfícies paralelas a estes planos de corte e que a adoção de diferentes planos produz resultados confusos [4]. Ao se fazer um corte transversal em um tronco, basicamente tem-se a visão apresentada na Figura 2.3(b). A **Casca** é o componente mais externo, com a função de revestir o tronco e proteger a planta contra ações externas. O **Câmbio** localiza-se entre o xilema (lenho ou madeira) e o floema, sendo o segundo responsável por gerar novos elementos celulares que formarão o xilema e a casca [4, 14, 68, 144].



**Figura 2.3:** Pontos de observação: (a) planos de corte; (b) estruturas macroscópicas no plano de corte X.

O **Cerne** e o **Alburno** compõem o lenho. O primeiro situa-se na região mais interna do tronco e geralmente apresenta uma coloração mais escura, por ser formado por células fisiologicamente inativas. Já o alburno compreende a parte mais periférica (externa) do tronco e é formado por células ativas [4, 14, 68, 144].

A **Medula** encontra-se normalmente no centro do tronco, armazena nutrientes e realiza o transporte ascendente de líquidos. Os **anéis de crescimento** caracterizam a transição entre os lenhos inicial e tardio, respectivamente, formados nos períodos anuais em que as atividades fisiológicas das plantas atingem os pontos máximo e mínimo. As células do lenho inicial apresentam paredes mais finas, lumes maiores e coloração mais clara, enquanto aquelas do lenho tardio têm paredes mais espessas, lumens menores e um aspecto mais escuro (*vide* Figura 2.4) [4, 14, 68, 144].

### 2.1.2 Grupos Vegetais produtores de Madeira

Diferentes alternativas foram propostas para melhor organizar os conhecimentos nas mais diversas áreas das ciências. Estas geralmente definem divisões e subdivisões sucessivas, sob uma estrutura de árvore, para se permitir a representação e a diferenciação das especializações dos subgrupos. A proposta de Carl Von Linné foi selecionada para o presente trabalho por ser a mais clássica, sendo constituída por sete níveis: Reino, Filo (ou Divisão), Classe, Ordem, Família, Gênero e Espécie [145].

O mais alto nível do sistema de classificação é o **Reino**, no qual os organismos são diferenciados considerando sua organização celular (uni ou pluri-celulares) e os métodos de nutrição (absorção, ingestão ou produção de alimentos). Logo abaixo tem-se o **Filo**, cujos agrupamentos estão baseados nas similaridades quanto à organização e forma básicas dos corpos. Na sequência, o nível **Classe** considera principalmente o sistema de sustentação (esqueleto, por exemplo), a capacidade geral de adaptação ambiental e o sistema reprodutivo. A **Ordem** agrupa famílias constituídas por espécies que apresentam um elevado grau de semelhança genômica e morfo-funcional entre si, geralmente devido a uma ancestralidade comum [2]

No nível **Família** tem-se conjuntos de gêneros afins, isto é, muito próximos ou parecidos, embora possuam diferenças mais significativas do que a divisão em gêneros. **Gênero** determina o nome genérico da espécie e agrupa espécies que compartilham um conjunto muito amplo de características morfológicas e funcionais, geralmente pela existência de ancestrais comuns muito próximos. **Espécie** determina o nome específico da espécie e designa a unidade básica do sistema taxonômico utilizado na classificação científica dos seres vivos. Sob este nível, os indivíduos de cada agrupamento possuem profundas semelhanças estruturais e funcionais, podendo ser vistos como cópias imperfeitas uns dos outros [2].

Considerando as definições apresentadas, sob o Reino das Plantas (*Plantae*), tem-se as definições para o filo Angiospermae, classe Magnoliopsida, ordem Myrtales, família Myrtaceae, gênero Eucalyptus e espécie globulus; tem-se ainda para o Reino das Plantas (*Plantae*), as definições para o filo Gymnospermae, classe Pinopsida, ordem Pinales, família Araucareaceae, gênero Agathis e espécie becarii. Além destes, outros exemplos podem ser encontrados no Apêndice A, sendo que basicamente as espécies produtoras de madeira estão compreendidas nos filos Gimnospermas (Gymnospermae) e Angiospermas (Angiospermae).

#### 2.1.2.1 Gimnospermas

De origem grega, gimnosperma provém da união das palavras gymnos (nua) e sperma (semente) e explicita o fato de suas sementes serem visíveis externamente à planta. Suas plantas são vulgarmente denominadas softwoods ou coníferas, com aproximadamente 675 espécies, organizadas em 63 gêneros, e que se concentram nas regiões temperadas e frias do globo terrestre. Na flora nativa brasileira são encontrados apenas os gêneros Araucaria, Podocarpus, Zamia, Gnetum e Ephedra. Embora somente Araucaria e Podocarpus sejam formados por espécies produtoras de madeira, Gimnospermas possui grande importância econômica devido à exploração das espécies exóticas introduzidas no país para fins ornamentais e madeireiros, tais como as do gênero Pinus [14, 81].

A anatomia primitiva e o reduzido número de características apresentadas implicam numa maior dificuldade para diferenciação entre as espécies do grupo. Dentre as principais alternativas para sua caracterização no processo de classificação, tem-se os seguintes componentes (Figura 2.4): traqueóides axiais, raios, células epiteliais e canais resiníferos [14, 81].



Figura 2.4: Gimnosperma: Pinus elliottii.

Os **traqueóides**, com destaque para os axiais na Figura 2.4, podem compreender até 95% do volume da madeira, mas também estar ausentes em algumas espécies do grupo Gimnospermas. Os **raios** armazenam nutrientes e os transportam no sentido horizontal. Estes podem ser distinguíveis a olho nu e são importantes elementos da anatomia para a identificação das espécies [4, 14, 68, 144].

Os canais resiníferos constituem uma das principais características das espécies pertencentes ao grupo Gimnospermas, sendo importantes para a diferenciação destas espécies com relação às do grupo Angiospermas. Visíveis a olho nu em algumas espécies, estes canais constituem espaços intercelulares delimitados por células epiteliais e, conforme denominação, vertem resina. As células epiteliais, por sua vez, delimitam os canais resiníferos e são especializadas na produção de resina [4, 14, 68, 144].

Apresentados na seção anterior, os anéis de crescimento são facilmente identificados nos Gimnospermas, com lenho inicial menos denso devido à função de condução de substâncias e lenho tardio mais denso devido à função de sustentação. Na Figura 2.4 destaca-se tal formação para uma planta do grupo Gimnospermas, na qual as células menores e com coloração em vermelho mais forte compõem o lenho tardio.

### 2.1.2.2 Angiospermas

Também de origem grega, angiosperma tem sua origem na união das palavras angios (urna ou recipiente) e sperma (semente), por suas sementes estarem envolvidas por algum invólucro. Embora mais de 250 mil espécies componham este grupo, apenas o subgrupo *Dicotiledôneas* (vulgarmente denominadas hardwoods ou folhosas) agrega as espécies que produzem madeira. De forma geral, este grupo é mais diversificado que o anterior, possui um conjunto mais amplo de características que permitem sua identificação, uma composição anatômica mais especializada e complexa, além de maior capacidade evolutiva e de adaptação às variadas condições ambientais do globo. Basicamente, vasos, fibras, parênquimas e raios são os principais tipos celulares que caracterizam estas plantas (Figura 2.5) [4, 14, 68, 81, 82, 144].



Figura 2.5: Angiosperma: Porcelia macrocarpa.

Os vasos constituem a principal característica para diferenciar Gimnospermas e Angiospermas, pois estão presentes em praticamente todas as espécies do segundo grupo. Estes componentes realizam o transporte de água das raízes para as folhas e são facilmente visíveis com o auxílio de lentes ou mesmo a olho nu [4, 14, 68, 144].

As fibras constituem entre 20% e 80% do lenho dos Angiospermas, tendo a função de sustentação nas plantas deste grupo e determinando o grau de resistência de sua madeira. Importantes recursos para a distinção das espécies, os **parênquimas** (axiais ou radiais - **raios**) armazenam, transformam e transportam nutrientes no *Cerne* e no *Alburno*, constituindo as únicas células vivas no segundo componente. Geralmente mais abundantes nos Angiospermas que nos Gimnospermas, parênquimas axiais raramente estão ausentes em algumas espécies. Sua abundância implica em madeiras muito leves, com baixa resistência e pouca durabilidade [4, 14, 68, 144].

### 2.2 Extração e representação de características texturais

A escolha das características a serem extraídas das imagens e empregadas no processo de classificação é altamente dependente do problema [21, 112]. Neste sentido, Pedrini e Schwartz [112] afirmam que "um dos problemas básicos no desenvolvimento de um sistema para análise de imagens é a seleção de um conjunto de características extraídas do objeto de interesse para o propósito de classificação" (p. 248). Ampliando o nível de complexidade para a definição das características a serem empregadas, tem-se as influências de fatores como iluminação, sobreposição de objetos, se os objetos estão parados ou em movimento, se há algum tipo de deformação, translação, rotação ou escala aplicado aos objetos de interesse [21, 112].

Como alternativa, ao se voltarem para o sistema visual humano, Pedrini e Schwartz [112] destacam a textura, com suas informações sobre a distribuição espacial, a variação de luminosidade, o arranjo estrutural das superfícies e as relações entre regiões vizinhas [112, 150]. Contudo, embora o sistema visual humano seja capaz de reconhecer texturas com os devidos graus de invariância quanto a escala, rotação e translação, para os sistemas computacionais esta garantia ainda é muito difícil e principalmente custosa [150].

Para Pedrini e Schwartz [112], as soluções computacionais esbarram ainda no fato de que "é extremamente difícil formalizar [a] definição [de textura] ou desenvolver um conjunto de descritores ou medidas que possa ser utilizado para análise de imagens em diferentes domínios de aplicações" (p. 287). Apesar da diversidade de definições existentes, de forma geral, o conceito de Textura se refere às propriedades empregadas na representação da superfície ou da estrutura de um objeto (Figura 2.6). Neste sentido, Conci *et al.* [21] afirmam que os padrões apresentados pelas texturas podem representar características físicas, tais como rugosidade e reflexão da luz. Já Haralick [44] define textura como um fenômeno espacial que pode ser decomposto em duas dimensões. A primeira descreve as primitivas básicas que compõem a imagem e a segunda descreve a organização, a interação ou mesmo a dependência espacial entre estas primitivas [21, 39, 44, 150].



**Figura 2.6:** Exemplos de textura da base Brodatz [11]: (a) ráfia; (b) areia; (c) cerca de madeira; (d) tijolos; (e) casca de árvore.

A primitiva é definida como um conjunto conexo de células (pixels) com propriedades locais semelhantes, muitas vezes denominadas Elementos de Textura (*TEXture ELement* - TEXTEL ou Texton). Dentre tais propriedades pode-se elencar níveis de cinza, direção, forma, comprimento e homogeneidade. Já os TEXTELs podem constituir elementos mais simples (pixels, arestas e polígonos) ou mesmos combinações destes, formando elementos mais complexos (componentes conexos sob qualquer forma) [44, 94, 150].

Nasirzadeh *et al.* [95] afirmam que medidas baseadas em textura podem lidar melhor com variação das condições de iluminação e sua influência nos níveis de cinza, principalmente para ambientes externos. Porém, a diversidade quanto às variações das primitivas dificulta o reconhecimento por parte dos sistemas computacionais, os quais são ainda mais prejudicados com variações de escala, rotação e translação [21, 39, 44, 45, 112]. Considerando tais variações, Pedrini e Schwartz [112] classificam texturas como "ásperas" e "finas". Segundo os autores, "texturas ásperas" (Figura 2.6(c-e)) apresentam interações espaciais melhor definidas e regiões mais homogêneas. Já as "texturas finas" (Figura 2.6(ab)) apresentam interações espaciais aleatórias e grandes variações nos níveis de cinza das primitivas, sendo geralmente tratadas por abordagens estatísticas [44, 45].

As diferentes perspectivas quanto às definições das primitivas e seus relacionamentos conduzem a abordagens distintas para a descrição das imagens. Diante da ampla gama de alternativas, as seções seguintes restringem-se à apresentação daquelas empregadas neste trabalho.

### 2.2.1 Métodos Estruturais

Na abordagem Estrutural a textura é definida como um conjunto de TEXELs arranjados entre si de acordo com algum conjunto de regras. Seus métodos têm foco primário nas formas definidas pelas fronteiras dos elementos, bem como na frequência e na organização destes elementos na imagem. Seus descritores consideram o contorno ou os aspectos inerentes à área, perímetro, excentricidade, orientação, centro de gravidade, retângulos englobantes e contornos [21, 39, 44, 94, 112, 150].

### 2.2.1.1 LBP

O método Padrão Binário Local (*Local Binary Pattern* - LBP) foi introduzido, em 1996, como uma medida complementar para contraste local de uma imagem em níveis de cinza, sendo definido como invariante a mudanças monotônicas dos níveis de cinza. Em sua versão original, LBP considera uma vizinhança-8 e distância um para o pixel central  $(x_c, y_c)$  de uma máscara com dimensões  $3 \times 3$  (Figura 2.7 (a)) [79].

Cada ponto da imagem é tomado como sendo o ponto central  $(x_c, y_c)$ , cujo valor é utilizado como limiar na comparação com o conteúdo de cada um de seus vizinhos  $(x_i, y_i)$ . Desta comparação gera-se uma cadeia de zeros e uns (Figura 2.7 (b)), pois cada vizinho assume o valor um se seu conteúdo for maior que o do ponto central  $(x_c, y_c)$ e zero caso contrário (Equação 2.2). A organização desta cadeia considera a posição relativa *j* de cada um dos vizinhos, iniciando do canto superior-esquerdo com valor zero

	Li	miar		<b>▼</b> [	Multipl	ica	P	esos		• •	
5	4	3	1	1	1	2 <u>0</u>	2 <u>1</u>	2 <sup>2</sup>	1	2	4
4	3	1	1		0	2 <u>7</u>		2 <u>3</u>	128		0
2	0	3	0	0	1	2 <u>6</u>	2 <u>5</u>	2 <u>4</u>	0	0	16
	(a)			(b)		L	(c)		L	(d)	
			LBP	= 1 +	2 + 4 + (e	16 + 1. )	28 = <u>1</u>	151			

**Figura 2.7:** Cálculo do padrão LBP para a região sobreposta por uma máscara  $3 \times 3$  ([90], p. 2).

e circundando o ponto central no sentido anti-horário (Figura 2.7 (c)). Ao ser tomada como uma representação em base dois e convertida para a base dez (Equação 2.1), tem-se o padrão que representa a região sobreposta pela máscara (Figura 2.7 (d-e)) [79].

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<sup>P</sup> padrões para P vizinhos. A consideração de P = 8 (Figura 2.8(a)) gera um total de 256 padrões de transição de bits (Figura 2.7 (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  $(LBP_{P,R}^{u2})$ . Os autores afirmam que a frequência dos padrões uniformes compreende cerca de 90% dos padrões para a vizinhança (8,1) (Figura 2.8 (a)) e 70% dos padrões para a vizinhança (16,2) (Figura 2.8 (c)) [79, 103, 104].

$$LBP_{P,R}(x_c, y_c) = \sum_{j=0}^{P-1} (x_i, y_i) 2^j$$
(2.1)

$$(x_i, y_i) = \begin{cases} 1, & \text{se } (x_i, y_i) \ge (x_c, y_c) \\ 0, & \text{caso contrário} \end{cases}$$
(2.2)

Posteriormente, esta proposta sofreu adequações para suportar invariância à rotação, diferentes quantidades de vizinhos (P) e diferentes distâncias (R - raio) destes vizinhos com relação ao ponto central, sendo genericamente denominados  $LBP_{PR}$ . A variação de P vizinhos  $(x_i, y_i)$  igualmente espaçados a um raio R do ponto central  $(x_c, y_c)$  é ilustrada na Figura 2.8. A coordenada do vizinho  $(x_i, y_i)$ , quando esta não coincide exatamente com um ponto qualquer da imagem (Figura 2.8(b-c)), é dada pela Equação 2.3 e seu valor é calculado pela interpolação bilinear de seus respectivos vizinhos [1, 151].

$$(x_i, y_i) = \left(x_c + R\cos\left(\frac{2\pi j}{P}\right), y_c + R\sin\left(\frac{2\pi j}{P}\right)\right)$$
(2.3)



Figura 2.8: Operador  $LBP_{P,R}$  extendido para P vizinhos e raio R ([90], p. 2).

LBP combina as abordagens estrutural e estatística, pois ao mesmo tempo explica a textura por meio da formação do pixel e de sua vizinhança local. Ou seja, cada pixel é representado por um código de primitiva de textura que melhor se adapta a sua vizinhança, o que permite detectar pontos, áreas planas, arestas, fins de linha, cantos, entre outras (Figura 2.9) [79].



Figura 2.9: Diferentes primitivas detectadas pelo operador LBP ([79], p. 4).

As versões invariantes à rotação  $LBP_{P,R}^{ri}$  (*LBP Rotation Invariant*) e  $LBP_{P,R}^{riu2}$  (*LBP Rotation Invariant and Uniform*) foram apresentadas por Ojala *et al.* [103], em 2002. Estas mantêm a mesma definição básica de LBP e se beneficiam com a representação circular da vizinhança e a invariância dos padrões binários (Figura 2.10). Tal invariância é obtida por *P* rotações dos bits que compõem a representação binária dos padrões e a identificação do menor valor decimal gerado.  $LBP_{P,R}^{ri}$  acumula, em um mesmo elemento do descritor, todos os padrões binários que mantêm o mesmo valor decimal mínimo  $LBP_{P,R}^{ri}$  combina as definições  $LBP_{P,R}^{u2}$  e  $LBP_{P,R}^{riu2}$ . Assim, usa apenas os padrões binários uniformes e acumula, em um mesmo elemento do descritor, todos os padrões tod descritor, todos os padrões combina as apenas os padrões binários uniformes e acumula, em um mesmo elemento do descritor, todos os padrões fazem com que  $LBP_{P,R}^{riu2}$  apresentem apenas 36 e 10 elementos em seus descritores, respectivamente. [1].

$$LBP_{P,R}^{ri} = min\{ROR(LBP_{P,R}, i) \mid i = [0, P-1]\}.$$
(2.4)

$$LBP_{P,R}^{riu2} = min\{ROR(LBP_{P,R}^{u2}, i) \mid i = [0, P-1]\}.$$
(2.5)



**Figura 2.10:** LBP<sup>*ri*</sup><sub>*P,R*</sub>: a rotação das imagens em  $\alpha$  graus é refletida nas vizinhanças circulares de seus pontos (x,y) ([1], p. 65).

### 2.2.1.2 LPQ

Proposto por Ojansivu e Heikkilä [105], em 2008, Quantização de Fase Local (*Local Phase Quantization* - LPQ) se baseia na fase quantizada da transformada discreta de Fourier (*Discrete Fourier Transform* - DFT). A informação da fase local de uma imagem ( $N \times N$ ) é obtida por uma 2D-DFT (Transformada de Fourier de Curto Termo, do inglês *Short-Term Fourier Transform* - STFT) computada para uma vizinhança retangular  $V_x$  ( $m \times m$ ) para cada pixel x da imagem. A STFT  $\hat{f}_{u_i}(x)$  para a imagem f(x) é dada pela Equação 2.6 e o filtro  $\phi_{u_i}$  ( $m \times m$ ) pela Equação 2.7 [46, 122].

$$\hat{f}_{u_i}(x) = (f * \phi_{u_i})(x) \tag{2.6}$$

$$\phi_{u_i} = e^{-j2\pi u_i^T y} \mid y \in V_x \tag{2.7}$$

com \* denotando a convolução de  $\phi_{u_i}$  em  $f, j = \sqrt{-1}, r = (m-1)/2$  e o vetor base da 2D-DFT  $u_i$  na frequência i.

LPQ considera apenas quatro coeficientes complexos que correspondem às frequências bidimensionais  $u_1 = [a, 0]^T$ ,  $u_2 = [0, a]^T$ ,  $u_3 = [a, a]^T$  e  $u_4 = [a, -a]^T$ , nas quais a frequência a = 1/m. Tomando a notação vetorial, a STFT pode ser representada pela Equação 2.8, na qual f(x) constitui o vetor com os  $m^2$  pixels da vizinhança  $V_x \in \Phi_{u_i}$ representa o vetor base da 2D-DFT na frequência  $i (\phi_{u_i})$  [105].

$$\hat{f}_{u_i}(x) = \Phi_{u_i}^T f(x)$$
 (2.8)

Seja  $F = [f(x_1), f(x_2), ..., f(x_{N^2})]$  e a matriz  $m^2 \times N^2$  para representar os  $m^2$  vizinhos dos  $N^2$  pixels da imagem. Seja  $\Phi = [\Phi_R, \Phi_I]^T$ , com suas partes real  $\Phi_R =$ Re{ $[\Phi_{u_1}, \Phi_{u_2}, \Phi_{u_3}, \Phi_{u_4}]$ } e imaginária  $\Phi_I = \text{Im}{[\Phi_{u_1}, \Phi_{u_2}, \Phi_{u_3}, \Phi_{u_4}]}$ . A STFT para todos os pixels da imagem f(x) é dada por  $\hat{F} = \Phi F$ , na qual  $\hat{F}$  é uma matriz de valores reais e dimensões  $8 \times N^2$  [46, 105, 122].
Ojansivu e Heikkilä [105] assumem que a função de uma imagem f(x) resulta do processo de 1<sup>*a*</sup> ordem de Markov, na qual o coeficiente de correlação  $\rho_s$  entre os pixels adjacentes  $x_i \in x_j$  está relacionado exponencialmente com sua distância  $d_{ij}^s$ , além de uma variação unitária para os pixels. Com os pixels de f(x) organizados em um vetor  $\vec{f}$ , gerase a matriz de covariância  $C(m^2 \times m^2)$  com os elementos  $C_{i,j}$  dados pela Equação 2.9, com  $d_{ij}^s$  sendo a distância Euclidiana dada pela Equação 2.10.

$$C_{i,j} = \rho_s^{d_{ij}^s} \tag{2.9}$$

$$d_{ij}^{s} = \sqrt{\sum_{k=1}^{2} |x_i(k) - x_j(k)|^2}$$
(2.10)

A matriz de covariância dos coeficientes de Fourier é, então, dada por  $D = \Phi C \Phi^T$ . Tais coeficientes podem deixar de ser correlacionados pela transformação  $E = V^T \hat{F}$ , sendo V uma matriz 8×8 cuja transformação  $D' = V^T D V$  resulte em uma matriz D' diagonal. Tal matriz V pode ser obtida pelo cálculo dos *eigenvectors* de D que, por sua vez, podem ser obtidos com a multiplicação dos valores singulares de decomposição (*Singular Value Decomposition* - SVD) pelos *eigenvalues* de D [46, 105, 122].

Os coeficientes são quantizados usando a Equação 2.12, na qual  $e_{i,j} \in E$ , e codificados em valores decimais (8 bits, [0,255]) pela Equação 2.11. As frequências destes valores decimais são, por fim, contabilizadas por meio de um histograma sob a forma de um vetor com 256 posições [46, 105].

$$b_j = \sum_{i=0}^{7} q_{i,j} 2^i \tag{2.11}$$

$$q_{i,j} = \begin{cases} 1, & \text{se } e_{i,j} \ge 0\\ 0, & \text{se } e_{i,j} < 0 \end{cases}$$
(2.12)

Os autores afirmam que os códigos produzidos pelo LPQ são invariantes a borramentos simétricos considerando um ponto central como referência, o que inclui movimentação e falta de foco [3]. Embora tal invariância não seja completamente alcançada devido ao tamanho finito da janela do filtro usado, o método ainda é altamente insensível a borramentos. Além disso, devido ao emprego de informações considerando fase, o método também apresenta invariância a mudanças uniformes de iluminação [46, 105].

Inspirados nas variantes Local Binary Pattern from Three Orthogonal Planes (LBP-TOP) e Volume Local Binary Pattern (VLBP) propostas por Zhao e Pietikäinen [151] para LBP, em 2011 Päivärinta et al. [106] propuseram variantes similares para LPQ: Local Phase Quantization from Three Orthogonal Planes (LPQ-TOP) e Volume Local Phase Quantization (VLPQ). A variante LPQ-TOP foi também empregada neste trabalho e, basicamente, é caracterizada pela aplicação da versão original LPQ nas três dimensões das imagens dinâmicas e na concatenação dos vetores com os descritores, num total de 768 elementos. Para LPQ-TOP, os elementos da matriz C utilizada no cálculo da matriz de covariância é obtido pela Equação 2.13, com  $d_{ij}^s$  e  $d_{ij}^t$  dados pelas Equações 2.10 e 2.14, respectivamente.  $\rho_t$  representa o coeficiente de correlação entre os pixels adjacentes  $x_i \, e \, x_j$  e está relacionado exponencialmente com sua distância  $d_{ij}^t$  no domínio temporal. Por abordar imagens estáticas, o presente trabalho utilizou apenas os primeiros 256 do total de 768 elementos, sendo que a diferença na aplicação das variantes LPQ e LPQ-TOP está no fato de que elas utilizam valores diferentes para  $\rho_s$ , tendo sido identificado complementaridade em seus resultados.

$$C_{i,j} = \rho_s^{d_{ij}^s} \rho_t^{d_{ij}^t}$$
(2.13)

$$d_{ij}^t = |x_i(3) - x_j(3)|$$
(2.14)

#### 2.2.1.3 SIFT

Transformação de Características Invariantes à Escala (*Scale Invariant Feature Transform* - SIFT) foi proposto por Lowe [75], em 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. As regiões identificadas são caracterizadas por pontos que apresentam diferenças máximas e mínimas da função Gaussiana aplicada no que o autor denomina espaço escala. 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. O autor afirma que, embora exista e provavelmente seja identificado um número elevado destas regiões, a correlação entre duas imagens contendo um mesmo objeto pode ser estabelecida com o uso de apenas três delas, o que provê certo grau de tolerância inclusive a oclusões parciais [75, 76, 143].

A detecção das regiões de interesse é realizada por um processo de filtragem em cascata tomando uma mesma imagem sob diferentes escalas. 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. Este espaço escala de uma imagem (Equação 2.15) é definido como uma função  $L(x, y, \sigma)$  produzida pela convolução de uma variável escala Gaussiana  $G(x, y, \sigma)$  na imagem de entrada I(x, y), na qual \* representa a operação de convolução no ponto (x, y),  $G(x, y, \sigma)$  é dada pela Equação 2.16 [75, 76] e  $\sigma$  é a escala.

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y)$$
(2.15)

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2 + y^2)/2\sigma^2}$$
(2.16)

Para garantir a precisão das localizações das regiões de interesse, Lowe emprega a função diferença da Gaussiana convoluída na imagem (Equação 2.17), a qual pode ser computada pela diferença de duas escalas próximas e separadas pelo fator multiplicador constante k ( $k = \sqrt{2}$ ). Para detectar os máximos e mínimos locais de  $D(x, y, \sigma)$ , cada ponto (x, y) é comparado com seus oito vizinhos na escala corrente e nove vizinhos nas escalas imediatamente acima e abaixo. Os pontos selecionados nesta fase obrigatoriamente são maiores (máximo) ou menores (mínimo) que todos seus vizinhos, mas ainda podem ser eliminados caso apresentem baixo contraste (sensibilidade a ruídos) ou componham arestas [75, 76].

A escala de um ponto selecionado é utilizada na escolha da imagem L suavizada pela Gaussiana, a partir da qual todas as computações são realizadas de forma invariante à escala. Para cada ponto L(x, y) desta imagem (Figura 2.11(a)), considerando a escala já predefinida, são computadas a magnitude m(x, y) e a orientação  $\theta(x, y)$  do gradiente por meio de diferenças entre pixels (Equações 2.18 e 2.19). A orientação do gradiente da região de interesse é obtida pela composição de um histograma de orientações dos pixels vizinhos a  $D(x, y, \sigma)$ , sendo que cada pixel adicionado ao histograma é previamente ponderado pela magnitude de seu gradiente local e uma Gaussiana circular também ponderada representada por um círculo na Figura 2.11(a). A orientação final do gradiente é dada pelo maior valor do histograma [75, 76].

$$D(x,y,\sigma) = (G(x,y,k\sigma) - G(x,y,\sigma)) * I(x,Y) = L(x,y,k\sigma) - L(x,y,\sigma)$$
(2.17)

$$m(x,y) = \sqrt{(L(x+1,y) - L(x-1,y))^2 + (L(x,y+1) - L(x,y-1))^2}$$
(2.18)

$$\theta(x,y) = \tan^{-1}((L(x,y+1) - L(x,y-1))/(L(x+1,y) - L(x-1,y)))$$
(2.19)

Embora o processo considere um conjunto de 4×4 descritores computados em uma vizinhança 16×16, a Figura 2.11(b) mostra apenas 2×2 descritores computados em uma vizinhança 8×8 (Figura 2.11(a)), o que não prejudica o entendimento. O processo de cálculo dos descritores é semelhante ao descrito para a definição da orientação do gradiente da região de interesse. Os pontos L(x, y) são ponderados pela Gaussiana identificada pelo círculo na Figura 2.11(a). Estes são então acumulados em um histograma de orientação

que sumariza os conteúdos em  $4 \times 4$  subregiões (Figura 2.11(b)), com o comprimento de cada aresta correspondendo à soma das magnitudes dos gradientes que pertencem àquela subregião e que possuem a mesma direção [75, 76, 143].



**Figura 2.11:** Descritor SIFT: (a) aplicação da máscara na imagem e obtenção dos gradientes para cada direção na região sobreposta; (b) acúmulo dos gradientes para cada subregião para as oito direções.

Considerando os histogramas das  $4 \times 4$  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 I, todos potencialmente candidatos a compor o conjunto de características que descreve I [75, 76, 143].

#### 2.2.1.4 SURF

Proposto por Bay *et al.* [6], em 2006, Características Robustas Aceleradas (*Speed-Up Robust Feature* - SURF) apresenta semelhanças com relação a SIFT e também permite detecção e descrição de regiões de interesse. Os autores afirmam que SIFT apresentou o melhor desempenho dentre os descritores por eles analisados e que, dentre suas vantagens, está a capacidade de capturar substanciais quantidades de informação dos padrões espaciais e ainda ser robusto a pequenas deformações e erros de localização das regiões detectadas. Porém, SIFT apresenta uma alta dimensionalidade em seu descritor e um custo computacional que dificulta seu uso para aplicações *on-line* [5].

Seguindo esta linha de raciocínio, os autores 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 acurácia. A proposta ainda inclui o uso de determinantes da matriz Hessiana, devido a sua robustez quanto a estruturas mal localizadas e alongadas, e o conceito de imagens integrais [5, 6]. As estruturas detectadas pelo SURF estão situadas em regiões que maximizam o determinante da matriz Hessiana. Por definição, dado o ponto (x, y) na imagem I sob uma escala  $\sigma$ , a matriz Hessiana  $H(x, y, \sigma)$  é dada pela Equação 2.20, na qual  $L_{xx}(x, y, \sigma)$ representa a convolução da derivada parcial de segunda ordem da Gaussiana

$$\frac{\partial^2}{\partial x^2}g(\sigma)$$

na imagem I no ponto (x, y). A mesma descrição é aplicada a  $L_{xy}(x, y, \sigma)$  e  $L_{yy}(x, y, \sigma)$ [5, 6].

$$H(x, y, \sigma) = \begin{bmatrix} L_{xx}(x, y, \sigma) & L_{xy}(x, y, \sigma) \\ L_{xy}(x, y, \sigma) & L_{yy}(x, y, \sigma) \end{bmatrix}$$
(2.20)

O cálculo do determinante da matriz Hessiana H é apresentado na Equação 2.21, na qual w representa um peso usado para preservar a energia entre os núcleos da Gaussiana e os núcleos da aproximação da Gaussiana; e D representa as aproximações das derivadas parciais de segunda ordem da Gaussiana nas respectivas direções  $x, y \in xy$  [5, 6].

$$det(H_{approx}) = D_{xx}D_{yy} - (wD_{xy})^2$$
(2.21)

O uso do conceito de imagens integrais reduz drasticamente o tempo de computação devido aos filtros de convolução baseados em caixas (Figura 2.12). 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) (Equação 2.22). Diante disto, o cálculo da soma dos pixels contidos em uma região qualquer requer apenas três operações de adição (Figura 2.12), 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 [5, 6].

$$I_{\sum}(x,y) = \sum_{i=0}^{i \le x} \sum_{j=0}^{j \le y} I(i,j)$$
(2.22)

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 2.13) e acumuladas considerando as direções horizontal e vertical e uma janela deslizante de orientação



Figura 2.12: Imagem integral: ilustração do cálculo da soma dos pixels contidos em uma subregião DBCA da imagem com apenas três operações de adição.

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 [5, 6].



Figura 2.13: Janela deslizante de orientação que com ângulo  $\pi/3$ .

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 (Figura 2.14). Para cada um dos 64 elementos, obtém-se a resposta da wavelet de Haar nas direções x e y, denominadas respectivamente  $d_x e d_y$ . Para cada subregião 2×2,  $d_x$ ,  $d_y$ ,  $|d_x| e |d_y|$  são acumuladas separadamente, gerando 16 conjuntos com as quatro características ( $\{\sum d_x, \sum d_y, \sum |d_x|, \sum |d_y|\}$ ), num total de 64 elementos. Ao final, como SIFT, geralmente são detectados centenas ou até milhares de pontos para cada imagem I. 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 I [5, 6].

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  $d_y \ge 0$ , 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 [5, 6].



**Figura 2.14:** Descritor SURF: (a) aplicação da máscara 8×8 alinhada com a orientação identificada e obtenção dos gradientes para cada direção na região sobreposta da imagem; (b) acúmulo dos gradientes para cada subregião.

#### 2.2.1.5 MSER

Em 2002, Matas *et al.* [88] conceituaram regiões extremas (*Extremal Regions* - ER) e propuseram o algoritmo Regiões Extremas Maximamente Estáveis (*Maximally Stable Extremal Regions* - MSER) para detectá-las. ERs são caracterizadas como componentes conexos invariantes a transformações das coordenadas das imagens e a transformações das intensidades de seus pixels. De forma simplificada, as regiões extremas são identificadas por meio de uma sequência de limiarizações da imagem original (em níveis de cinza) e das imagens binárias geradas (Figura 2.15). Tal sequência de imagens inicia com um quadro totalmente branco e termina com um outro totalmente negro, passando por diversas imagens intermediárias nas quais as regiões de interesse são identificadas. Tais regiões se tornam cada vez maiores e se fundem à medida que o valor utilizado como limiar é incrementado [77, 88].

Formalmente, Matas *et al.* [88] apresentam definições para imagem, região, borda da região, regiões extremas e regiões extremas maximamente estáveis. Dada a **Imagem** *I*, a qual representa um mapeamento  $I : \mathcal{D} \subset \mathbb{Z}^2 \to S$ , ERs são bem definidas em *I* se:

1. S é totalmente ordenado, isto é, há uma relação binária  $\leq$  reflexiva, antisimétrica e transitiva<sup>1</sup>.

2. Uma relação de adjacência (vizinhança)  $A \subset \mathcal{D} \times \mathcal{D}$  é definida<sup>2</sup>.

**Região**  $\mathcal{Q}$  é um subconjunto contíguo de  $\mathcal{D}$ , isto é, para cada  $p, q \in \mathcal{Q}$  há uma sequência  $p, a_1, a_2, ..., a_n, q \in pAa_1, a_iAa_{i+1}, a_nAq$ .

Borda externa da regiao  $\partial \mathcal{Q} = \{q \in \mathcal{D} \setminus \mathcal{Q} : \exists p \in \mathcal{Q} : qAp\}$ , isto é, a borda  $\partial \mathcal{Q}$  de  $\mathcal{Q}$  é o conjunto de pixels adjacentes a, pelo menos, um pixel de  $\mathcal{Q}$ , mas não pertence

<sup>&</sup>lt;sup>1</sup>No trabalho original os autores assumem S = [0, 255], mas deixam claro que valores reais ( $S = \mathbb{R}$ ) poderiam ser considerados.

<sup>&</sup>lt;sup>2</sup>Os autores utilizam vizinhança-4, isto é,  $p, q \in \mathcal{D}$  são adjacentes (pAq) se  $\sum_{i=1}^{d} |p_i - q_i| \leq 1$ .



**Figura 2.15:** Processo de definição das regiões extremas. Considere a imagem original em (a) *Porcelia macrocarpa*. Após esta ser convertida para níveis de cinza, diferentes limiares são aplicados e diferentes imagens binarizadas são geradas para a identificação das regiões extremas. As imagens (b) a (h) ilustram os resultados para os limiares 31, 62, 93, 124, 155 e 186

аQ.

**Região Extrema**  $\mathcal{Q} \subset \mathcal{D}$  é a região tal que para todo  $p \in \mathcal{Q}, q \in \partial \mathcal{Q} : I(p) > I(q)$ (região de intensidade máxima) ou I(p) < I(q) (região de intensidade mínima).

Região extrema maximamente estável. Considere  $\mathcal{Q}_1, ..., \mathcal{Q}_{i-1}, \mathcal{Q}_i,...$  como uma sequência de regiões extremas aninhadas, isto é,  $\mathcal{Q}_i \subset \mathcal{Q}_{i+1}$ .  $\mathcal{Q}_{i^*}$  é maximamente estável se  $q_i = |\mathcal{Q}_{i+\Delta} \setminus \mathcal{Q}_{i-\Delta}| / \mathcal{Q}_i$  possui um mínimo local em  $i^*$ . Nesta notação, |.|define a cardinalidade de um conjunto, isto é, o número de elementos presentes neste conjunto;  $A \setminus B$  define o conjunto de todos os elementos de A que não estão em B; e  $\Delta$ e S são parâmetros do métodos.

Pelas definições anteriores, as ERs são identificadas apenas em função dos níveis de cinza dos pixels que as compõem e daqueles externos a elas. Ou seja, tais regiões são ou mais escuras ou mais claras que sua vizinhança, o que as tornam estáveis diante da aplicação de diferentes limiares num processo de binarização. Os autores afirmam que tais regiões devem ser estáveis e invariantes a escalas, a transformações das coordenadas das imagens e a transformações das intensidades de seus pixels. A enumeração destas regiões inicia com a ordenação dos pixels da imagem. Em seguida, tal sequência (crescrente ou decrescente) é percorrida e as posições dos pixels na imagem permitem que os componentes conexos e suas áreas sejam identidicados e mantidos por meio do algoritmo *union-find*. Ao se encontrarem, duas ou mais regiões deixam de existir e dão origem a uma única região maior, formada por todos os pixels previamente existentes nas antecessoras. Por fim, níveis de cinza caracterizados como mínimos locais da taxa de mudança da área são selecionados como limiares produzindo regiões extremas maximamente estáveis [32, 88].

A saída do algoritmo consiste do nível de cinza mínimo (ou máximo) local e do limiar. No entanto, não há uma busca por um limiar ótimo ou global, pois todos os limiares são testados e a estabilidade dos componentes conexos avaliadas. Para os casos em que existam múltiplos limiares estáveis, um sistema de subconjuntos aninhados é retornado [88].

#### 2.2.2 Métodos Estatísticos

Primeira abordagem utilizada na representação de textura, os métodos estatísticos constituem o maior conjunto de técnicas computacionais para este fim. Suas técnicas representam textura como uma coleção de valores estatísticos obtidos para as características selecionadas para representar uma superfície [39, 112, 150].

Geralmente estes métodos caracterizam medidas de frequência espacial, direta ou indiretamente. Neste contexto, texturas finas apresentam altas frequências espaciais enquanto texturas irregulares apresentam baixas frequências espaciais [44]. Isto permite a caracterização de níveis de suavidade, aspereza e granularidade, bem como sua graduação diante dos altos níveis de aleatoriedade característicos [39, 112, 150]. Diante disto, as principais aplicações dos métodos estatísticos focam texturas finas e sem a presença de primitivas mais complexas, basicamente formadas por pontos com distribuição aparentemente aleatória.

## 2.2.2.1 Medidas Estatísticas de Primeira Ordem

As propriedades texturais de uma imagem I podem ser representadas pelos momentos estatísticos de primeira ordem. Estes momentos consideram a distribuição dos níveis tonais e podem ser obtidos a partir de histogramas dos canais de I, considerando a imagem total ou parcialmente.

Formalmente, considere a imagem I com dimensões  $M \times N$  e L níveis de cinza. Seja zuma variável aleatória que demonstra a intensidade discreta de I;  $n_i$  o número de pixels em I com o nível tonal  $z_i$  (i = [1, L]);  $p(z_i)$  o histograma representando a probabilidade de ocorrência do nível tonal  $z_i$  em I (Equação 2.23); e a intensidade média m (Equação 2.24). A partir destas definições, o n-ésimo momento angular de z ( $\mu_n(z)$ ) pode ser obtido pela Equação 2.25, a partir do qual pode-se obter estatísticas e utilizá-las como descritores para I [21].

$$p(z_i) = \frac{n_i}{MN} \tag{2.23}$$

$$m = \sum_{i=1}^{L} z_i p(z_i)$$
 (2.24)

$$\mu_n(z) = \sum_{i=1}^{L} (z_i - m)^n p(z_i)$$
(2.25)

O primeiro momento central  $(\mu_1)$  corresponde à própria **média** dos níveis tonais mda Equação 2.24. O segundo momento central  $(\mu_2)$  é a **variância** (var) e representa a distribuição dos níveis com relação aos valores médios e a homogeneidade da imagem (Equação 2.26). A partir da variância obtém-se o desvio padrão  $\sigma$  (Equação 2.27), utilizado nas estatísticas subsequentes. A **obliquidade** v (Equação 2.28) é derivada do terceiro momento angular  $(\mu_3)$  e indica a assimetria da distribuição dos níveis em torno da média. A **curtose** k (Equação 2.29) decorre do quarto momento angular e representa o achatamento da curva de distribuição [21, 112].

$$var = \sum_{i=1}^{L} (z_i - m)^2 p(z_i)$$
(2.26)

$$\sigma = \sqrt{var} \tag{2.27}$$

$$v = \frac{\mu_3}{\sigma^3(z)} \tag{2.28}$$

$$k = \frac{\mu_4}{\sigma^4(z)} - 3 \tag{2.29}$$

Além destes, há outros momentos estatísticos da distribuição dos níveis tonais. Porém, Gonzalez e Woods [39] afirmam que os demais não agregam informação quantitativa ao conteúdo da textura. Além disso, os autores declaram que, de forma geral, os momentos não possuem informações quanto à posição relativa dos pixels na imagem.

## 2.2.2.2 GLCM

Matriz de Co-occorrência de Níveis de Cinza (*Gray Level Co-occurrence Matrix* - GLCM) foi proposta por Haralick *et al.* [45], em 1973, e caracteriza-se como um dos mais conhecidos métodos que exploram repetições de ocorrências de padrões. Tais padrões são caracterizados pela dependência entre os níveis de cinza dos pixels das imagens e por sua distribuição espacial. As repetições dos padrões provêem medidas quanto a propriedades como rugosidade, suavidade e regularidade sob diferentes perspectivas com a variação dos parâmetros direção e distância [141].

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. A imagem 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,  $I : L_r \times L_c \rightarrow G$  [44, 45, 112].

A partir disto, 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  $p_i$  ( $p_j$  - a uma distância d e um ângulo  $\alpha$ ) possua nível de cinza  $n_j$ . Embora Haralick tenha estabe-

lecido ângulos com intervalos de 45 graus, os cálculos podem assumir outros ângulos [44, 45, 112, 135, 136].

Seguindo as definições anteriores, as GLCM da Figura 2.16(b-c) foram geradas para a imagem da Figura 2.16(a) com  $N_g = 5$ , distância d = 1 e direções 0 e 45 graus, respectivamente.



**Figura 2.16:** Geração de GLCMs: (a) fragmento considerado da imagem com apenas cinco níveis de cinza; (b) GLCM para  $0^0$ ; e (c) GLCM para  $45^0$ .

Dentre as possíveis medidas extraídas de GLCM, tem-se as 14 características apresentadas por Haralick *et al.* (em 1973) e Haralick (em 1979): Segundo Momento Angular, Contraste (Soma do Quadrado da Variância), Correlação, Variância (Soma dos Quadrados), Momento de Diferença Inverso (Homogeneidade), Soma da Média, Soma da Variância, Soma da Entropia, Entropia, Diferença da Variância, Diferença da Entropia, Informação de Medidas de Correlação 1, Informação de Medidas de Correlação 2 e Coeficiente de Correlação Máxima [44, 45].

Embora a proposta inicial tenha definido 14 elementos, a maioria dos trabalhos encontrados na literatura consideram diferentes subconjuntos destes e afirmam haver correlações e/ou redundâncias entre as informações provenientes de alguns deles. Assim, aqui empregou-se apenas seis das características propostas por Haralick [44, 45]: energia, contraste, entropia, homogeneidade, probabilidade máxima e momento de terceira ordem (Equações 2.30 a 2.35).  $N_g$  é 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.

$$Energia = \sqrt{\sum_{i=0}^{N_g - 1} \sum_{i=0}^{N_g - 1} \{P(i, j)\}^2}$$
(2.30)

$$Contraste = \sum_{i=0}^{N_g-1} \sum_{i=0}^{N_g-1} |i-j|^2 P(i,j)$$
(2.31)

$$Entropia = -\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i,j) log(P(i,j))$$
(2.32)

$$Homogeneidade = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{P(i,j)}{1+|i-j|^2}$$
(2.33)

$$Probabilidade \ M\acute{a}xima = \max_{i=0}^{N_g-1} P(i,j)$$
(2.34)

Momento Terceira Ordem = 
$$\sum_{i=0}^{N_g-1} \sum_{i=0}^{N_g-1} |i-j|^3 P(i,j)$$
 (2.35)

## 2.2.3 Métodos Espectrais

Os métodos compreendidos neste grupo transformam a representação da imagem do domínio espacial para o domínio de frequência. Assim, permitem que as imagens sejam analisadas considerando as frequências e as variações nas intensidades dos pixels, provendo invariância à escala em que a imagem esteja representada, uma vez que diferentes resoluções podem caracterizar diferentes estruturas físicas [21, 80, 112].

Dentre os métodos mais conhecidos deste grupo têm-se transformada de Fourier, filtros de Gabor e *Wavelets*. A primeira alternativa não permite representar informações inerentes a localização ou regiões específicas nas imagens. Já os filtros de Gabor apresentam maior custo computacional quando comparados com *Wavelets*, embora seus resultados geralmente superem aqueles obtidos com *Wavelets* [39, 101, 112]. Diante destas considerações, optou-se pelo emprego dos filtros de Gabor, descritos na subseção seguinte.

## 2.2.3.1 Filtros de Gabor

Proposto em 1946 por Dennis Gabor, os filtros de Gabor são bastante utilizados para segmentação de imagens, reconhecimento de faces e assinaturas, melhoria e identificação de impressões digitais, criação de imagens sintéticas, além de outras aplicações de processamento de imagens. Os filtros de Gabor caracterizam-se como um conjunto de funções senoidais complexas, bidimensionais e moduladas por funções Gaussianas também bidimensionais. Estes são invariantes a deslocamento e geram imagens características de Gabor r(x, y), as quais são resultantes da convolução do filtro g(x, y) centrado no ponto  $(\xi, \eta)$  sobre a imagem original I(x, y) de dimensões  $M \times N$ , tal como ilustrado na Equação 2.36 [21, 39, 40, 91, 149].

$$r(x,y) = \int_{x=0}^{M-1} \int_{y=0}^{N-1} I(x,y)g(x-\xi,y-\eta)dxdy$$
(2.36)

Dependendo dos parâmetros empregados por meio de g(x, y), isto é, ângulo  $\theta$  e largura da Gaussiana  $\sigma^3$ , o filtro de Gabor permite a caracterização de orientação e frequência. Porém, uma das principais dificuldades quanto a sua utilização consiste na definição destes parâmetros. Uma possível solução consiste no emprego de recursos como imagem direcional<sup>4</sup> para identificar os melhores valores quanto à orientação do filtro e à largura da Gaussiana [21, 40].

A variação de g(x, y) implica também na alteração de seus parâmetros  $\theta \in \sigma$  e permite a criação de diferentes conjuntos de filtros, geralmente referenciados como bancos de filtros (Figura 2.17). Além disso, diferentemente da transformada de Fourier, os filtros de Gabor permitem a captura de informações tanto em termos de frequência quanto em termos temporais. Esta é uma de suas principais vantagens, sendo importante para o reconhecimento de padrões por agregar maior riqueza de informações [39, 40].



**Figura 2.17:** Bancos de Filtros de Gabor: imagens das partes reais considerando cinco escalas ( $\nu = [0, 4]$ ) e oito orientações ( $\mu = [0, 7]$ ),  $\sigma = 2\pi$ ,  $k_{max} = \pi/2$  e  $f = \sqrt{2}$ .

Neste trabalho empregou-se a implementação disponibilizada por Zhu *et al.* [153], a qual se baseia na pesquisa desenvolvida por Lades *et al.* [69]. Zhu *et al.* simplificam a

 $<sup>^3\</sup>sigma$  corresponde ao desvio padrão da distribuição normal e relaciona-se à largura da Gaussiana que modula o filtro de Gabor e controla o tamanho da banda passante deste filtro.

<sup>&</sup>lt;sup>4</sup>A imagem direcional é obtida com a aplicação de filtros especiais e determina o ângulo médio dos elementos presentes na imagem filtrada.

Equação 2.36 com a expressão da Equação 2.37, com z sendo as coordenadas (x, y) na imagem em níveis de cinza I. \* representa a convolução da família de filtros  $\psi_k$  centrados na origem sobre  $I \in O_k(z)$  é o resultado desta convolução. Os autores também definem a família de filtros dada pela Equação 2.38, na qual k identifica o filtro  $\psi_k(z)$ , criado com a orientação  $\mu$  e a escala  $\nu$ .  $\psi_k(z)$  é definido como  $k(\mu, \nu) = k_{\nu}e^{i\phi\mu}$  para  $k_{\nu} = k_{max}/f^{\nu}$ ,  $\phi_{\mu} = \pi \mu/\mu_{max}$  e  $\sigma = 2\pi$ .  $k_{max}$  ( $k_{max} = \pi/2$ ) define a frequência máxima,  $\mu_{max}$  identifica o número máximo de orientações e f ( $f = \sqrt{2}$ ) representa o fator de espaçamento entre os filtros no domínio de frequência.

$$O_k(z) = I(z) * \psi_k(z) \tag{2.37}$$

$$\psi_k(z) = \frac{\|k\|^2}{\sigma^2} e^{\|k\|^2 \|z\|^2 / 2\sigma^2} [e^{ikz} - e^{-\sigma^2/2}]$$
(2.38)

## 2.3 Representação das relações entre objetos por meio do conceito de dissimilaridade

Os conceitos de similaridade, dissimilaridade e proximidade têm sido discutidos sob diferentes perspectivas [38, 114, 129]. Pekalska e Duin em [27, 113, 114] introduziram a ideia de representar relações entre objetos por meio de suas diferenças e a denominaram representação por dissimilaridade. Na proposta, os autores consideram um conjunto de referências R ( $r_j \in R$ ; j = [1, n]), a amostra a ser classificada  $s_q$  e seus respectivos vetores de características  $V_j \in V_q$ . As referências em R são assumidas como protótipos das diferentes classes  $Cl_l$  (l = [1, m]) existentes no problema em questão. Assim, dada a distância  $d(V_q, R)$  entre  $s_q$  e as referências em R, pela regra do vizinho mais próximo,  $s_q$  é atribuída à classe  $Cl_j$ , tal que  $r_j \in Cl_j$  e  $d(s_q, r_j) = \min d(V_q, R)$ . Ou seja, dentre as possíveis classes  $Cl_l$ ,  $Cl_j$  é definida como a classe predita  $Cl_p$ .

Bertolini *et al.* [7] empregaram a ideia de vetores de dissimilaridade, combinando a descrição baseada em características com o conceito de dissimilaridade. Esta abordagem foi escolhida para o presente trabalho por reduzir a complexidade de um problema qualquer de m para 2 classes e pela independência dos modelos com relação às classes empregadas nas fases de treinamento e classificação. A mesma é detalhada na próxima seção, seguida de ROC que se caracteriza como alternativa para a avaliação de problemas com duas classes.

# 2.3.1 Vetores de dissimilaridade e a mudança na representação dos problemas de espaços *n*-dimensionais para o espaço bidimensional

Bertolini *et al.* [7] consideram um conjunto S composto por p amostras  $(s_i \in S, i = [1, p])$ e um conjunto R composto por n referências  $(r_j \in R, j = [1, n])$ , bem como seus vetores de características  $V^S$  e  $V^R$ . A partir de S e R, as amostras  $s_i$  e as referências  $r_j$  são selecionadas e seus vetores de características  $V_i$  ( $V_i \in V^S$ ) e  $V_j$  ( $V_j \in V^R$ ) são extraídos. Computa-se os vetores de dissimilaridade  $Z_{i,j}$ , conforme Equação 2.39, na qual t representa o número de características utilizadas para descrever  $s_i$  e  $r_j$  e define a dimensionalidade de  $V_i$ ,  $V_j$  e  $Z_{i,j}$ .

$$Z_{i,j} = d(V_i, V_j) = [|V_{i,1} - V_{j,1}|, |V_{i,2} - V_{j,2}|, ..., |V_{i,t} - V_{j,t}|]$$
(2.39)

O emprego dos vetores de dissimilaridade  $Z_{i,j}$  foca um momento posterior à extração de  $V_i \in V_j$  e é independente dos descritores utilizados. Dado o conjunto das amostras  $s_i$ pertencentes à classe  $Cl_i$ , o conjunto R deve compreender referências  $r_j$  pertencentes às classes  $Cl_j$  positivas e negativas. As referências  $r_j$  positivas (Figura 2.18(a)) pertencem à mesma classe  $Cl_i$  que  $s_i$ , isto é,  $Cl_i = Cl_j$ . Assim, é esperado que os valores que compõem  $Z_{i,j}$  fiquem próximos de zero. Já as referências  $r_j$  negativas (Figura 2.18(b)) pertencem a classes  $Cl_j$  diferentes de  $Cl_i$  e os valores que compõem  $Z_{i,j}$  devem divergir de zero [7, 43], tal como ilustrado nas Figuras 2.19 (b) e (d).



**Figura 2.18:** Cálculo dos vetores de dissimilaridade  $Z_{i,j}$ : (a) amostras positivas; (b) amostras negativas (Baseado em Hanusiak *et al.* [43]).

A partir da descrição anterior, identifica-se a redução da complexidade do problema de m para 2 classes (Figura 2.19). Partindo da representação no espaço de características (Figuras 2.19 (a) e (c)), com m = 3 e as classes  $Cl_1$ ,  $Cl_2$  e  $Cl_3$ , o cálculo de  $Z_{i,j}$  muda a representação do problema para o espaço de dissimilaridade (Figuras 2.19 (b) e (d)), no qual haverá apenas as classes positiva ( $Cl_+$ ) e negativa ( $Cl_-$ ) [7, 27, 114].

A base de dados utilizada na criação do modelo de classificação no espaço de dissimilaridade é composta por  $Z_{i,j}$  e não por  $V_i$ , como ocorre na classificação tradicional. Após definir o subconjunto de vetores  $Z_{i,j}$  utilizados para o treinamento, este é fornecido ao classificador e o modelo é criado. Tal modelo define os limites para que cada vetor de



**Figura 2.19:** Transformação de um problema *n*-dimensional (a) e (c) para bidimensional (b) e (d) [124, 125].

dissimilaridade  $Z_{q,j}$  possa ser atribuído a uma das possíveis classes,  $Cl_+$  ou  $Cl_-$ .

Para classificar  $s_q$ , esta deve ser fornecida ao sistema juntamente com as referências  $r_j \in R$ , positivas e negativas. Extrai-se seus vetores de características  $V_q$  e  $V_j$  e calcula-se  $Z_{q,j}$ . Os vetores  $Z_{q,j}$  resultantes são submetidos ao classificador e as decisões individuais para cada  $Z_{q,j}$  são combinadas (*vide* seção 2.4.1) para alcançar a decisão final para  $s_q$  [7, 43]. Após combinar as decisões individuais, a classe candidata  $Cl_l$  (no espaço de características) que maximizar as probabilidades para a classe positiva  $Cl_+$  será definida como a classe predita  $Cl_p$ .

Outra vantagem desta representação consiste na independência do modelo quanto às classes empregadas nas fases de treinamento e classificação. Tal independência possibilita que o modelo seja utilizado para classificar amostras cujas classes não tenham sido utilizadas em sua criação [7, 26, 27]. Porém, deve-se garantir que existam referências pertencentes à classe real à que  $s_q$  pertence. Caso contrário,  $s_q$  será atribuída à qualquer classe  $Cl_l$  (negativa, no espaço de características) que maximizar as probabilidades para a classe  $Cl_+$  (no espaço de dissimilaridade).

Uma vez criado, um mesmo modelo poderá ser empregado para a classificação nos contextos de identificação, verificação e monitoramento [7, 26, 27, 113, 114]. A *Identi-ficação* exige que  $s_q$  seja comparada com referências de todas as classes da base (1 : m) e a classe candidata  $Cl_l$  (no espaço de características) que maximizar as probabilidades

para a classe  $Cl_+$  será definida como a classe predita  $Cl_p$  para  $s_q$ . A Verificação implica em apenas uma comparação (1 : 1) com a suposta classe  $Cl_s$ . Se  $Cl_s$  (no espaço de características) maximizar as probabilidades para a classe  $Cl_+$ , confirma-se a suposição para  $Cl_s$ . Caso contrário, não se pode determinar à que classe  $s_q$  pertence. O Monitoramento implica em uma comparação 1 : k, em que k representa um subconjunto de m ( $k \le m$ ). Tal subconjunto é definido por Jain *et al.* [57] como uma lista mantida pelo sistema e que contém as identidades (ou classes) dos objetos desejados (monitorados). A cada objeto detectado, o sistema compara com as referências de sua lista, o que situa o monitoramento entre verificação e identificação.

Diante do elevado número de espécies florestais existentes (vide Seção 2.1), do reduzido número de amostras por espécie (vide Apêndice A) e, consequentemente, da dificuldade quanto à construção de modelos tradicionais para sua identificação, escolheu-se os modelos construídos a partir de vetores de dissimilaridade e o contexto de identificação. Tal escolha caracteriza a tentativa de garantir robustez ao modelo, mesmo quando aplicado a espécies não utilizadas durante o treinamento dos classificadores. Também procura-se otimizar os modelos construídos por meio da avaliação da influência de fatores como as quantidades de classes, de amostras por classe e de referências utilizadas para cada amostra durante a geração de seus vetores  $Z_{i,j}$ . Tais fatores são mencionados por Bertolini *et al.* [7] e Hanusiak *et al.* [43] e foram avaliados tanto no processo de construção do modelo quanto no processo de classificação, diante de sua relevância para problemas com poucas amostras por classe.

#### 2.3.2 Características de Receptor-Operador

Fawcett [31] afirma que considerar apenas a precisão de um classificador não é suficiente para avaliar sua performance, principalmente se houver diferenças ou alterações das distribuições entre as classes e dos custos quanto aos erros de classificação. Neste sentido, a Figura 2.20 ilustra a robustez de Características de Receptor-Operador (*Receiver Operator Characteristics* - ROC) para ambientes imprecisos. Nela, verifica-se que alterações inerentes às distribuições entre as classes não alteram os gráficos ROC enquanto o mesmo não ocorre com a relação entre precisão e *taxa tp* (*recall*) [60, 61, 120, 121].

Como ilustrado na Figura 2.20, ROC provêem gráficos que permitem visualizar as performances dos classificadores, bem como organizá-los e selecionar aqueles cujas performances, individual ou em conjunto, forem melhor avaliadas. Tais ferramentas são úteis para avaliar classificadores aplicados a problemas com apenas duas classes, uma positiva (P) e outra negativa (N) [31, 61]. Este contexto é inerente aos problemas representados no espaço de dissimilaridade e que geralmente apresentam um número maior de exemplares para a segunda classe, tal como o deste trabalho.

A avaliação dos classificadores por meio de ROC pode empregar diferentes indicadores. Para obtê-los, ao final do processo de classificação, gera-se uma Matriz de Confusão (MC)



**Figura 2.20:** Invariância à distribuição das amostras entre as classes: (a) curvas ROC idênticas para 'taxa de erro igual' (*Equal Error Rate* - EER, Equação 2.45); (b) curvas para a relação precisão e *taxa tp* (Baseado em [31], p. 865).

bidimensional em que a diagonal principal representa os acertos e a diagonal secundária representa os erros do classificador (Figura 2.21). Dentre os indicadores obtidos a partir desta MC sob um contexto de avaliação mais geral, destaca-se a totalização de acertos e erros dados por verdadeiros positivos (*True Positive* - TP), falsos negativos (*False Negative* - FN), verdadeiros negativos (*True Negative* - TN) e falsos positivos (*False Positive* - FP). TP compreende as amostras positivas classificadas como positivas. FN compreende as amostras positivas classificadas como negativas. TN compreende as amostras negativas classificadas como negativas. FP compreende as amostras negativas classificadas como positivas. TP, FN, TN e FP são expressos em valores absolutos e permitem a derivação de taxas em termos percentuais (Equações 2.40 a 2.45), o que facilita a avaliação da performance dos classificadores [31, 42, 60, 61].



**Figura 2.21:** Matriz de confusão bidimensional representando os acertos (diagonal principal) e os erros (diagonal secundária) de cada classificador ([31], p. 862).

A partir da combinação dos pares ordenados (taxa fp, taxa tp), denominados Pontos de Operação (POs), gera-se as curvas ROC (Figura 2.20(a)). Plotadas em um gráfico bidimensional, estas curvas permitem analisar as relações entre os custos (taxa fp) e os benefícios (taxa tp) dos classificadores [31, 83]. Com isso, tem-se diferentes limiares para a decisão, o que não é possível para as taxas derivadas da MC, por exemplo. Esta flexibilidade quanto aos POs permite realizar ajustes diante de situações em que diferentes tipos de erro tenham diferentes custos associados [31, 83].

Neste sentido, pode-se definir o PO ideal de acordo com a necessidade ou criticidade quanto à tolerância a falhas de cada problema [31, 60, 61, 83]. Um exemplo quanto à necessidade de definição de um PO poderia considerar um limite máximo para a classificação de Angiospermas como Gimnospermas, devido ao valor mais elevado da madeira pertencente às espécies do primeiro grupo. Ou, num ângulo oposto, o ajuste poderia contemplar a aceitação de Angiospermas classificados como Gimnospermas, mas não o contrário, ao se selecionar materiais para edificações que devam ter maior vida últil ou garantias quanto a resistência do material e segurança. Para o presente trabalho, não houve qualquer especificação prévia dos POs. Assim, todas as classificações consideraram a definição da Equação 2.45 (Figura 2.20) para a 'taxa de erro igual' (*Equal Error Rate* -EER).

A representação gráfica das curvas ROC também permite a quantificação numérica quanto à performance do classificador pelo cálculo da Área sob a Curva ROC (*Area Under a ROC Curve* - AUC). Este valor numérico está compreendido no intervalo [0, 1] e equivale à probabilidade de que um determinado classificador organize as amostras tal que uma amostra positiva escolhida aleatoriamente possua maior *score* que uma amostra negativa também escolhida aleatoriamente [31, 61, 83]. Ou, como afirmado por Khreich *et al* [60], AUC representa a fração de pares positivos-negativos ordenados corretamente.

$$taxa \ tp = \frac{TP}{P} \tag{2.40}$$

$$taxa fp = \frac{FP}{N} \tag{2.41}$$

$$precisão = \frac{TP}{TP + FP}$$
(2.42)

$$especificidade = \frac{TN}{N} \text{ ou } 1 - taxa fp \tag{2.43}$$

$$acurácia = \frac{TP + TN}{P + N} \tag{2.44}$$

$$taxa \ de \ erro \ igual = \frac{FP}{N} = \frac{FN}{P} \tag{2.45}$$

Uma outra vantagem de ROC com relação à MC consiste no fato de que, ao se tomar o processo de classificação, pode-se considerar que a organização caracteriza um processo mais básico. Esta organização pode ocorrer previamente à classificação propriamente dita ou prover uma saída final com uma ordenação das possíveis classes de acordo com as probabilidades da amostra pertencer a cada uma delas. Ou ainda, em contextos em que não é necessário atribuir uma amostra questionada a alguma classe específica, pode-se apenas fornecer indícios (probabilidades) quanto a sua caracterização e deixar a decisão para um especialista humano ou algum outro processo computacional [31, 42, 60, 61, 83].

## 2.4 Sistemas compostos por Múltiplos 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 (*Multiple Classifier Systems* - MCSs) [25, 31, 56, 60, 61].

Basicamente, as propostas para MCSs podem ser posicionadas em uma dentre três possíveis fases (Figura 2.22): geração, seleção e integração. Na primeira fase tem-se a construção dos classificadores. A seleção não é caracterizada como obrigatória e consiste na escolha de um subconjunto dos classificadores gerados na primeira fase. A fase de integração compreende a combinação (interpolação) dos classificadores selecionados, caso o subconjunto não contenha um único classificador [25, 31, 56, 60, 61].



Figura 2.22: Possíveis fases para MCSs.

MCSs ainda podem ser classificados sob diferentes parâmetros. Sob a perspectiva dos tipos das saídas dos classificadores, distingue-se três níveis: abstrato, *ranking* e probabilidade (*scores*). Se o classificador provê apenas o rótulo da classe predita em suas saídas, este é denominado *abstrato*. Se o classificador provê uma lista ordenada que indica a sequência das possíveis classes para uma amostra questionada, da mais provável à menos provável, ele será denominado *ranking*. No último nível, tem-se os classificadores cujas saídas associam valores de probabilidade *a posteriori* (*scores*) quanto à predição para todas as classes definidas no problema [56]. Neste trabalho, considerando as estratégias de combinação de classificadores apresentadas na Seção 2.4.1, cada um destes três tipos foi utilizado em algum momento.

Outra possível distinção quanto aos classificadores pode considerar os conjuntos resultantes de sua combinação. Os conjuntos *homogêneos* contêm classificadores que implementam as mesmas técnicas e que alcançam diversidade por meio de variações em seus parâmetros de configuração, tais como valores iniciais utilizados na construção dos modelos, diferentes subconjuntos dos dados de treinamento (*Bagging* [10] e *Boosting* [131]) e diferentes subespaços de características (*Random Subspace Selection* [47]). Já os conjuntos *heterogêneos* empregam diferentes tipos de classificadores, diferentes arquiteturas de classificadores ou diferentes inicializações dos parâmetros de aprendizagem, embora mantenham os mesmos conjuntos de treinamento ou dados de entrada [130]. Sob esta perspectiva, os classificadores empregados no desenvolvimento deste trabalho são heterogêneos, gerados com diferentes descritores, mas mantendo exatamente as mesmas amostras em seus conjuntos de treinamento, teste e validação.

O emprego de MCSs geralmente é vantajoso por aumentar a precisão, mas determinar quais classificadores devem ser utilizados (construídos, selecionados e/ou combinados) não é uma tarefa tão trivial [25, 42, 51, 52, 60, 61, 62]. Primeiramente, a combinação de classificadores depende do pressuposto de que todos os membros do agrupamento cometem erros de classificação independentes. Se esta independência não for garantida, não será possível assegurar que a combinação de suas decisões implicará na melhoria das taxas finais de classificação do agrupamento. Estas taxas finais podem, inclusive, piorar em alguns casos [24, 51, 52, 56, 62, 130].

Assumindo a independência dos erros dos classificadores, sua combinação permite o uso de modelos mais simples sob a perspectiva individual e eleva a precisão do conjunto de classificadores [25, 51, 52, 62, 118]. Para isso, a combinação deve garantir o emprego de classificadores complementares [7, 47, 56, 78]. A complementaridade garante que haja uma distribuição dos riscos entre os classificadores e que estes cometam erros não-correlacionados diante de novos padrões [24, 51, 52, 62, 65, 63, 64]. No entanto, nas aplicações reais de reconhecimento de padrões, é difícil projetar um conjunto de classificadores que satisfaça tal critério de independência mútua quanto a suas predições [33, 37, 51, 52, 146].

As seções seguintes apresentam algumas alternativas quanto a combinação e/ou seleção de classificadores.

## 2.4.1 Combinação de Classificadores

De acordo com Jain *et al.* [56], MCSs podem ser agrupados em três diferentes topologias (série, paralela e hierárquica), havendo ainda derivações e combinações destas. Neste trabalho, a topologia em *Paralelo* foi a única utilizada na combinação das saídas dos classificadores (*vide* Seção 4.5). Esta define o emprego dos classificadores de forma independente e, posteriormente, a combinação de seus resultados. Todos os classificadores trabalham com um mesmo escopo do problema e os erros individuais de cada classificador não interferem nos resultados individuais dos demais. Porém, o desempenho obtido por implementações desta topologia sofre grande influência da estratégia de combinação de classificadores adotada [56]. 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 a duas primeiras regras, os classificadores devem fornecer saídas com probabilidades [56, 62].

As Equações 2.47 a 2.53 apresentam as fórmulas para as regras anteriormente mencionadas. Nelas,  $s_q$  é a amostra questionada,  $V_q$  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 2.46) [56, 62].

$$s_q \rightarrow Cl_p$$
 se  
 $P(Cl_p|V_q) = \max_{l=1}^m P(Cl_l|V_q)$  (2.46)

O voto majoritário constitui a regra mais simples e conhecida para combinar classificadores, sendo que cada classificador representa um voto (Equação 2.47). 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 2.48, 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 provêem apenas o rótulo das classes preditas por cada um [56, 62].

$$s_q \rightarrow Cl_p \quad \text{se}$$

$$\sum_{k=1}^{K} \Delta_{pk} = \max_{l=1}^{m} \sum_{k=1}^{K} \Delta_{lk}, \text{ com} \qquad (2.47)$$

$$\Delta_{lk} = \begin{cases} 1, \text{ se } P(Cl_{lk}|V_q) = \max_{j=1}^m P(Cl_{jk}|V_q) \\ 0, \text{ caso contrário.} \end{cases}$$
(2.48)

A regra *Borda count* foi proposta por Black [8] 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  $Cl_p$  [8, 48].

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 2.23 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 Figuras 2.23 (a-c)), o maior número de pontos foi acumulado pela classe dois (Figuras 2.23 (d)). Esta é definida como "vencedora", mesmo com apenas um dos classificadores a identificando como tal [8, 48].



Figura 2.23: Borda *count*.

A regra *Produto* combina as probabilidades finais para cada classe  $Cl_l$  por meio de um produtório entre as probabilidades associadas às saídas dos classificadores para esta classe (Equação 2.49) [56, 62].

$$s_q \rightarrow Cl_p \qquad \text{se}$$

$$\prod_{k=1}^K P(Cl_{pk}|V_q) = \max_{l=1}^m \prod_{k=1}^K P(Cl_{lk}|V_q) \qquad (2.49)$$

A Soma combina as probabilidades finais para cada classe  $Cl_l$  pelo somatório das probabilidades associadas às saídas dos classificadores  $C_k$  (Equação 2.50). De forma semelhante, a Média (Equação 2.51) calcula a média entre as probabilidades associadas às saídas dos classificadores para cada classe  $Cl_l$ . Estas regras geralmente apresentam bons resultados e semelhanças entre os mesmos [56, 62].

$$s_q \to Cl_p$$
 se  
 $\sum_{k=1}^{K} P(Cl_{pk}|V_q) = \max_{l=1}^{m} \sum_{k=1}^{K} P(Cl_{lk}|V_q)$  (2.50)

$$s_q \to Cl_p$$
 se  
 $\frac{1}{K} \sum_{k=1}^{K} P(Cl_{pk}|V_q) = \max_{l=1}^{m} \frac{1}{K} \sum_{k=1}^{K} P(Cl_{lk}|V_q)$  (2.51)

*Máximo* (Equação 2.52) 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 2.53), 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 [56, 62].

$$s_q \rightarrow Cl_p \qquad \text{se}$$

$$\max_{k=1}^K P(Cl_{pk}|V_q) = \max_{l=1}^m (\max_{k=1}^K P(Cl_{lk}|V_q)) \qquad (2.52)$$

$$s_q \rightarrow Cl_p \qquad \text{se}$$

$$\min_{k=1}^{K} P(Cl_{pk}|V_q) = \max_{l=1}^{m} (\min_{k=1}^{K} P(Cl_{lk}|V_q)) \qquad (2.53)$$

Considerando as regras que exigem o emprego de probabilidades (produto, soma, média, máximo e mínimo) e que estes valores sejam expressos no intervalo [0,1], estas podem ser categorizadas de acordo com sua severidade (Equação 2.54). Produto caracterizase como a mais severa, pois a ocorrência de pelo menos uma probabilidade com valor baixo para uma classe  $Cl_l$  em um dos classificadores  $C_k$  incorrerá em um valor resultante final baixo a ser associado a  $Cl_l$ . Esta regra é indicada para situações de extrema criticidade, nas quais erros não são tolerados ou a tolerância permite taxas de erros muito pequenas. Mínimo é considerada severa e Máximo é uma regra de baixa severidade [56, 62].

$$\prod_{k=1}^{K} P(Cl_{lk}|V_q) \leq \min_{k=1}^{K} P(Cl_{lk}|V_q) \leq \dots$$

$$\leq \frac{1}{K} \sum_{k=1}^{K} P(Cl_{lk}|V_q) \leq \max_{k=1}^{K} P(Cl_{lk}|V_q)$$
(2.54)

#### 2.4.2 Seleção de Classificadores

Dado um conjunto com K classificadores, a melhor alternativa para sua combinação não necessariamente implicará na utilização de todos eles, mas na escolha daqueles que se demonstrarem complementares. O emprego de classificadores com sobreposição pode implicar no aumento do custo computacional, bem como na redução das taxas de reconhecimento individuais [56, 78, 130]. Assim, a seleção de classificadores provê maior flexibilidade aos sistemas e estabelece diferentes alternativas para a escolha de um subconjunto dos classificadores disponíveis, para sua posterior combinação na classificação de um conjunto de amostras [7, 24, 47].

Tomando como parâmetro o momento em que o conjunto de classificadores é determinado, a seleção pode ser definida como estática ou dinâmica. Na seleção estática, todas as amostras questionadas  $s_q$  são classificadas por um subconjunto fixo de classificadores, o qual é definido na fase de treinamento. Por outro lado, na seleção dinâmica, o subconjunto de classificadores é definido durante a fase de classificação, considerando as características das diferentes  $s_q$  [56, 65, 63, 64, 127, 130].

As principais alternativas quanto à seleção de classificadores são apresentadas na Figura 2.24. Na Seleção Estática de Agrupamento (Figura 2.24(a)), um subconjunto dos classificadores disponíveis é pré-selecionado durante o treinamento. O mesmo subconjunto é então empregado para a classificação, independentemente de variações na caracterização do problema ou das amostras. Na Seleção Dinâmica de Classificador (Figura 2.24(b)) um único classificador é escolhido com base nas características da amostra. A Seleção Dinâmica de Agrupamento (Figura 2.24(c)) considera as características de cada  $s_q$  para selecionar um subconjunto de classificadores. Tanto no primeiro quanto no terceiro caso, as saídas dos classificadores selecionados são combinadas seguindo critérios que podem variar em função dos classificadores escolhidos. De modo diferente, a decisão do classificador selecionado no segundo caso é assumida como a decisão final do sistema [65, 63, 64].

Por necessitar que apenas um classificador realize a predição corretamente para cada amostra, a criação de MCSs baseados em seleção de um único classificador torna-se bem mais simples que a criação de MCSs baseados em seleção e/ou combinação de múltiplos classificadores. Entretanto, a seleção de agrupamentos tende a apresentar melhores resultados [33, 35, 146]. Considerando as limitações e o foco deste trabalho, a próxima subseção descreve alguns métodos para seleção dinâmica de um único classificador e também para



**Figura 2.24:** Alternativas para a seleção de classificadores [64]: (a) seleção estática de agrupamento; (b) seleção dinâmica de classificador; e (c) seleção dinâmica de agrupamento.

a seleção dinâmica de agrupamentos de classificadores.

## 2.4.2.1 Seleção Dinâmica de Classificadores

Algumas alternativas têm sido propostas para minimizar ou eliminar a imposição quanto aos classificadores independentes. Dentre estas, têm-se conjuntos de classificadores nãocorrelacionados [108, 126], funções de combinação que não impõem tal independência [51, 52] e seleção dinâmica de classificadores [33, 34, 35, 146].

As estratégias empregadas na seleção dinâmica de classificadores podem considerar diferentes critérios de competência durante a escolha do subconjunto dos classificadores. Alguns critérios concentram-se na interação entre os elementos do conjunto por meio de sua diversidade e ambiguidade enquanto outros baseiam-se nas taxas individuais dos classificadores na vizinhança da amostra questionada  $s_q$  (Local Accuracy) [7, 24, 47, 56, 63, 64, 65, 78, 130].

Este trabalho concentra-se no segundo grupo e em suas possíveis alternativas para a seleção dinâmica de um único classificador ou de agrupamentos de classificadores. Algumas destas alternativas são brevemente apresentadas nesta seção e utilizam as definições da Seção 2.4.1. Além disso, conforme apresentado no Capítulo 1 e detalhado na Seção 4.4, devido à representação baseada em vetores de dissimilaridade, a seleção e/ou combinação dos classificadores ocorre neste espaço de representação. Ou seja, enquanto a seleção no espaço de características ocorreria uma única vez para a amostra questionada  $s_q$ , no espaço de dissimilaridade esta ocorre para cada vetor de dissimilaridade  $Z_{q,j}$  criado para  $s_q$ 

e as referências utilizadas  $r_j$ . Destaca-se também que não foi necessário realizar quaisquer alterações nos métodos de seleção dinâmica de classificadores originais para empregá-los neste estudo. Ao mesmo tempo, os métodos propostos na Seção 4.4.2, embora tenham sido empregados apenas no espaço de dissimilaridade, também podem ser utilizados no espaço de características.

Para definir a relação de proximidade entre  $s_q$  e os vizinhos mais próximos (referências  $r_j$ ) do conjunto de validação, Woods *et al.* [146] utilizaram a distância Euclidiana  $d(s_q, r_j)$ . Os autores estimam a acurácia de cada classificador na vizinhança de  $s_q$  e selecionam o classificador mais preciso nesta vizinhança, assumindo esta decisão individual como a decisão global do MCS para  $s_q$ .

Implicitamente, os mesmos autores também definem critérios Acurácia Local Geral (Overall Local Accuracy - OLA) e Acurácia de Classe Local (Local Class Accuracy -LCA) para a delimitação da vizinhança, os quais são utilizados por outras técnicas. Pelo critério OLA, todas as h referências do conjunto de validação compõem a vizinhança de  $s_q$ . Já o critério LCA limita a vizinhança de  $s_q$  para cada classificador  $C_k$ . Ou seja, pelo critério LCA, dado que  $C_k$  classifique  $s_q$  como pertencente à classe  $Cl_l$ , a vizinhança de  $s_q$  será composta apenas pelas  $h_l$  ( $h_l \leq h$ ) referências do conjunto de validação também pertencentes à  $Cl_l$ .

Proposto por Woods *et al.* [146], o método OLA (Pseudo-código 2.1) emprega o critério OLA ao delimitar a vizinhança de  $s_q$ . Este considera que o classificador mais preciso  $C^*$  é definido pela maximização da taxa de vizinhos corretamente classificados em todo o conjunto de Validação (Equação 2.55), com  $h_k$  sendo a quantidade de vizinhos corretamente classificados pelo classificador  $C_k$  [63, 64, 65, 146].

$$C^* = \max_{k=1}^{K} \frac{h_k}{h}$$
(2.55)

O método LCA (Pseudo-código 2.2) emprega o critério LCA para delimitar a vizinhança de  $s_q$ . Conforme a Equação 2.56, o classificador selecionado  $C^*$  será aquele que maximizar a relação entre os vizinhos por ele corretamente classificados e pertencentes à classe  $Cl_l$  ( $h_{lk}$ ) e todos os vizinhos pertencentes à classe  $Cl_l$  ( $h_l$ ) [63, 64, 65, 146].

$$C^* = \max_{k=1}^{K} \frac{h_{lk}}{h_l}$$
(2.56)

Giacinto e Roli [35] demonstraram que um classificador Bayseano ótimo pode ser obtido por meio da seleção de um classificador  $C_k$  considerando as probabilidades de suas predições corretas. A partir disto, os autores assumem classificadores probabilísticos (*scores*), ao invés dos abstratos (rótulos) considerados por Woods *et al.* [146], e propõem variantes dos métodos anteriores. Por considerar apenas as probabilidades das predições corretas, a vizinhança é limitada a  $h_k$  nas Equações 2.57 e 2.58, bem como a  $h_{lk}$  nas Equações 2.59 e 2.60.

O método a priori (Pseudo-código 2.3) baseia-se no método OLA e no critério OLA

Pseudo-código 2.1. Método OLA. Detalhes: classificadores abstratos, critério OLA para delimitação da vizinhança. **Entradas:** conjunto de validação, rótulos associados por cada classificador  $C_k$ para todo o conjunto de validação, tamanho h da vizinhança. Saída: classificador  $C_k$  que maximiza a taxa de vizinhos corretamente classificados. 1: ordene os elementos do conjunto de validação considerando suas distâncias Euclidianas para  $s_q$ , em ordem crescente 2: para cada classificador  $C_k$  faça conte os  $h_k$  vizinhos mais próximos corretamente classificados por  $C_k$ 3: 4: calcule a taxa de vizinhos corretamente classificados por  $C_k$  (Eq. 2.55) 5: fim-para selecione  $C_k$  que maximiza a taxa de vizinhos corretamente classificados 6: calculada nos passos 2-5. Pseudo-código 2.2. Método LCA. Detalhes: classificadores abstratos, critério LCA para delimitação da vizinhança. Entradas: conjunto de validação, rótulos associados por cada classificador  $C_k$ para todo o conjunto de validação, tamanho  $h_l$ da vizinhança, rótulo da classe  $Cl_l$  associada por  $C_k$  à  $s_q$ . Saída: classificador  $C_k$  que maximiza a taxa de vizinhos corretamente classificados. ordene os elementos do conjunto de validação considerando suas distâncias 1: Euclidianas para  $s_q$ , em ordem crescente 2: para cada classificador  $C_k$  faça 3: selecione os  $h_l$  vizinhos mais próximos no conjunto de validação conte os  $h_{lk}$  vizinhos mais próximos corretamente classificados por  $C_k$ 4: 5:calcule a taxa de vizinhos corretamente classificados por  $C_k$  (Eq. 2.56) 6: fim-para selecione  $C_k$  que maximiza a taxa de vizinhos corretamente classificados 7:

calculada nos passos 2-6.

para delimitar a vizinhança de  $s_q$ , com a Equação 2.57 substituindo Equação 2.55. Com o intuito de minimizar a incerteza inerente ao tamanho da vizinhança, os autores também propõem a aplicação dos pesos  $W_i = 1/d(s_q, r_j)$  correspondentes às distâncias Euclidianas entre  $s_q$  e seus vizinhos  $r_j$  por meio da Equação 2.58 [35].

$$C^* = \max_{k=1}^{K} \frac{\sum_{i=1}^{h_k} \hat{P}(Cl_{lk} \mid V_i \in Cl_l)}{h_k}$$
(2.57)

$$C^* = \max_{k=1}^{K} \frac{\sum_{i=1}^{n_k} \hat{P}(Cl_{lk} \mid V_i \in Cl_l) W_i}{\sum_{i=1}^{h_k} W_i}$$
(2.58)

O método *a posteriori* (Pseudo-código 2.4), por sua vez, é baseado no método LCA e no critério LCA para delimitar a vizinhança de  $s_q$ , com a Equação 2.59 substituindo a Equação 2.56. Com o intuito de minimizar a incerteza inerente ao tamanho da vizinhança, os autores também propõem a aplicação dos pesos  $W_i = 1/d(s_q, r_j)$  (Equação 2.60) [35].

Em outro trabalho, Giacinto e Roli [36] propõem a seleção dinâmica de classificadores

baseada no comportamento de múltiplos classificadores (Multiple Classifier Behaviour -MCB). Nesta proposta, cria-se uma assinatura  $MCB(s_i)$ , tal como expresso na Equação 2.61, com as predições  $C_k(s_i)$  do classificador  $C_k$  (k = [1, K]) para cada amostra  $s_i$  dos conjuntos de Teste ( $s_q$ ) e Validação ( $r_j$ ). Para cada amostra questionada  $s_q$ , calcula-se o índice de similaridade  $S(s_q, r_j)$  entre  $s_q$  e seus vizinhos  $r_j$ , o qual é dado pela Equação 2.62, com  $T_k(s_q, r_j)$  dado pela Equação 2.63.

$$C^{*} = \max_{k=1}^{K} \hat{P}(C_{k}(V_{i}) = Cl_{l} \mid V_{i} \in Cl_{l}) = \max_{k=1}^{K} \frac{\sum_{i=1}^{h_{lk}} \hat{P}(Cl_{lk} \mid V_{i})}{\sum_{i=1}^{h_{l}} \hat{P}(Cl_{l} \mid V_{i})}$$
(2.59)  
$$C^{*} = \max_{k=1}^{K} \hat{P}(C_{k}(V_{i}) = Cl_{l} \mid V_{i} \in Cl_{l}) = \max_{k=1}^{K} \frac{\sum_{i=1}^{h_{lk}} \hat{P}(Cl_{lk} \mid V_{i})W_{i}}{\sum_{i=1}^{h_{l}} \hat{P}(Cl_{l} \mid V_{i})W_{i}}$$
(2.60)

Pseudo-código 2.3. Método a priori.

**Detalhes:** classificadores probabilísticos, critério OLA para delimitação da vizinhança e restritos somente aos  $h_k$  corretamente classificados por cada  $C_k$ .

**Entradas:** conjunto de validação, probabilidades *a posteriori* associadas por cada  $C_k$  para todo o conjunto de validação, tamanho  $h_k$  da vizinhança.

**Saída:** classificador  $C_k$  que maximiza as probabilidades a posteriori dos  $h_k$ 

vizinhos mais próximos  $r_j$  ponderadas pela distância Euclidiana  $d_j$  entre  $s_q \in r_j$ . 1: ordene os elementos do conjunto de validação considerando suas distâncias

- Euclidianas para  $s_q$ , em ordem crescente
- 2: para cada classificador  $C_k$  faça
- 3: selecione os  $h_k$  vizinhos vizinhos mais próximos corretamente classificados no conjunto de validação

4: calcule a média ponderada das probabilidades a posteriori (Eq. 2.58)

- 5: fim-para
- 6: Selecione  $C_k$  que maximiza a média ponderada calculada nos passos 2-5.

O índice S define a relação de vizinhança e proximidade entre  $s_q$  e seus vizinhos  $r_j$ , havendo maior semelhança entre eles à medida que o valor de S aumenta. Assim, para cada  $s_q$ , seus vizinhos  $r_j$  são ordenados com base em S, sendo utilizados todos os que tiverem índice de similaridade superior a um limiar pré-definido. Na sequência, tomandose as assinaturas  $MCB(r_j)$ , para cada classificador  $C_k$ , contabiliza-se a taxa de acertos (Equação 2.55) para os h vizinhos (referências) mais próximos à  $s_q$  selecionados. Por fim, seleciona-se o classificador  $C_k$  que apresentar a maior taxa de acertos. Pseudo-código 2.4. Método a posteriori.

- **Detalhes:** classificadores probabilísticos, critério LCA para delimitação da vizinhança e restritos somente aos  $h_{lk}$  corretamente classificados por cada  $C_k$ .
- **Entradas:** conjunto de validação, probabilidades *a posteriori* associadas por cada  $C_k$  para todo o conjunto de validação, tamanho  $h_{lk}$  da vizinhança, rótulo da classe  $Cl_l$  associada por  $C_k$  à  $s_q$ .

**Saída:** classificador  $C_k$  que maximiza as probabilidades *a posteriori* dos  $h_{lk}$  vizinhos mais próximos  $r_j$  ponderadas pela distância Euclidiana  $d_j$  entre  $s_q \in r_j$ .

- 1: ordene os elementos do conjunto de validação considerando suas distâncias Euclidianas para  $s_a$ , em ordem crescente
- 2: para cada classificador  $C_k$  faça
- 3: selecionar os  $h_{lk}$  vizinhos vizinhos mais próximos corretamente classificados no conjunto de validação
- 4: calcule a média ponderada das probabilidades a posteriori (Eq. 2.60)

5: fim-para

6: selecione  $C_k$  que maximiza a média ponderada calculada nos passos 2-5.

$$MCB(s_i) = \{C_1(s_i), C_2(s_i), ..., C_k(s_i), ..., C_K(s_i)\}$$
(2.61)

$$S(s_q, r_j) = \frac{1}{n} \sum_{k=1}^{n} T_k(s_q, r_j)$$
(2.62)

$$T_k(s_q, r_j) = \begin{cases} 1, & \text{se } C_k(s_q) = C_k(r_j) \\ 0, & \text{se } C_k(s_q) \neq C_k(r_j) \end{cases}$$
(2.63)

Como se pode perceber, Giacinto e Roli [36] definem a taxa de acertos de forma global, sendo que os próprios autores mencionam a semelhança com o método OLA na fase de definição do classificador selecionado. Por aplicar o critério OLA para a delimitação da vizinhança de  $s_q$ , com sua independência com relação à classe predita, esta estratégia será aqui denominada MCB OLA (Pseudo-código 2.5). Além disto, os autores propõem o uso de um limiar pré-definido e que implica em diferentes quantidades de vizinhos para cada  $s_q$ . Em seu trabalho, os autores não utilizam um limiar fixo, mas sim determinam a quantidade de vizinhos a serem considerados. Neste sentido, devido à alta probabilidade de haver índices de proximidade muito semelhantes entre o *h*-ésimo vizinho e seus sucessores, os autores definem que todos os sucessores com o mesmo índice que o *h*-ésimo vizinho sejam selecionados.

Outro método para seleção dinâmica de classificadores (ensembles) bastante referenciado na literatura foi proposto por Ko et al. [65, 63, 64]. Denominado KNORA (K-Nearest-ORAcles - k oráculos mais próximos), este se diferencia dos demais por escolher o subconjunto de classificadores  $C^*$  que corretamente classificam os k vizinhos mais próximos de uma instância questionada  $s_q$ , no conjunto de validação. Na Figura 2.25, em ambas ilustrações, os pequenos círculos da esquerda representam os vizinhos de  $s_q$  no conjunto de validação, sendo que apenas os cinco mais próximos são considerados neste exemplo.

A Figura 2.25(a) representa a versão KNORA-ELIMINATE (KNORA-E), dada pela

Pseudo-código 2.5. Método MCB OLA.
Detalhes: classificadores abstratos, critério OLA para delimitação da vizinhança.
Entradas: conjunto de validação, rótulos associados por cada classificador C<sub>k</sub> para todo o conjunto de validação, tamanho h da vizinhança.
Saída: classificador C<sub>k</sub> que maximiza a taxa de vizinhos corretamente classificados.
1: crie vetor MCB(s<sub>i</sub>), conforme Eq. 2.61, para cada amostra s<sub>i</sub> dos conjuntos de teste e validação
2: ordene os elementos do conjunto de validação considerando sua similaridade com s<sub>q</sub> (Eq. 2.62), em ordem decrescente
3: selecione os elementos do conjunto de validação com o índice de similaridade maior ou igual ao do h-ésimo elemento

- 4: para cada classificador  $C_k$  faça
- 5: conte os  $h_k$  vizinhos corretamente classificados por  $C_k$  na vizinhança selecionada no passo 3
- 6: calcule a taxa de vizinhos corretamente classificados por  $C_k$  (Eq. 2.55)

7: fim-para

8: selecione  $C_k$  que maximiza a taxa de vizinhos corretamente classificados calculada nos passos 4-7.

interseção dos classificadores que classificam os elementos de uma dada vizinhança corretamente. Nesta versão (Pseudo-código 2.6), dados os k vizinhos mais próximos  $r_j$  (j = [1, k])a  $s_q$  e o subconjunto de classificadores  $C^*$  que corretamente classificam todos os k vizinhos, cada classificador  $C_i \in C^*$  terá direito a um voto na classificação de  $s_q$ . No entanto, se nenhum classificador puder classificar corretamente todos os k vizinhos mais próximos a  $s_q$ , dever-se-á selecionar o(s) classificador(es) com o maior número de acertos dentre os k vizinhos. Já para KNORA-UNION (KNORA-U) tem-se a união dos classificadores que corretamente classificam pelo menos um dos elementos pertencentes a uma determinada vizinhança (Figura 2.25(b)). Nesta versão (Pseudo-código 2.7), cada classificador  $C_i$  terá direito a um voto para cada vizinho  $r_j$  por ele corretamente classificado dentre os k vizinhos mais próximos a  $s_q$ .

Similar a Giacinto e Roli [36], Ko *et al.* [64, 65] também propõem versões do KNORA em que as distâncias entre  $s_q \in r_j$  são utilizadas como pesos para os votos dos classificadores selecionados. Com exceção dos pesos, as demais definições anteriores são mantidas e tais versões são denominadas KNORA-E-W e KNORA-U-W.

A Seção 4.4 apresenta três novas propostas para os métodos de seleção dinâmica de classificadores, as quais são baseadas nas estratégias propostas por Woods *et al.* [146] e Giacinto e Roli [36]. Como se pode perceber, os métodos de seleção dinâmica de classificadores aqui apresentados (e também os propostos) utilizam critérios de vizinhança e medidas de distância.

Durante o desenvolvimento deste trabalho, alguns testes foram realizados tomando medidas de distância entre a instância questionada e seus vizinhos do conjunto de validação como critério de seleção do espaço de representação a ser utilizado para a classificação. Todas as estratégias avaliadas mostraram-se inviáveis, visto que os classificadores aqui considerados foram construídos em diferentes espaços n-dimensionais. Ou seja, os testes realizados demonstram a impossibilidade quanto à realização de comparações que



# **Figura 2.25:** KNORA [64, 65]: (a) ELIMINATE; e (b) UNION.

Pseudo-código 2.6. Método KNORA-E.
Detalhes: classificadores probabilísticos.
<b>Entradas:</b> conjunto de validação, rótulos associados por cada classificador $C_k$
para todo o conjunto de validação, tamanho $h$ da vizinhança.
Saída: classe predita.
1: ordene os elementos do conjunto de validação considerando suas distâncias
Euclidianas para $s_q$ , em ordem crescente
2: para cada classificador $C_k$ faça
3: contar os $h_k$ vizinhos corretamente classificados por $C_k$
4: fim-para
5: enquanto $h > 0$ e não houver um subconjunto de classificadores $C^*$ que
classifica corretamente todos os $h$ elementos faça
6: decremente $h$
7: fim-enquanto
8: se $h > 0$
9: selecione $C^*$
10: senão
11: enquanto pelo menos um classificador não classificar um vizinho
corretamente faça
12: incremente $h$
13: fim-enquanto
14: selecione $C^*$
15: fim-se
16: use o regra de fusão 'voto majoritário' para para identificar a classe eleita
dentre aquelas preditas pelos classificadores $C^*$ .

envolvam as medidas de distância direta ou indiretamente entre os diferentes espaços

Pseudo-código 2.7. Método KNORA-U.
Detalhes: classificadores probabilísticos.
<b>Entradas:</b> conjunto de validação, rótulos associados por cada classificador $C_k$
para todo o conjunto de validação, tamanho $h$ da vizinhança.
Saída: classe predita.
1: ordene os h elementos do conjunto de validação considerando suas distâncias
Euclidianas para $s_q$ , em ordem crescente
2: para cada classificador $C_k$ faça
3: conte os $h_k$ vizinhos corretamente classificados por $C_k$
4: fim-para
5: use o regra de fusão 'voto majoritário' para para identificar a classe eleita
dentre aquelas preditas pelos classificadores $C^*$ , sendo que cada voto de $C_k$
é multiplicado pelo número de vizinhos por ele corretamente classificados.

de representação, até mesmo quando normalizadas. Assim, as versões KNORA-E-W e KNORA-U-W propostas por Ko *et al.* [64, 65] e as propostas originais de Giacinto e Roli [36] não foram utilizadas. Nestas versões, as distâncias são utilizadas como pesos em uma combinação ponderada dos votos dos classificadores e das probabilidades dos vizinhos, respectivamente. Maiores detalhes são apresentados nas Seções 4.4.1 e 5.3.2.

## 2.5 Considerações Finais

O presente capítulo apresentou os conceitos e ferramentas necessários para o desenvolvimento e a compreensão deste trabalho. Foram abordados conceitos da Anatomia da Madeira e da Botânica que embasam a representação textural considerada. Seguiu-se com os métodos utilizados para a extração e a representação dos padrões texturais, a representação no espaço de dissimilaridade e ROC.

Destacou-se os MCSs, a combinação de classificadores por meio das regras de fusão e a seleção dinâmica de classificadores como alternativa para elevar as taxas de reconhecimento. A partir deste conjunto de elementos, os próximos capítulos apresentam uma revisão da literatura com o estado da arte em reconhecimento de espécies florestais e a metodologia empregada no decorrer deste trabalho.

# CAPÍTULO 3

# ESTADO DA ARTE EM RECONHECIMENTO DE MADEIRA

Henry Huber realizou um dos primeiros trabalhos com foco na automação da produção de artefatos de madeira. Este trabalho foi relatado em sua dissertação intitulada "*Economics of Cutting Hardwood Lumber by Two Different Methods*" em 1969 [53], com posterior publicação em 1971 sob o título "*A Computerized Economic Comparison of a Conventional Furniture Rough Mill with a New System of Processing*" [54]. Desde então, os crescentes avanços tecnológicos têm permitido ampliar o foco dos estudos. Tais estudos têm incluído o reconhecimento da espécie florestal à qual uma amostra de madeira pertence e a avaliação da qualidade desta amostra de madeira. Este capítulo apresenta uma revisão dos principais e mais recentes estudos desenvolvidos no campo de reconhecimento de espécies florestais e seus agrupamentos nos filos Angiospermas (*Hardwoods*) e Gimnospermas (*Softwoods*)<sup>1</sup>, destacando as técnicas empregadas e os resultados obtidos.

### 3.1 Revisão da Literatura

Nault e Manville [97] desenvolveram um estudo para a identificação de oito espécies do filo Gimnospermas. O método limitou-se a medir o espectro do infravermelho refletido pelas amostras de madeira no intervalo entre 4.000nm e 25.000nm, sendo cada espectro representado por um vetor de 2.116 elementos. A partir da análise de correlação e da aplicação de Análise de Componente Principal (Principal Component Analysis - PCA) às medidas anteriores, selecionou-se os diferentes conjuntos de comprimentos de onda, e suas respectivas medidas, utilizados na diferenciação das espécies. As amostras foram organizadas em três grupos com diferentes espécies e a mesma abordagem de classificação foi utilizada em dois momentos para cada um deles, considerando as amostras verdes e após estas serem desidratadas por congelamento. No primeiro agrupamento havia um total de 308 amostras das espécies Picea glauca (99), Pinus contorta (147) e Abies lasiocarpa (62). Destas, 60 compuseram o conjunto de treinamento e 248 o de teste, tendo-se alcançado taxas de reconhecimento de 83% das amostras verdes e 76% das amostras desidratadas, com 10 e 30 diferentes comprimentos de onda, respectivamente. O segundo agrupamento continha 192 imagens das espécies Larix occidentalis (158) e Pseudotsuga menziesii (34). Destas, 20 compuseram o conjunto de treinamento e 172 o de teste, tendo-se alcançado taxas de reconhecimento de 91% das amostras verdes e 98% das amostras desidratadas, com 12 e 18 diferentes comprimentos de onda, respectivamente. O último agrupamento

 $<sup>^1\</sup>mathrm{As}$  subdivisões definidas pela Botânica são apresentadas na Seção 2.1.2.

continha 166 imagens das espécies Tsuga heterophylla (92), Picea sitchensis (58) e Abies amabilis (16). Destas, 30 compuseram o conjunto de treinamento e 136 o de teste, tendose alcançado taxas de reconhecimento de 67% das amostras verdes e 83% das amostras desidratadas, com 15 e 19 diferentes comprimentos de onda, respectivamente [96, 97].

Os mesmos autores em [98] utilizaram espectroscopia por Reflectância Difusa no Infravermelho com Transformada de Fourier (*Diffuse Reflectance Infrared Fourier Transform* - DRIFT) para diferenciar espécies do filo Gimnospermas. Neste trabalho, os experimentos consideraram apenas amostras verdes, o terceiro agrupamento do trabalho anterior permaneceu o mesmo e a espécie *Picea engelmannii* foi adicionada ao primeiro conjunto. Para tais conjuntos alcançou-se taxas de reconhecimento de 99% e 94%, respectivamente.

Inserido no mesmo contexto, Brunner *et al.* [12] avaliaram o espectro do infravermelho refletido pelas amostras de madeira no intervalo entre 400nm e 1.100nm. Os autores utilizaram entre cinco e dez leituras de regiões aleatórias das amostras, bem como Classificador Discriminante Quadrático (*Quadratic Discriminant Classifier* - QDC) para identificar as espécies *Pseudotsuga menziesii*, *Pinus contorta* e *Picea sp* para 75 amostras de madeira, sendo 25 amostras por espécie. Os resultados indicaram que algumas vezes QDC realizou confusões entre *Picea sp* e *Pinus contorta*, mas alcançou resultados entre 98% e 99% ao separar *Pseudotsuga menziesii* das outras duas (*Picea sp* e *Pinus contorta*).

Lewis *et al.* [73] realizaram um estudo para a diferenciação entre *hardwoods* e *softwoods* provenientes de regiões com clima temperado. Foram empregadas características espectrais baseadas em espectroscopia Raman, a qual segundo os autores provê bandas mais bem definidas por reduzir a degradação fototérmica da amostra provocada por aquecimento e radiação de fluorescência decorrente do uso de infravermelho. Também se realizou um pré-processamento para minimizar o efeito da fluorescência. Foram utilizados 56 espectros, sendo 28 de *hardwoods* e 28 de *softwoods*. Foi utilizada validação cruzada com a divisão dos espectros em quatro folds, sendo três deles empregados para treinamento e um para teste.

Os resultados foram avaliados considerando as resoluções utilizadas para os espectros, as quais foram avaliadas como muito boa, boa, média, ruim ou muito ruim. Para esta variável, não foram encontradas diferenças entre os espectros gerados para imagens com resoluções consideradas boas ou ruins, sendo que em ambos os casos alcançou-se taxas de reconhecimento de 98,21%. Os autores identificaram a influência quanto aos diferentes níveis da radiação de fluorescência testados e do aquecimento das amostras, bem como bandas em que *hardwoods* e *softwoods* podem ser melhor diferenciados. Durante os experimentos, também identificou-se que o uso de duas camadas ocultas nas Redes Neurais (RNA) *feed-forward* propiciaram melhores resultados enquanto que RNAs sem camadas ocultas foram incapazes de diferenciar *hardwoods* e *softwoods*. De forma geral, os autores afirmam que há um alto grau de dificuldade na diferenciação entre *hardwoods* e *softwoods* por meio da combinação de espectroscopia Raman e RNAs *feed-forward*.

Yang et al. [147] replicaram o estudo anterior, substituindo as RNAs feed-forward

por RNAs Kohonen Self-Organizing Maps (SOMs) e utilizando 59 espécies de regiões com clima temperado, com 31 hardwoods e 28 softwoods. Foram empregadas SOMs uni e bidimensionais, sendo que apenas duas amostras foram classificadas incorretamente pela primeira. Houve um erro para hardwood e outro para softwood, cujas amostras ficaram próximas à fronteira definida pela SOM bidimensional. Os resultados alcançados (96.6%) foram semelhantes àqueles obtidos por Lewis *et al.* [73], mas sem a exigência de conhecimento prévio quanto ao tipo de madeira dos espectros.

Num segundo conjunto de testes, os autores incorporaram 24 novas espécies de hardwoods provenientes de regiões com clima tropical. Os resultados para a SOM unidimensional ficaram em 63,86% de acerto e, mesmo com a variação entre três e 81 neurônios, a RNA não alcançou uma completa separação dos três grupos. Os autores empregaram uma adaptação da proposta de Chen e Gasteiger [20], na qual a matriz de pesos da Kohonen SOM (representada pela distância entre cada neurônio e seus vizinhos) auxilia na exploração e agrupamento de dados desconhecidos. As taxas de reconhecimento alcançaram 89,8% e ficaram próximas daquelas obtidas com RNAs multi-camadas feedforward para diferenciar os grupos hardwoods e softwoods provenientes de regiões temperadas. As análises dos autores identificaram um nível muito alto de semelhança entre os espectros obtidos de amostras dos três diferentes grupos. Além disso, as amostras de hardwoods provenientes de regiões tropicais apresentaram espectros intermediários àquelas pertencentes aos outros dois grupos.

Lavine *et al.* [71] também realizaram um estudo para a diferenciação entre *hardwoods* e *softwoods* provenientes de regiões com clima temperado e *hardwoods* provenientes de regiões com clima tropical. Dentre as 98 amostras de madeira, 59 eram de região com clima temperado (América do Norte, 31 *hardwoods* e 28 *softwoods*) e 39 de regiões com clima tropical (Brasil, 15; e Honduras, 24). O conjunto de treinamento era composto por 88 amostras e o de teste por apenas 10 amostras.

Cada espectro foi produzido tomando-se a média de 500 varreduras e representado por um conjunto de 670 características. Após a aplicação de PCA e tomando apenas os 2 maiores componentes principais, foi possível classificar corretamente as amostras de *hardwoods* e *softwoods* provenientes de regiões temperadas. Porém, houve erros no que se refere às amostras pertencentes a *hardwoods* provenientes de regiões tropicais. Com o uso de Algoritmos Genéticos para selecionar um subconjunto dentre as 670 características, o vetor foi reduzido a apenas 8 elementos. Os autores concluíram que as 3 classes puderam ser completamente separadas e identificaram grandes diferenças entre os grupos e pequenas diferenças internamente a eles.

Palm [107] propôs uma extensão de GLCM considerando múltiplos canais de cor. O autor também aplicou sua proposta para a classificação de espécies florestais por meio de imagens da casca das plantas. A base de imagens era formada por seis espécies, cada qual com 68 imagens com dimensões 384×256. Para a realização dos experimentos, as 408 imagens foram recortadas para eliminar os planos de fundo das bordas, e as imagens
finais ficaram com dimensões de  $300 \times 200$ . O autor empregou diferentes conjuntos de treinamento e teste, os quais sempre continham 67 e uma imagens, respectivamente. O classificador utilizado foi 5-NN e distância Euclidiana entre os vetores. As taxas de reconhecimento ficaram em 72,1% para características de textura extraídas do canal 'L' do sistema LUV, 65,4% para características de textura propostas por Haralick e extraídas de imagens em escalas de cinza e 98,6% quando se combina as características inerentes à cor e as características inerentes à intensidade.

Nilsson [99] aplicou duas abordagens para a classificação de amostras da madeira das espécies *Picea Abies* e *Pinus Sylvestris*. Na primeira abordagem foram coletadas medidas por meio de espectroscopia com infravermelho próximo (*near-infrared* - NIR) de 53 discos de madeira, 28 pertencentes à espécie *Picea Abies* e 25 à *Pinus Sylvestris*. Para a segunda abordagem foram coletadas imagens RGB (*Red, Green, Blue*) de 146 discos, 79 pertencentes a *Picea Abies* e 67 pertencentes a *Pinus Sylvestris*, e que compreendiam a casca, a madeira e a combinação casca e madeira. Nesta abordagem, inicialmente aplicouse Transformada Discreta *Wavelet* (*Discrete Wavelet Transform* - DWT) bidimensional (2D DWT) seguida por DFT bidimensional (2D DFT) às imagens RGB, sendo que cada canal foi tratado como uma imagem distinta e era representado por 5.000 coeficientes das 2D DFT. Numa segunda estratégia, gerou-se uma GLCM para 0<sup>0</sup> para cada imagem, seguida pela aplicação de 2D DWT, com um vetor de características com 5.000 coeficientes das 2D DWT [99, 100].

Mínimos Quadrados Parciais (*Partial Least Squares* - PLS) foi utilizado para encontrar modelos de regressão entre os espectros coletados e as espécies reais às quais os discos utilizados pertenciam. As duas abordagens alcançaram resultados semelhantes, sendo que na primeira todas as amostras do conjunto de teste foram classificadas corretamente. Para a segunda abordagem, a combinação entre DWT e DFT alcançou 89,6%, 81,3% e 66,7% de precisão, respectivamente, para imagens com somente casca, casca e madeira e somente madeira. Já a combinação entre GLCM e DWT alcançou taxas de reconhecimento de 97,9%, 85,4% e 72,9%, respectivamente, para imagens com somente casca, casca e madeira e somente madeira [99, 100].

Nuopponen et al. [102] também tentaram distinguir hardwoods e softwoods por meio de medidas de densidade, lignina,  $\alpha$ -celulose e resina obtidas por meio de espectroscopia. A base era composta por um total de 535 amostras. Do grupo de softwoods haviam 491 amostras da espécie Picea sitchensis e 20 amostras da espécie Pinus sylvestris. As amostras pertencentes ao grupo de hardwoods foram extraídas de 24 diferentes espécies provenientes de regiões de clima tropical. O conjunto de teste foi composto por 243 amostras da espécie Picea sitchensis e as demais amostras compuseram o conjunto de treinamento.

Foram avaliados diferentes comprimentos de ondas e as combinações de seus resultados, concluindo-se que o uso de um número reduzido de diferentes comprimentos de onda manteve as taxas de reconhecimento obtidas com todo o conjunto. De forma geral, os resultados apresentados foram similares àqueles obtidos por outros estudos. Os modelos baseados nas medidas de resina e densidade diferenciaram as espécies de cada grupo. Embora o mesmo tenha ocorrido com  $\alpha$ -celulose, seus resultados foram inferiores aos anteriores, enquanto que os modelos baseados em lignina apresentaram baixa precisão.

Tou *et al.* [135] propuseram a aplicação de GLCM e *Multilayer Perceptron* (MLP) em um sistema completo. Os experimentos avaliaram a influência de diferentes distâncias na geração da GLCM e na representatividade das características empregadas na diferenciação das espécies. Para isso, foram utilizadas 50 imagens macroscópicas pertencentes a cinco diferentes espécies da base do *Centre for Artificial Intelligence and Robotics* (CAIRO). Cada imagem foi representada por um vetor com as características de contraste, correlação, energia, entropia e homogeneidade nas quatro direções (ângulos de  $0^0$ ,  $45^0$ ,  $90^0$  e  $135^0$ ), totalizando 20 características. As imagens foram divididas na proporção 50%-50%para treino e teste. Os resultados ficaram entre 60% e 72%, sendo que distâncias menores geraram valores mais próximos para todas as espécies. Os autores destacam que, de forma geral, a MLP gerou *scores* baixos para todas as espécies vencedoras em todos os experimentos.

Khalid *et al.* [59] apresentaram um sistema de baixo custo e integrado para automatizar todo o processo de reconhecimento. Este compreende a aquisição das imagens, o préprocessamento, a extração de características, a classificação e apresentação dos resultados. Foram utilizadas 1.949 imagens de 20 diferentes espécies florestais malaias pertencentes à base *Forest Research Institute of Malaysia* (FRIM). As imagens são macroscópicas e foram melhoradas com aplicação de filtro passa-alta, operações de equalização de histograma, remoção de irregularidades, binarização e melhoria do contraste. As características extraídas para cada imagem a partir das GLCM foram segundo momento angular, contraste, correlação, entropia e momento da diferença inversa para as quatro direções, num total de 20 atributos. A classificação empregou MLP, utilizou 90% das imagens para treinamento e 10% para teste, apresentando resultados superiores a 95% de acerto.

Em outro trabalho Tou *et al.* [137] empregaram uma representação unidimensional de GLCM e a compararam com o tradicional formato bidimensional. A proposta unidimensional implica em um menor custo computacional e representa apenas a frequência da diferença (ou da soma) de dois níveis de cinza. Por ser diferente da forma tradicional, que representa a frequência de co-ocorrência entre dois níveis de cinza, esta implica na realização de alguns ajustes nas fórmulas propostas por Haralick. Os autores utilizaram as bases de imagens Brodatz e CAIRO, bem como os classificadores *k*-Nearest Neighbors (*k*NN, k = [1, 10]) e MLP. Os experimentos consideraram ainda diferentes combinações das características contraste, energia, entropia, homogeneidade e correlação, calculados para as quatro direções e concatenados. Também variou-se a distância (d = [1, 5]), os níveis de cinza (8, 16, 32, 64, 128 e 256).

Para a base Brodatz, as GLCM bi e unidimensional obtiveram taxas de reconhecimento de 81,35% (k=1) e 83,01% (k=4), respectivamente. Na base CAIRO todos os experimentos empregaram cinco espécies com 100 imagens cada uma, considerando divisões com proporções 50%-50% e 90%-10% para treinamento e teste. As melhores taxas de reconhecimento (80%) foram obtidas com kNN (k=3) para a primeira divisão e GLCM unidimensional contra 77% para MLP com 32 níveis de cinza para a segunda divisão. De forma geral, os resultados indicaram que o número de níveis de cinza e a distância empregada na obtenção da GLCM afetaram os resultados finais; GLCM unidimensional obteve resultados melhores que a bidimensional mesmo com menos descritores que a GLCM convencional; de forma geral, kNN apresentou desempenho pior que MLP.

Os mesmos autores em [138] realizaram testes para reconhecimento de textura considerando as técnicas Matriz de Covariância, GLCM, filtros de Gabor e a combinação das duas últimas. Foram utilizadas imagens macroscópicas de seis espécies florestais da base CAIRO, num total de 600 imagens (100 para cada espécie). Foram empregadas 90% destas para treinamento e 10% para teste do classificador kNN. Cada imagem foi dividida em 16 amostras (partes) com dimensões de  $64 \times 64$  pixels. Foram aplicadas três variações (rotação, escala e rotação e escala em conjunto) a cada uma destas amostras. Posteriormente, foram combinadas a imagem normal e estas três variações para representar as amostras finais. Deste conjunto de imagens com 16 combinações, foram escolhidas aleatoriamente oito para treinamento e as oito restantes para teste (como em [136]). Após dez execuções, as taxas médias de reconhecimento foram 85% para matriz de covariância aplicadas às imagens geradas pelos filtros de Gabor; 78,33% para *raw GLCM*; 76,67% para GLCM; 73,33% para filtros de Gabor; e 76,67% para GLCM combinada com filtros de Gabor.

Os autores ainda apresentaram em [139] um algoritmo invariante a rotação focando o reconhecimento de espécies florestais por meio de imagens macroscópicas. Durante o processo de classificação, era verificado se a espécie da amostra questionada correspondia a alguma das espécies com exemplares na base de treinamento. O algoritmo empregou GLCM e considerou os valores de energia para definir o grau de similaridade entre os pares amostra de teste e amostra (*template*) de treinamento. Também foi considerado um limiar para determinar a compatibilidade (ou não) entre ambas as amostras. Nos testes foram empregadas distância de um pixel para GLCM e 510 imagens macroscópicas de seis espécies florestais da base CAIRO. No início do processo, tais imagens foram convertidas para oito níveis de cinza. Além disso, as imagens originais que possuíam dimensões de  $576 \times 768$  pixels foram recortadas em fragmentos com dimensões  $512 \times 512$  pixels e  $256 \times 256$ pixels. Em cada teste, foi utilizado 90% das imagens para treinamento e 10% para teste, sendo que a determinação da classe vencedora ocorreu por meio de votação. As taxas obtidas foram 80% para imagens inteiras; 78,33% para as dimensões  $512 \times 512$ ; e 73,33% para  $256 \times 256$  pixels.

Ioannou *et al.* [55] apresentaram um sistema especialista baseado em regras para a identificação de espécies florestais existentes na Grécia. O sistema foi implementado por meio de árvores de decisão construídas a partir das chaves de identificação das espécies.

As informações das chaves de identificação das espécies eram fornecidas de forma iterativa. Como consequência, podia-se comparar a amostra a ser classificada com outras pertencentes às espécies candidatas a cada nova informação fornecida. Os autores afirmam que esta abordagem facilita o processo de identificação das espécies florestais para qualquer público interessado no assunto. Enfatizam ainda que esta abordagem não obriga o público a ter contato com especialistas da área e que a repetição do processo de identificação pode garantir a precisão de seus resultados e evitar equívocos quanto aos mesmos. No entanto, os autores não apresentaram os resultados obtidos com a utilização do sistema proposto.

Paula Filho *et al.* [110] apresentaram uma base composta por 347 imagens de 11 diferentes espécies florestais brasileiras. A aquisição das imagens ocorreu com distância e iluminação padronizadas, com uma câmera fotográfica digital e aproximação ótica de dez vezes. Os experimentos consideraram as imagens inteiras e sua divisão, com a melhor alternativa para 25 fragmentos. Foram empregadas 18 características de cor e 24 extraídas de GLCM, num total de 42. As características de cor combinaram canais dos modelos RGB, HSV (*Hue, Saturation and Value*) e CIELUV<sup>2</sup>. Já para GLCM, considerou-se energia, contraste, entropia, homogeneidade, probabilidade máxima e momento de terceira ordem para as quatro direções e distância de um pixel. As imagens foram divididas na proporção 30%-50%-20% para os conjuntos de treinamento, teste e validação. Para tais configurações, as taxas de reconhecimento do classificador MLP foram 65% para as imagens inteiras e 82% quando estas eram divididas e se realizava votação.

A base proposta em [110] foi ampliada pelos autores em [111] com 11 novas espécies. A segunda versão da base contém 1.270 imagens pertencentes a 22 diferentes espécies. Os procedimentos e ferramentas foram os mesmos descritos no trabalho anterior e os resultados finais foram 66,3% para as imagens inteiras e 80,8% quando estas eram divididas e se realizava votação. Ou seja, embora se tenha dobrado o número de espécies e triplicado o número de imagens, os resultados se mantiveram semelhantes.

Labati *et al.* [67] realizaram uma série de experimentos considerando a distinção entre *hardwoods* e *softwoods*, bem como entre as 21 diferentes espécies florestais presentes no conjunto de amostras utilizadas. Os experimentos consideraram 20 espectros para cada espécie, obtidos em regiões diferentes das amostras e avaliados com diferentes quantidades e comprimentos de ondas. As diferentes configurações para as RNAs *feed-forward* compreenderam o uso de 3, 10 ou 30 neurônios na camada oculta, sendo que todas elas tinham duas camadas e utilizavam as funções de ativação *log-sigmoidal* na camada intermediária e *linear* na camada de saída.

Com validação cruzada com 12 folds e 12 execuções, os resultados alcançados indicaram a possibilidade de se aplicar a proposta a sistemas de tempo real. A classificação entre hardwoods e softwoods alcançou taxas de reconhecimento de 97,9% ( $\sigma$ =3,0), para a qual se utilizou uma configuração mais simples com 11 filtros óticos com amplitude de 100nm

<sup>&</sup>lt;sup>2</sup>Proposta pela International Commission on Illumination, com L referenciando a luminosidade (lightness), U a graduação de vermelho e V a predominância do verde sobre o azul.

e centros regularmente distribuídos entre 500nm e 750nm. Já a diferença entre as 21 espécies alcançou taxas de reconhecimento de 82,4% ( $\sigma=9,8$ ) e exigiu o emprego de 30 filtros óticos com amplitude de 100nm e centros regularmente distribuídos entre 500nm e 750nm.

Piuri e Scotti [116] propuseram um sistema para a classificação da madeira de 21 espécies florestais. O sistema utilizou espectros de fluorescência para a extração de características e permitia a classificação das amostras de madeira em tempo real. Os autores empregaram um intervalo fixo de comprimentos de ondas e os espectros de fluorescência foram normalizados para minimizar os efeitos inerentes à absorção de luz por parte das amostras. Os dados foram divididos em 10 *folds*, houveram 10 rodadas e, em cada uma, os conjuntos de treinamento e teste eram formados por nove e um *fold*, respectivamente.

Foram empregados os Classificadores Discriminantes Lineares (*Linear Discriminant Classifier* - LDC), quadráticos (QDC), kNN e Máquina de Vetor de Suporte (*Support Vector Machine* - SVM). Para tais classificadores foram empregadas versões com e sem a utilização prévia de normalização e PCA, sendo que o segundo foi empregado com o objetivo de reduzir a dimensionalidade dos vetores de características originais. O primeiro conjunto de testes focou a diferenciação entre *hardwoods* e *softwoods*, alcançando taxas de reconhecimento de 98,93% ( $\sigma$ =0,2%) com SVM. Para estes testes, a aplicação prévia de PCA não influenciou os resultados. Considerando a diferenciação entre os 21 tipos de madeira houve taxas de reconhecimento de 93,6% ( $\sigma$ =0,9%) utilizando QDC.

Nasirzadeh *et al.* [95] realizaram um estudo focando reconhecimento de espécies florestais tropicais. Os autores apresentaram uma nova variante para LBP denominada *Local Binary Pattern Histogram Fourier Features* (LBP-HF), a qual garante invariância à rotação por meio da aplicação da DFT. Para avaliar seu desempenho, os autores realizaram testes com descritores gerados por LBP<sup>riu2</sup> (LBP with rotation invariant uniform 2 pattern code), LBP<sup>u2</sup> (LBP with uniform 2 pattern code) e LBP-HF, bem como o classificador kNN.

Foram utilizadas imagens da base CAIRO, sendo que todas as imagens de treinamento estavam com um mesmo ângulo de rotação enquanto as imagens de teste possuíam outros ângulos de rotação. O primeiro conjunto de experimentos empregou 1.000 imagens, sendo 10 diferentes espécies com 100 imagens cada uma, e considerou a proporção 70%-30% para os conjuntos de treinamento e teste, respectivamente. Os melhores resultados foram obtidos para LBP-HF para diferentes combinações (P:d) quanto a vizinhos (P) e distâncias (d), sendo 90% para (8:1), 93,33% para (16:2) e 100% para (24:3). Os experimentos anteriores foram replicados, mas considerando as 37.000 imagens e a divisão com proporção 80%-20%. Novamente, LBP-HF obteve os melhores resultados, com 83% para (8:1), 87% para (16:2) e 96,6% para (24:3), embora LBP<sup>riu2</sup> tenha obtido taxas de reconhecimento de 84% para (8:1).

Tarrío-Saavedra *et al.* [133] analisaram o potencial de identificação de espécies florestais, ou agrupamentos destas (*softwoods* e *hardwoods* - de climas temperado e tropical), considerando os níveis de degradação das amostras quando submetidas a diferentes temperaturas. Assim, a partir da variação da temperatura, foram obtidas medidas de massa (termogravimetria) e de calorimetria diferencial<sup>3</sup> e analisou-se a influência da primeira com relação às outras duas medidas.

Os experimentos empregaram sete classes, cada uma com sete amostras. Aplicou-se validação cruzada com 48 elementos no conjunto de treinamento e apenas um no conjunto de teste (a cada rodada) e quatro algoritmos de classificação: B, B-PCA, K-NPFDA (*functional Nadaraya-Watson kernel nonparametric method*) e KNN-NPFDA. Segundo os autores, os intervalos de temperatura que apresentaram as melhores taxas para cada espécie e/ou grupo de espécies coincidiram com aqueles relatados na literatura. Também os resultados alcançados são compatíveis com os apresentados na literatura por trabalhos que utilizaram sistemas baseados em processamento de imagens ou espectro. As características baseadas em medidas de massa tiveram melhor desempenho que as baseadas em calorimetria diferencial. Combinadas com o algoritmo B, as primeiras obtiveram taxas de reconhecimento de 90% na diferenciação das sete espécies e, com os algoritmos K-NPFDA e KNN-NPFDA, alcançaram 94% para a separação dos três agrupamentos.

Além dos trabalhos anteriormente destacados, há diversos outros contextos de aplicação de visão computacional envolvendo madeira. Em sua grande maioria, os estudos focam a avaliação da qualidade da madeira ainda num estado bruto ou de peças já confeccionadas. Caron-Decloquement [16], Rinnhofer *et al.* [123], Butler *et al.* [15], Lebow *et al.* [72] e Thomas *et al.* [134] focaram a identificação de defeitos decorrentes de irregularidades externas aos troncos, mas ainda ocultas pela casca. Conners *et al.* [22] avaliaram a qualidade de placas de madeira considerando características de suas superfícies (tais como nós, buracos, fissuras e manchas), características geométricas (forma e irregularidades quanto ao corte) e características internas (vazios, nós e regiões deterioradas). Em sua maioria, os trabalhos concentram-se na detecção e classificação de defeitos em placas de madeira [13, 30, 41, 74, 119] e otimização de cortes de peças de madeira considerando a eliminação de defeitos [19, 93, 115]. Num contexto mais específico, mas não menos importante, há processos de inspeção de produtos finais [92], tal como a avaliação da qualidade de peças de piso de madeira realizado por Kauppinen [58], a qual se baseou em características de cor.

# 3.2 Considerações Finais

Este capítulo apresentou um levantamento dos principais e mais recentes estudos desenvolvidos no campo de reconhecimento de espécies florestais, os quais estão resumidos na Tabela 3.1. Relativamente recente, esta linha de pesquisa tem sido impulsionada pela necessidade de compradores e órgãos de fiscalização certificarem a matéria-prima, pela

 $<sup>^{3}</sup>Differential \ scanning \ calorimetry$  é uma técnica termo-analítica que relaciona a diferença entre a quantidade de calor utilizada e a temperatura do objeto.

evolução tecnológica e pela crescente escassez de algumas espécies florestais.

Na Tabela 3.1, a coluna 'Amostras' apresenta a relação entre as quantidades de imagens (TL) e classes (CL), bem como o nível da Botânica (N) em que a classificação ocorreu em cada trabalho. Já a coluna 'Distribuição' apresenta a relação quanto às imagens utilizadas para treinamento (TR), teste (TS) e validação (VL), embora nem todos os experimentos tenham considerado a validação.

Autor	Ano	Características	Classificador	Amostras		Dist	Distribuição(%)		Taxas	
				TL	CL	Ν	TR	TS	VL	(%)
[97]	1992	Espectro infravermelho	An. Correlação	192	2	Ε	10	90	-	98,0
[98]	1997	DRIFT	An. Correlação	166	3	Ε	18	82	-	99,0
[12]	1996	DRIFT	QDC	75	3	Ε	-	-	-	99,0
[107]	2004	Matriz de Co- ocorrência para Cor	5-NN	408	6	Ε	98	2	-	$_{98,6}$
[99]	2005	Espectro infravermelho	PLS	53	2	Ε	-	-	-	100,0
[135]	2007	GLCM	MLP	50	5	Ε	50	50	-	72,0
[59]	2008	GLCM	MLP	1.949	20	$\mathbf{E}$	90	10	-	95,0
[137]	2008	GLCM	kNN	500	5	$\mathbf{E}$	50	50	-	80,0
[138]	2009	Filtros Gabor e Matriz de Covariância	kNN	600	6	Е	90	10	-	85,0
[139]	2009	GLCM e raw GLCM	kNN	510	6	$\mathbf{E}$	90	10	-	80,0
[55]	2009	Chaves dicotômicas	Árvores de Decisão	-	-	$\mathbf{E}$	-	-	-	-
[110]	2009	cor e GLCM	MLP	347	11	$\mathbf{E}$	30	50	20	82,0
[111]	2010	cor e GLCM	MLP	1.270	22	$\mathbf{E}$	30	50	20	80,8
[95]	2010	LBP-HF	kNN	1.000	10	$\mathbf{E}$	70	30	-	$96,\!6$
[67]	2009	Espectro de Fluo-	RNA feed-forward	420	21	$\mathbf{E}$	-	-	-	82,4
		rescência								
				420	2	$\mathbf{F}$	-	-	-	97,9
[116]	2010	Espectro	SVM	420	21	$\mathbf{E}$	90	10	-	$93,\!6$
			QDC	420	2	$\mathbf{F}$	90	10	-	98,9
[133]	2011	Medida de massa	В	49	7	$\mathbf{E}$	98	2	-	90,0
			K-NPFDA/	49	3	G	98	2	-	94,0
			KNN-NPFDA							
[73]	1994	Espectro de Raman	RNA feed-forward	56	2	F	75	25	_	98,2
[147]	1999	Espectro de Raman	RNA SOM 1D	59	2	$\mathbf{F}$	-	-	-	$96,\!6$
[71]	2001	Espectro de Raman	PCA	98	2	$\mathbf{F}$	90	10	-	100,0
[102]	2006	Espectro	PLS	535	2	F	55	45	-	100,0

**Tabela 3.1:** Síntese dos resultados apresentados para classificação de madeira.

(-) não se aplica ou não apresentado.

(EF) Espectro de Fluorescência.

(E) Classificação em nível de Espécies.

(F) Classificação em nível de Filo (Angiospermas e Gimnospermas).

(G) Classificação em nível de Grupos de Espécies.

Ao se considerar o número de aproximações, tem-se claro que esta variável pode influenciar as taxas de reconhecimento. No entanto, todos os trabalhos referenciados na literatura da área e apresentados neste capítulo consideraram imagens macroscópicas. Embora seja viável tanto técnica quanto financeiramente, não foram encontrados trabalhos relacionados a imagens microscópicas, tal como aquelas empregadas neste trabalho. Tal fato exclui a possibilidade de se explorar a maior riqueza de detalhes de cada um dos componentes anatômicos da madeira apresentados na Seção 2.1.

# CAPÍTULO 4

# METODOLOGIA

A metodologia empregada durante o desenvolvimento deste trabalho está inserida no contexto da Figura 2.1, assim como a visão geral de um sistema para o reconhecimento de padrões. Para o sistema de classificação proposto neste trabalho, destaca-se o processo de extração de características e as estratégias de classificação, principalmente a seleção dinâmica e/ou a combinação de classificadores. Etapas como pré-processamento e segmentação não são discutidas por basicamente terem envolvido operações como conversões entre os sistemas de cores e fragmentações das imagens em pedaços menores.

O presente capítulo inicia com uma visão geral do modelo proposto. Segue-se com o detalhamento das configurações utilizadas para a extração dos descritores de características. Para a classificação, avaliou-se os parâmetros envolvidos na geração dos vetores de dissimilaridade empregados nas fases de treinamento e teste. A seleção de classificadores apresenta as abordagens analisadas e contextualiza os métodos propostos diante daqueles pré-existentes descritos no Capítulo 2. A combinação de classificadores avalia um conjunto de oito diferentes regras de fusão. Encerrando o capítulo, são apresentados estratégias e critérios para a avaliação dos resultados obtidos e as considerações finais.

Diante da inviabilidade de testar todas as possíveis combinações para as avaliações realizadas pelos diferentes experimentos, alguns testes serviram para delinear os experimentos seguintes.

# 4.1 Visão geral da arquitetura proposta

Esta seção apresenta o modelo proposto para a classificação de espécies florestais baseada na seleção dinâmica de classificadores no espaço de dissimilaridade (Figura 4.1). Esse está fundamentado na representação baseada em vetores de dissimilaridade descrita por Bertolini *et al.* [7] e no modelo de combinação de classificadores apresentado por Hanusiak [43]. Diferente de Hanusiak, que combina classificadores no espaço ROC, a presente proposta realiza a combinação das decisões individuais para os vetores de dissimilaridade por meio de regras de fusão. Além disso, também foi incluído um módulo para selecionar dinamicamente um único classificador ou um agrupamento de classificadores dentre aqueles disponíveis, conforme descrito a seguir.

A Figura 4.1 ilustra (a) a fase de treinamento, com a construção dos modelos  $C_k$  e da base de validação, bem como (b) a classificação de uma amostra questionada  $s_q$ . Para construir os modelos  $C_k$ , um conjunto de *n* imagens de madeira  $r_u$  (u = [1..n]) é enviado para o módulo de extração de características e os vetores  $V_u$  resultantes são armazenados em uma base de referências<sup>1</sup>. Dada a nomenclatura apresentada na Seção 2.3.1 e a definição aleatória das imagens<sup>2</sup>, nesta fase uma mesma imagem pode ser utilizada como amostra  $(V_u)$  e/ou como referência  $(V_v)$  para o cômputo dos vetores de dissimilaridade  $Z_{u,v} = |V_u - V_v|$  obtidos para as classes positiva e negativa<sup>3</sup>. Tais vetores  $Z_{u,v}$  são fornecidos para o treinamento dos classificadores SVM  $C_k$  e/ou armazenados para compor o conjunto de validação utilizado para a seleção dinâmica de classificadores (no espaço de dissimilaridade) durante a fase de classificação de  $s_q$ .



**Figura 4.1:** Modelo proposto com base na seleção dinâmica de classificadores no espaço de dissimilaridade: (a) treinamento e (b) classificação.

Para que  $s_q$  seja classificada (Figura 4.1(b)), essa é apresentada ao sistema e passa pelo mesmo processo de extração de características, gerando o vetor de característica  $V_q$ . Dada a independência entre as classes utilizadas nas fases de treinamento e classificação, bem como a classe  $Cl_s$  à que  $s_q$  supostamente pertence, as referências  $r_j$  podem ser obtidas diretamente da base construída no momento em que os modelos foram treinados e/ou fornecidas ao sistema no momento em que  $s_q$  for submetida à classificação. No segundo caso, os vetores de características  $V_j$  são extraídos e armazenados na base de referências.

 $<sup>^1\</sup>mathrm{A}$  base de imagens é apresentada no Apêndice A e os parâmetros considerados para cada descritor durante a extração de características são descritos na Seção 4.2.

 $<sup>^{2}</sup>$ As imagens capturadas compreendem partes do lenho inicial, do lenho tardio e/ou de ambos, sem qualquer organização quanto a este aspecto internamente às classes. A seleção aleatória de subconjuntos e da ordem com que as imagens foram incluídas durante a geração dos vetores de dissimilaridade utilizados nas fases de treinamento e teste permitiu um maior grau de generalização do sistema e evitou que se privilegiasse um ou outro contexto (lenho inicial e/ou lenho tardio).

<sup>&</sup>lt;sup>3</sup>Este processo é apresentado na Seção 2.3.1 e a avaliação dos parâmetros para a geração dos vetores de dissimilaridade empregados nas fases de treinamento e teste é descrita na Seção 4.3.

A partir de  $V_q$  e  $V_j$ , os vetores de dissimilaridade  $Z_{q,j} = |V_q - V_j|$  são computados e os classificadores  $C_k$  geram as decisões  $d_k$  para cada  $Z_{q,j}$ . De forma geral, as decisões parciais  $D(Z_{q,j})$  dependem da seleção de apenas uma decisão  $d_k$  dentre as geradas pelo conjunto de classificadores disponíveis. A única exceção refere-se ao uso do KNORA, pois mediante a seleção de mais de um classificador, as decisões  $d_k$  dos classificadores escolhidos deverão ser combinadas para gerar  $D(Z_{q,j})$ .

Devido à transformação do espaço de características para o espaço de dissimilaridade, com a geração dos vetores  $Z_{q,j}$ , a decisão final  $D(s_q)$  para a amostra questionada  $s_q$ depende da combinação das decisões parciais selecionadas (e/ou combinadas)  $D(Z_{q,j})$ . As abordagens analisadas e os métodos propostos para seleção dinâmica de classificadores, bem como demais considerações para esta fase são descritos na Seção 4.4. Por fim, a combinação dos classificadores selecionados no espaço de dissimilaridade é discutida na Seção 4.5 e os critérios de avaliação dos resultados são apresentados na Seção 4.6.

#### 4.2 Extração de características e avaliação dos descritores

Durante esta fase analisou-se os 10 diferentes descritores apresentados na Seção 2.2: SURF, MSER-SURF, SIFT, LPQ, LPQ-TOP,  $LBP^{u2}$ ,  $LBP^{ri}$ ,  $LBP^{riu2}$ , GLCM e filtros de Gabor. Esta avaliação quanto à capacidade de representar as características texturais presentes nas imagens da madeira implicou na variação dos parâmetros utilizados, de acordo com as possibilidades de configuração de cada descritor, e na identificação dos valores que maximizaram as taxas individuais de reconhecimento.

Para todos os experimentos realizados, dada a descrição da Apêndice ??, a fase de pré-processamento das imagens compreendeu apenas a conversão das imagens para níveis de cinza, pois a utilização de corantes inviabilizou a utilização de características referentes à cor. Nestes experimentos foi empregado o classificador Máquina de Vetor de Suporte (Support Vector Machine - SVM) proposto por Vapnik [142] e sua implementação disponibilizada pela biblioteca libSVM [18]. 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  $\gamma$ . A normalização dos dados considerou a escala linear de cada atributo dos vetores de dissimilaridade no intervalo [-1, +1].

Nas seções 4.2.1 à 4.2.7 são identificados os parâmetros avaliados para cada um dos descritores utilizados e os valores para os quais se obteve os melhores resultados. A seção 4.2.8 finaliza as avaliações específicas e individuais para os 10 descritores, com um resumo dos mesmos, suas complexidades algorítmicas e seus custos computacionais.

#### 4.2.1 Família de descritores LBP

Os três descritores da família LBP foram avaliados com oito vizinhos e distâncias um e dois, sendo que os demais parâmetros foram mantidos com os valores padrão das implementações disponibilizadas por Maenpää e Pietikäinen [79] e Ahonen *et al.* [1].

Para a versão  $LBP_{8,2}^{u2}$ , o vetor de características é composto por 59 elementos. As versões invariantes à rotação também tiveram seus descritores padrão utilizados, com 36 e 10 elementos nos vetores de  $LBP_{8,2}^{ri}$  e  $LBP_{8,2}^{riu2}$ , respectivamente.

# 4.2.2 Família de descritores LPQ

LPQ e LPQ-TOP foram avaliados neste trabalho. Os descritores finais utilizados para LPQ foram os vetores com 256 posições retornados pelas implementações e que contêm os histogramas gerados para os códigos binários no intervalo [0, 255]. Já o descritor para LPQ-TOP compreendeu apenas as 256 posições do plano XY, dentre as 756 posições geradas (planos XY, XZ e YZ) e concatenas, visto que as imagens são estáticas.

Para ambos, testou-se diferentes dimensões na janela da STFT e os demais parâmetros foram mantidos com valores padrão das implementações disponibilizadas por Ojansivu e Heikkilä [105] e Päivärinta [106]. Foram avaliadas todas as possibilidades de janelas da STFT com  $N \times N$  pixels, para todos os N ímpares do intervalo [3, 21]. Os valores ímpares para as dimensões da janela da STFT constituem uma exigência do próprio descritor. Já o intervalo [3, 21] permitiu a análise das taxas de reconhecimento e a identificação das dimensões que as maximizaram, além de uma tendência de queda com o aumento do valor de N.

As melhores taxas com LPQ e LPQ-TOP foram obtidas com janelas  $11 \times 11$  e  $15 \times 15$  pixels, respectivamente. Tal diferença justifica-se pelos diferentes valores padrão dos parâmetros utilizados nas implementações disponibilizadas por seus autores. Embora as taxas alcançadas por LPQ e LPQ-TOP tenham ficado bem próximas, testes realizados indicaram pequeno ganho diante da combinação das duas versões.

# 4.2.3 SIFT

Para este descritor foram testadas as implementações de Lowe [75] e Vedaldi [143], seguindo exatamente a mesma metodologia para ambos. Conforme descrito na Seção 2.2.1.3, os vetores de características foram gerados para cada ponto de interesse identificado pelo detector SIFT, cada um com 128 elementos. Diante da variação do número de pontos de interesse identificados para cada imagem, optou-se por utilizar momentos estatísticos para padronizar sua representação. Esta abordagem é comumente utilizada para a extração de características com filtros de Gabor [148, 152, 153].

Foram calculadas média, variância, obliquidade e curtose para cada coluna dos vetores gerados pelo descritor SIFT, dando origem a vetores com dimensões de 128 elementos para cada um dos momentos estatísticos utilizados. A partir dos vetores obtidos para os quatro momentos estatísticos, foram analisadas diferentes combinações de concatenação entre eles e também incluindo o número de pontos de interesse identificados em cada imagem. Tais opções englobaram vetores de características com dimensões entre 128 e 513 elementos, sendo que os melhores resultados foram alcançados pela combinação do número de pontos em cada imagem e do momento média, num total de 129 elementos no vetor final de características.

## 4.2.4 SURF

Dentre outras implementações, para este descritor foram testadas as disponibilizadas pela biblioteca *Open Source Computer Vision Library* (OpenCV) [9], MatLab [89] e pelo próprio Bay [6]. Seguindo exatamente a mesma metodologia para todas elas e, conforme descrito na Seção 2.2.1.4, os vetores de características foram gerados para cada ponto de interesse identificado pelo detector SURF, cada um com 64 ou 128 elementos para as versões original e SURF-128, respectivamente.

Semelhante ao SIFT, devido à variação do número de pontos de interesse identificados para cada imagem (*vide* Tabela 5.6 da Seção 5.1.2), novamente utilizou-se momentos estatísticos para padronizar sua representação. A partir da média, variância, obliquidade e curtose, foram gerados vetores com dimensões de 64 e 128 elementos para cada um dos momentos estatísticos utilizados.

Aqui também foram analisadas diferentes combinações de concatenação dos vetores gerados e do número de pontos de interesse identificados nas imagens. Para a versão original, o número de elementos dos vetores finais ficou entre 64 e 257, enquanto para SURF-128 as dimensões variaram de 128 à 513. As melhores taxas foram alcançadas com a versão SURF-128 da ferramenta Matlab, 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.

# 4.2.5 MSER-SURF

O MSER possui apenas a opção de detecção. Assim, SURF foi utilizado como descritor das regiões identificadas. Como antes, foram utilizadas as versões original e SURF-128, com a mesma metodologia para ambas, e os vetores de características com 64 ou 128 elementos, respectivamente.

Novamente, diante da variação do número de regiões identificadas para cada imagem, optou-se por utilizar momentos estatísticos para padronizar sua representação. Para cada um dos momentos anteriormente citados (média, variância, obliquidade e curtose) foram gerados vetores com dimensões de 64 e 128 elementos, bem como as mesmas combinações da seção anterior. Os melhores resultados foram obtidos com vetores finais com 193 elementos, mediante a combinação do número de regiões detectadas na imagem e dos momentos média, variância e obliquidade. Salienta-se que para a combinação MSER-SURF apenas as implementações disponibilizadas pela ferramenta MatLab [89] foram utilizadas e que a versão original do descritor SURF obteve taxas superiores.

# 4.2.6 GLCM

Conforme apresentado na Seção 2.2.2.2, foram utilizados apenas seis dentre os 14 descritores propostos por Haralick. Tal decisão embasou-se no fato de que a maioria dos trabalhos encontrados na literatura consideram diferentes subconjuntos dos 14 descritores e afirmam haver correlações e/ou redundâncias entre as informações provenientes de alguns deles. Assim, com a combinação de energia, contraste, entropia, homogeneidade, probabilidade máxima e momento de terceira ordem, para as quatro direções, o vetor de características ficou com 24 componentes.

Para GLCM, foram avaliadas distâncias no intervalo [1, 10] pixels para a geração do vetor de características definido anteriormente. Os melhores resultados foram obtidos para a distância d = 6 e os piores para d = 1. Destaca-se aqui o fato de que, em geral, os estudos que empregam imagens macroscópicas têm seus melhores resultados para d = 1, conforme apresentado no Capítulo 3.

## 4.2.7 Filtros de Gabor

Para filtros de Gabor, foram mantidos os valores padrão da implementação de Zhu *et al.* [153], com exceção do número de escalas e orientações. Foram avaliadas as combinações entre escalas no intervalo [1,10] e quatro e oito orientações.

O melhor resultado foi alcançado com oito orientações ( $\mu = [0, 7]$ ) e cinco escalas ( $\nu = [0, 4]$ ). Para cada uma das 40 imagens características de Gabor geradas por esta família de filtros, obteve-se os momentos estatísticos média, variância e obliquidade, chegando a um vetor de características com 120 elementos.

### 4.2.8 Resumo dos descritores utilizados

A Tabela 4.1 apresenta um resumo geral dos 10 descritores empregados, considerando sua complexidade algorítmica, as dimensões dos vetores de características com os quais foram obtidos os melhores resultados e o tempo médio por imagem para sua extração.

A utilização de um conjunto de diferentes bibliotecas e ferramentas, sem ter acesso aos códigos-fonte, impossibilitou a avaliação da complexidade algorítmica de forma detalhada para cada etapa do processo de extração de características definido para cada descritor. Diante disto, a Tabela 4.1 apresenta uma avaliação geral de suas complexidades algorítmicas.

Para se ter uma noção de seus custos, avaliou-se também o tempo médio (por imagem) para a extração dos vetores de características utilizados para cada descritor, isto é, aqueles que geraram as melhores taxas de reconhecimento. Para tal avaliação foi utilizado um equipamento dotado de processador Intel Core i7 (2.2GHz), 8GB (1333MHz DDR3) de memória RAM e sistema operacional Mac OS X em sua versão 10.8.4. Cabe destacar que os tempos são representados em segundos (s) e consideraram apenas as operações de extração, desprezando todas as demais, tais como leitura e escrita.

Descritor	# Características	Tempo (s)	Complexidade Algorítmica
SURF	385	0,38	$O(N \ log_2 \ N)$
MSER-SURF	193	1,66	$O(N \ log_2 \ N)$
SIFT	129	1,57	O(N)
LPQ	256	0,34	$O(N^2 \log_2 N)$
LPQ-TOP	256	0,93	$O(N^2 \log_2 N)$
$LBP_{8,2}^{u2}$	59	0,30	O(N)
$LBP_{8,2}^{ri}$	36	0,33	O(N)
$LBP_{8,2}^{riu2}$	10	0,31	O(N)
GLCM	24	$1,2e^{-4}$	O(N)
GABOR	120	$0,9e^{-4}$	O(N)
Tempo = segund	os por imagem.		

Tabela 4.1: Descritores utilizados, dimensões de seus vetores de características, tempo médio de extração e complexidade algorítmica.

= total de pixels em cada imagem. Ν

#### 4.3Classificação: avaliação dos parâmetros inerentes à representação baseada em vetores de dissimilaridade

Esta seção avalia a influência dos parâmetros empregados na transformação do espaço de características para o espaço de dissimilaridade. Tal avaliação considerou as quantidades de classes, amostras por classe e referências por amostra utilizadas para gerar os vetores de dissimilaridade que compuseram os conjuntos de treinamento e teste, bem como sua influência com relação às taxas de reconhecimento alcançadas pelas diferentes configurações testadas.

Partindo dos resultados apresentados na Seção 4.2, foram selecionados o descritor LPQ<sup>4</sup> e a configuração que produziu as melhores taxas de reconhecimento para este descritor, sendo que as configurações que produziram os melhores resultados foram assumidas para todos os descritores.

Tomando o contexto de dissimilaridade e a independência entre as classes utilizadas durante treinamento e teste, a base de imagens foi dividida em cinco partes, em termos

<sup>&</sup>lt;sup>4</sup>Os descritores baseados em pontos de atenção SURF, MSER-SURF e SIFT ainda não haviam sido testados no momento em que este conjunto de experimentos foi realizado. Assim, LPQ foi escolhido por ser o descritor para o qual o classificador construído apresentava os melhores resultados naquele momento.

de classes (espécies florestais). Diferentes combinações foram testadas para estas cinco partes, com a proporção de 60%-40% para treinamento e teste, respectivamente. Ao final das execuções, todas as cinco partes tiveram o mesmo número de participações nos conjuntos de treinamento e teste, respectivamente. A maior amplitude para o primeiro conjunto do que para o segundo, permitiu uma melhor avaliação da influência do número de classes do conjunto de treinamento com relação às taxas de reconhecimento. Maiores detalhes quanto ao processo de avaliação são apresentados na Seção 4.6.

O primeiro conjunto de testes avaliou a influência das p amostras por espécie florestal e das n referências por amostra. A descrição algorítmica do processo é apresentada no Pseudo-código 4.1. Para a geração do **conjunto de treinamento**, p assumiu todos os valores do intervalo [4, 20]. Para cada variação de p e para cada diferente espécie florestal, as amostras  $s_i$  foram combinadas aos pares e  $\binom{p}{2}$  vetores de dissimilaridade foram gerados para a classe positiva. Ou seja, para cada amostra  $s_i$ , havia um total de n referências (n = p - 1). Para equilibrar os conjuntos de vetores de dissimilaridade positivos e negativos,  $\binom{p}{2}$  vetores também foram gerados para a classe negativa. Para isso, n amostras  $s_i$  e n referências  $r_j$  foram sorteadas e utilizadas para gerar n vetores de dissimilaridade para  $\binom{p}{2}/n$  classes também definidas aleatoriamente. Tal escolha reduziu o elevado custo de treinamento dos modelos decorrente do uso de todas as classes negativas, além de provavelmente eliminar muitas repetições de padrões gerados para as mesmas e que não contribuiriam para com os modelos.

Para a geração do **conjunto de teste**, foram gerados vetores de dissimilaridade entre a amostra questionada  $s_q \in n$  ( $n \in [3, 19]$ ) referências definidas aleatoriamente para cada espécie florestal candidata. Cada um dos modelos de classificação foi testado com todos os 16 conjuntos de teste. Ao final, observou-se que as melhores taxas de reconhecimento foram alcançadas pelos conjuntos de treinamento que utilizaram 12 amostras e 11 referências para cada uma das 68 espécies florestais, num total de 8.976 ( $66 \times 2 \times 68$ ) vetores de dissimilaridade. Combinadas aos pares, as 12 amostras de cada espécie florestal geraram 66 vetores de dissimilaridade positivos, sendo que outros 66 vetores foram gerados para a classe negativa  $Cl_-$ , por meio da combinação de 11 das 12 amostras com outras 11 referências de seis outras espécies escolhidas aleatoriamente. As 19 referências disponíveis foram utilizadas para cada uma das 20 amostras  $s_q$  pertencentes às 44 espécies florestais do conjunto de teste, num total de 735.680 ( $20 \times 19 \times 44 \times 44$ ) vetores de dissimilaridade.

A influência do número de classes utilizadas para o treinamento foi realizada mantendo a configuração identifica nos experimentos anteriores. Assim, diferentes subconjuntos das 68 espécies florestais foram considerados no intervalo [9, 68], enquanto o conjunto de teste foi mantido com as 44 espécies florestais. O Pseudo-código 4.1 pode ser utilizado para representar este processo. A única alteração ocorre na linha 2 (dois) da geração dos conjuntos de vetores de dissimilaridade utilizados para treinamento dos classificadores. Neste ponto, o limite superior do laço 'para' assume diferentes valores no intervalo [9, 68]. Os melhores resultados foram obtidos pelo modelo de classificação inicialmente testado,

#### GeraConjuntosTreinamento

- 1: para p de 4 à 20 passo 1 faça
- 2: para cada espécie florestal  $Cl_i$  de 1 à 68 passo 1 faça
- 3: sorteie p amostras  $s_i, s_i \in Cl_i$
- 4: gere os vetores de dissimilaridade para as  $\binom{p}{2}$  combinações possíveis entre as amostras  $s_i$  para a classe  $Cl_+$
- 5: gere  $\binom{p}{2}$  vetores de dissimilaridade para cada par  $(s_i, r_j), s_i \in Cl_i$  e  $r_j \in Cl_j$ , para a classe  $Cl_-$ , utilizando p-1 amostras  $s_i$  e p-1 referências  $r_j$  de  $\binom{p}{2}/n$  espécies florestais  $Cl_j$  diferentes de  $Cl_i$
- 6: fim-para
- 7: fim-para

#### ${\it GeraConjuntosTeste}$

- 1: para p de 4 à 20 passo 1 faça
- 2: para cada espécie florestal  $Cl_q$  de 1 à 44 passo 1 faça
- 3: sorteie p amostras  $s_q, s_q \in Cl_q$
- 4: para cada espécie florestal  $Cl_j$  de 1 à 44 passo 1 faça
- 5: sorteie p-1 referências  $r_j, r_j \in Cl_j$
- 6: gere os vetores de dissimilaridade para cada par  $(s_q, r_j)$
- 7: fim-para
- 8: fim-para
- 9: fim-para

#### Principal

- 1: GeraConjuntosTreinamento
- 2: GeraConjuntosTeste
- 3: para cada conjunto de treinamento  $C_{TR}$  gerado faça
- 4: construa modelo de classificação  $M_{TR}$
- 5: para cada conjunto de teste  $C_{TS}$  gerado faça
- 6: avalie  $M_{TR}$  em  $C_{TS}$
- 7: fim-para
- 8: fim-para

```
9: selecione configurações para C_{TR} e C_{TS} que maximizaram os resultados
```

o qual utilizou as 68 espécies florestais em sua construção.

Por fim, avaliou-se a robustez dos modelos anteriormente construídos diante do crescimento da base de teste. Para isso, manteve-se os modelos de classificação criados com as configurações que apresentaram os melhores resultados. Exceto pelo número de espécies florestais, que variou no intervalo [9, 44], as configurações utilizadas na criação dos conjuntos de teste também foram mantidas. O Pseudo-código 4.1 pode também ser utilizado para representar este processo. As únicas alterações ocorrem nas linhas 2 (dois) e 4 (quatro) da geração dos conjuntos de vetores de dissimilaridade utilizados na classificação ('Gera-ConjuntosTeste'). Neste ponto, os limites superiores dos laços 'para' assumem diferentes valores no intervalo [9, 44].

Destaca-se que nem todos os valores dos intervalos anteriormente identificados foram considerados na avaliação da influência do número de espécies florestais utilizadas na geração dos vetores de dissimilaridade. Diante das amplitudes dos intervalos, no segundo conjunto de experimentos, nove das 68 espécies florestais foram aleatoriamente escolhidas para treinamento. A partir deste subconjunto de espécies, outros foram gerados pela agregação de três novas espécies, também aleatoriamente definidas, até que as 68 espécies florestais disponíveis fossem contempladas. O mesmo procedimento foi seguido durante a avaliação da robustez dos modelos de classificação com diferentes conjuntos de teste. Assim, iniciou-se com nove espécies florestais, aleatoriamente escolhidas dentre as 44 disponíveis. Como antes, novos subconjuntos foram gerados pela agregação de três novas espécies, também aleatoriamente definidas, até que as 44 espécies florestais fossem contempladas. Tal escolha permitiu a avaliação da influência destes parâmetros e das tendências das taxas de reconhecimento, com a vantagem da redução dos custos computacionais inerentes à avaliação de todos os valores dos intervalos.

#### 4.4 Seleção de Classificadores

Os métodos propostos para seleção dinâmica de classificadores são apresentados nas subseções seguintes. Para a avaliação destes e também daqueles descritos na Seção 2.4.2.1 foi empregado o modelo apresentado na Seção 4.1. Assim, a mesma metodologia foi empregada para todos os métodos testados, exceto é claro pelo próprio método utilizado na etapa de seleção. Maiores detalhes quanto aos critérios de avaliação estão definidos na Seção 4.6.

Destaca-se nesta etapa o uso da representação baseada em vetores de dissimilaridade e a seleção dinâmica dos classificadores neste espaço de representação. Ou seja, enquanto a seleção no espaço de características ocorreria uma única vez para a amostra questionada  $s_q$ , no espaço de dissimilaridade esta ocorre para cada vetor de dissimilaridade  $Z_{q,j}$  criado para  $s_q$  e as referências utilizadas  $r_j$ . Como ilustração, considere a Figura 4.2, com os vetores  $Z_{q,j}$  criados para  $s_q$  e cinco referências  $r_j$  para três espaços de dissimilaridade sintéticos com dimensões x1 e x2 quaisquer. Neste exemplo, cada espaço de dissimilaridade representa um diferente descritor dentre aqueles descritos na Seção 2.2. Conforme ilustrado nas Figuras 4.2(a), 4.2(b) e 4.2(c), espera-se que as distribuições das instâncias  $Z_{q,j}$  nos diferentes espaços de dissimilaridade também sejam diferentes por refletir as teorias em que seus descritores são baseados, as dimensionalidades de seus vetores de características e seus modelos de classificação.

Suponha ainda a minimização da distância Euclidiana entre  $Z_{q,j}$  e a origem do respectivo espaço de representação como critério de seleção. Diante desta situação hipotética, as instâncias  $Z_{q,1}$ ,  $Z_{q,4}$  e  $Z_{q,5}$  seriam classificadas no espaço da Figura 4.2(a). Já  $Z_{q,2}$  e  $Z_{q,3}$  seriam classificadas no espaço da Figura 4.2(b) e não haveria qualquer instância classificada no espaço da Figura 4.2(c). Além disso, devido ao fato de haver apenas um único classificador em cada diferente espaço de representação, a seleção de um espaço específico implica diretamente na seleção do respectivo classificador.

Como a seleção dos classificadores ocorre no espaço de dissimilaridade, tanto a instância questionada  $Z_{q,j}$  quanto os vizinhos do conjunto de validação utilizados no processo de seleção dos classificadores são vetores de dissimilaridade. Assim, é importante não con-



**Figura 4.2:** Situação hipotética para a seleção dinâmica de classificadores baseada na minimização da distância entre a instância questionada  $Z_{q,j}$  e a origem do respectivo espaço de representação sintético com dimensões x1 e x2 quaisquer.

fundir os vizinhos do conjunto de validação utilizados para a seleção dos classificadores, que muitas vezes podem ser vistos e/ou denominados como referências, com as referências utilizadas para a geração dos vetores de dissimilaridade.

Diante da contextualização anterior, as definições de distância utilizadas por Woods et al. [146] e similaridade definidas por Giacinto e Roli [36] tornam-se  $d(Z_{q,j}, Z_{u,v})$  e  $S(Z_{q,j}, Z_{u,v})$ . Como ilustrado na Figura 4.1,  $Z_{u,v}$  representa o vetor de dissimilaridade calculado para as amostras (imagens)  $r_u e r_v$ , ambas do conjunto de validação no espaço de características. Ou seja,  $Z_{u,v}$  representa os vizinhos (referências) do conjunto de validação no espaço de dissimilaridade utilizados na seleção do espaço de representação em que  $Z_{q,j}$ será classificada. Cabe destacar que, embora o modelo e os métodos propostos utilizem a representação baseada em dissimilaridade, os métodos apresentados nesta seção também podem ser aplicados para a seleção dinâmica de classificadores no espaço de características.

Conforme apresentado na Seção 4.3, apenas 12 das 20 imagens existentes para cada espécie florestal foram utilizadas para gerar os vetores de dissimilaridade empregados na construção dos modelos de classificação. Considerando a necessidade de um conjunto de validação no processo de seleção dinâmica de classificadores e buscando uma independência quanto às amostras empregadas na construção dos modelos, foram selecionadas aleatoriamente três das oito amostras restantes por espécie florestal. Diante da existência de 68 espécies florestais na base de treinamento, um total de 408 ( $3\times 2\times 68$ ) vetores de dissimilaridade foram gerados. Para isso, combinou-se as três imagens entre si para obter as instâncias positivas. Para as instâncias negativas, as mesmas três imagens foram combinadas com uma imagem de referência de outras três espécies também selecionadas aleatoriamente. Também foram realizados testes preliminares com cinco e oito imagens para a geração dos vetores de dissimilaridade do conjunto de validação, mas não se identificou diferenças significativas. No entanto, o aumento da quantidade de elementos gerados de 408 para 1.360 ( $10\times 2\times 68$ ) e 3.808 ( $56\times 2\times 68$ ) com cinco e oito imagens, respectivamente, implicou na elevação do custo computacional do processo de seleção.

As seções seguintes apresentam os métodos avaliados para a seleção dinâmica de classificadores, o quais baseiam-se na distribuição das instâncias e nas decisões tomadas para as vizinhanças das amostras questionadas.

# 4.4.1 Métodos de seleção dinâmica de classificadores baseados na distribuição das instâncias no espaço de dissimilaridade

Nesta seção são apresentadas as alternativas avaliadas para a seleção dinâmica de classificadores tomando como base apenas a distribuição das instâncias (vetores de dissimilaridade) no espaço de dissimilidade. A principal motivação para o uso de tal critério concentra-se no fato de que a transformação do espaço de características para o espaço de dissimilaridade tende a gerar conjuntos mais coesos, principalmente para a classe positiva, conforme apresentado na Seção 2.3.1.

Para facilitar a compreensão dos critérios de seleção propostos nas subseções seguintes, são apresentadas ilustrações com apenas três conjuntos sintéticos, isto é, gerados artificialmente. No entanto, todos os processos definidos nestas subseções consideram os 10 espaços de representação utilizados neste trabalho.

# 4.4.1.1 Seleção dinâmica de classificadores baseada na distância entre a instância questionada e os centróides das classes do conjunto de validação

A presente estratégia está embasada nos critérios de proximidade e vizinhança utilizados por diversos métodos de seleção dinâmica de classificadores. Como cada classificador foi construído em um espaço de dissimilaridade *n*-dimensional diferente, busca-se validar a hipótese de que quanto menor a distância entre a instância questionada  $Z_{q,j}$  e o centróide de uma classe candidata  $Cl_l$ , maior é a probabilidade de  $Z_{q,j}$  pertencer a  $Cl_l$  e do classificador prover tal predição. Em outras palavras, supõe-se que  $Z_{q,j}$  deva ser classificada no espaço de dissimilaridade que apresente a menor distância entre  $Z_{q,j}$  e o centróide de  $Cl_l$ . Neste caso, a classe selecionada  $Cl_l$  pode ser qualquer uma das classes (positiva ou negativa) dos conjuntos de validação dos 10 diferentes espaços de dissimilaridade considerados neste estudo.

Para exemplificar graficamente esta estratégia, a Figura 4.3 apresenta três diferentes conjuntos de validação sintéticos no espaço de dissimilaridade bidimensional com dimensões x1 e x2 quaisquer. Como ilustrado, supõe-se que as teorias em que os descritores são baseados e as diferentes dimensionalidades de seus vetores de características gerem distribuições diversas para vetores de dissimilaridade  $Z_{u,v}$ , embora as semelhanças inerentes às classes (positiva e negativa) ainda sejam preservadas e possíveis agrupamentos sejam mantidos em cada espaço de representação. Uma descrição algorítmica desta estratégia é apresentada no Pseudo-código 4.2. A partir dos vetores de dissimilaridade  $Z_{u,v}$  dos conjuntos de validação, identificados por  $(+) e(\cdot)$  nas Figuras 4.3(a), 4.3(b) e 4.3(c), os centróides (vetores médios) C+e C- das classes positiva e negativa, respectivamente, são calculados. Na sequência, calcula-se as distâncias Manhattan entre  $Z_{q,j}$  e os centróides C+e C-, identificadas por  $d_+ e d_-$ . O uso das distâncias Manhattan justifica-se pelas diferentes dimensionalidades dos vetores em cada espaço de representação e desta métrica não influenciar no valor final das distâncias em decorrência da normalização realizada pelo tamanho t do vetor gerado no respectivo espaço. Após realizar tal procedimento para os três conjuntos de validação sintéticos no espaço de dissimilaridade bidimensional, o espaço da Figura 4.3(a) é selecionado e  $Z_{q,j}$  é atribuída à classe positiva representada pelo centróide C+.



**Figura 4.3:** Seleção dinâmica de classificadores baseada na minimização da distância entre a instância questionada  $Z_{q,j}$  e os centróides (C + e C -) das classes positiva e negativa dos conjuntos de validação.

<b>Pseudo-código 4.2.</b> Método min $d(Z_{q,j}, C)$ .				
<b>Detalhes:</b> classificadores abstratos, critério min $d(Z_{q,j}, C)$ .				
<b>Entradas:</b> conjunto de validação, $Z_{q,j}$ e predições de cada classificador $C_k$ para $Z_{q,j}$ .				
Saída: classificador $C_k$ com min $d(Z_{q,j}, C)$ .				
1: para cada classificador $C_k$ faça				
2: calcule os centróides C para as classes $(Cl_+ \in Cl)$ do conjunto de validação				
3: calcule distâncias Manhattan $d(Z_{q,j}, C)$ entre $Z_{q,j}$ e os centróides C				
4: fim-para				
5: selectione $C_k$ com menor valor para $d(Z_{q,j}, C)$ , calculada nos passos 1-4.				
A/V ·				

# 4.4.1.2 Seleção dinâmica de classificadores baseada na distância entre a instância questionada e as fronteiras dos modelos de classificação

Esta estratégia está embasada no fato de que os modelos foram construídos com o classificador SVM, o qual procura maximizar a distância entre as margens do conjunto de treinamento e o hiperplano que define a fronteira f entre as duas classes do problema [25, 142]. Assim, dados os classificadores construídos nos diferentes espaços de dissimilaridade *n*-dimensionais, busca-se validar a hipótese de que cada instância questionada  $Z_{q,j}$ deva ser classificada no espaço que apresente a maior distância entre  $Z_{q,j}$  e f. Ou seja, considera-se que quanto maior a distância d entre  $Z_{q,j}$  e f, maior é a probabilidade do classificador gerar uma predição correta para  $Z_{q,j}$  no respectivo espaço.

Durante a fase de classificação, mediante ajustes no código da ferramenta libSVM [18], obteve-se também a distância d entre a instância questionada  $Z_{q,j}$  e f nos diferentes espaços considerados, sendo desnecessário o uso dos conjuntos de validação. A Equação 4.1 apresenta o cálculo da distância d, com o módulo do 'valor de decisão' dividido pela norma do vetor w, ortogonal ao hiperplano que representa f. O 'valor de decisão' pode ser positivo ou negativo, dependendo do lado do hiperplano em que  $Z_{q,j}$  estiver situada, e representa a medida algébrica da distância entre  $Z_{q,j}$  e f [25].

$$d(Z_{q,j}, f) = \frac{abs(\text{valor de decissão})}{|w|}$$
(4.1)

Para exemplificar graficamente esta estratégia, a Figura 4.4 apresenta três conjuntos sintéticos no espaço de dissimilaridade bidimensional com dimensões x1 e x2 quaisquer. Nas Figuras 4.4(a), 4.4(b) e 4.4(c), os vetores de dissimilaridade  $Z_{u,v}$  são identificados por (+) e ( $\cdot$ ) e representam, respectivamente, os elementos das classes positiva e negativa dos conjuntos de treinamento. Novamente, supõe-se que as teorias em que os descritores são baseados e as diferentes dimensionalidades de seus vetores de características gerem distribuições diversas para  $Z_{u,v}$ , mas ainda mantenham as semelhanças inerentes às classes (positiva e negativa) e seus agrupamentos em cada espaço de representação.

A partir das instâncias  $Z_{u,v}$ , os modelos de classificação são construídos e as fronteiras f são definidas. Tomando-se a ilustração dos três conjuntos sintéticos no espaço de dissimilaridade bidimensional e a maximização de d como critério de seleção, o espaço da Figura 4.4(c) é selecionado e  $Z_{q,j}$  é atribuída à classe predita pelo classificador deste espaço. Uma descrição algorítmica desta estratégia é apresentada no Pseudo-código 4.3.

<b>Pseudo-código 4.3</b> . Método max $d(Z_{q,j}, f)$ .				
<b>Detalhes:</b> classificadores abstratos, critério max $d(Z_{q,j}, f)$ .				
<b>Entradas:</b> predições de cada classificador $C_k$ para $Z_{q,j}$ e distância $d(Z_{q,j}, f)$				
em cada espaço.				
<b>Saída:</b> classificador $C_k$ com max $d(Z_{q,j}, f)$ .				
1: para cada classificador $C_k$ faça				
2: obtenha $d(Z_{q,j}, f)$ calculada durante a classificação de $Z_{q,j}$				
3: fim-para				
4: selectione $C_k$ com major valor para $d(Z_{a,i}, f)$ , obtida nos passos 1-3.				



Figura 4.4: Seleção dinâmica de classificadores baseada na maximização da distância entre a instância questionada  $Z_{q,j}$  e as fronteiras f dos modelos.

# 4.4.1.3 Seleção dinâmica de classificadores baseada na dispersão das referências dos conjuntos de validação

Nesta estratégia busca-se validar a hipótese de que cada instância questionada  $Z_{q,j}$  deva ser classificada no espaço em que os vetores de dissimilaridade  $Z_{u,v}$  obtidos com as referências  $r_u \, e \, r_v \, (r_j, r_u, r_v \in Cl_j)$  apresentem a menor dispersão. Ou seja, considera-se que quanto menor a dispersão maior é a probabilidade de  $Z_{q,j}$  pertencer a  $Cl_j$ , pois a transformação do espaço de características para o espaço de dissimilaridade tende a gerar conjuntos mais coesos, principalmente para a classe positiva, conforme apresentado na Seção 2.3.1. Tal hipótese está embasada nos critérios de proximidade e vizinhança utilizados por diversos métodos de seleção dinâmica de classificadores, sendo avaliada por meio do método proposto por Davies e Bouldin [23] e que recebe o nome de seus autores, *Davies-Bouldin Index* (DBI).

Uma descrição algorítmica desta estratégia é apresentada no Pseudo-código 4.4. Seguindo a descrição da Seção 2.3.1, para cada amostra (imagem) questionada  $s_q$  e para cada classe candidata  $Cl_l$ , obtém-se as n referências  $r_j$  utilizadas na geração dos vetores de dissimilaridade  $Z_{q,j}$ . Para cada uma das  $\binom{n}{2}$  possíveis combinações das referências  $r_j$ , gera-se os vetores de dissimilaridade  $Z_{u,v}$  (u = [1, n] e  $v = [1, n], u \neq v$ ). Na sequência, calcula-se o centróide (vetor médio - C) dos vetores de dissimilaridade  $Z_{u,v}$  e calcula-se o índice de dispersão  $Disp(s_q)$ . A Equação 4.2 apresenta a expressão para o cálculo de  $Disp(s_q)$ , dado pela distância média (Manhattan) entre os elementos  $Z_{u,v}$  e seu centróide C. Para se obter a distância média, utiliza-se o número de vetores de dissimilaridade (n)e seu tamanho (t) para a normalização. O uso das distâncias Manhattan justifica-se pelas diferentes dimensionalidades dos vetores em cada espaço de representação e desta métrica não influenciar no valor final das distâncias em decorrência da normalização realizada com a divisão por t.

$$Disp(s_q) = \frac{1}{n \times t} \sum_{i=1}^{n} \sum_{j=1}^{t} |Z_{u,v}(j) - C(j)|$$
(4.2)

<b>Pseudo-código 4.4.</b> Método min $Disp(s_q)$ .				
<b>Detalhes:</b> classificadores abstratos, critério min $Disp(s_q)$ .				
<b>Entradas:</b> predições de cada classificador $C_k$ para $Z_{q,j}$ e relação de referências				
$r_j$ para $s_q$ em cada espaço.				
Saída: classificador $C_k$ com min $Disp(s_q)$ .				
1: para cada classificador $C_k$ faça				
2: para cada classe candidata $Cl_l$ (no espaço de características) faça				
3: obtenha as referências $r_j$ utilizadas para gerar os vetores $Z_{q,j}$				
4: gere os $\binom{n}{2}$ possíveis vetores $Z_{u,v}$ para as combinações das referências $r_j$				
5: calcule o centróide C dos vetores $Z_{u,v}$				
6: calcule a dispersão $Disp(s_q)$ , (Eq. 4.2)				
7: fim-para				
8: fim-para				
9: selectione $C_k$ com menor valor para $Disp(s_q)$ , calculada nos passos 1-8,				
para todos os vetores $Z_{q,j}$ .				

Para exemplificar graficamente esta estratégia, a Figura 4.5 apresenta três conjuntos sintéticos de instâncias  $Z_{u,v}$  no espaço de dissimilaridade bidimensional com dimensões x1 e x2 quaisquer. As Figuras 4.5(a), 4.5(b) e 4.5(c) apresentam os conjuntos gerados para três diferentes classes candidatas  $Cl_l$  e suas instâncias identificadas por (+). Após calcular a dispersão  $Disp(s_q)$  para as três classes, a classe da Figura 4.5(b) é identificada como vencedora por apresentar a menor dispersão.

Nesta estratégia, a classe selecionada  $Cl_l$  pode ser qualquer uma das 44 classes candidatas existentes em cada um dos 10 diferentes espaços de dissimilaridade considerados neste estudo. Assim, diante da hipótese inicial para esta estratégia, das teorias em que os descritores são baseados, das diferentes dimensionalidades de seus vetores de características e também das distribuições diversas para os vetores de dissimilaridade  $Z_{u,v}$ , as três classes do exemplo podem pertencer a três espaços distintos ou até mesmo ao mesmo espaço de representação. Dado que a medida de dispersão é obtida para todo o conjunto de vetores de dissimilaridade  $Z_{u,v}$  uma única vez, um único classificador é selecionado para todos os n vetores de dissimilaridade  $Z_{q,j}$  gerados para  $s_q$ . Além disso, nesta estratégia também não é necessário utilizar o conjunto de validação.

# 4.4.2 Métodos de seleção dinâmica de classificadores baseados nas decisões para as vizinhanças das instâncias questionadas

A motivação dos métodos propostos nesta seção compreende o potencial quanto ao incremento das taxas de reconhecimento alcançadas por meio da combinação de um conjunto de fatores. O primeiro fator compreende a variação dos resultados obtidos para os métodos propostos por Woods *et al.* [146] com a simples alteração dos critérios OLA e LCA para



**Figura 4.5:** Seleção dinâmica de classificadores baseada na minimização da dispersão das instâncias positivas  $Z_{u,v}$  obtidas para cada classe candidata.

a delimitação da vizinhança da amostra questionada  $s_q$ . Ainda relacionado à vizinhança, outro fator foi identificado por Giacinto e Roli [36] ao definirem o método MCB OLA, os quais afirmam que uma das principais dificuldades ao se trabalhar com vizinhanças consiste na determinação de um valor ideal para seu tamanho e na dependência que todo o sistema terá deste valor. O terceiro fator refere-se ao incremento das taxas de reconhecimento a partir do uso de probabilidades, tal como proposto por Giacinto e Roli [35] nos métodos *a priori* e *a posteriori*, para os critérios OLA e LCA, respectivamente. Por fim, tem-se o fato de que diferentes regras de combinação geram resultados diversos de acordo com as características do problema em questão.

Os métodos aqui propostos consideram as definições das Seções 2.4.2.1 e 4.4 e utilizam a vizinhança de uma amostra questionada  $s_q$  (Figura 4.6) para selecionar o classificador utilizado na predição de sua classe. A definição de tal vizinhança ocorre a partir do índice de similaridade definido por Giacinto e Roli [36] (Figura 4.6(a)), segundo o qual os vizinhos em uma base de validação são ordenados (Figura 4.6(b)) e vizinhanças com diferentes tamanhos podem ser consideradas.

Embora se possa avaliar vizinhanças com diferentes tamanhos, Giacinto e Roli [36] afirmam que, por empregar informações baseadas no índice de similaridade definido para MCB, o tamanho da vizinhança de  $s_q$  é dinamicamente adaptado e não exerce o mesmo nível de influência como ocorre nos demais métodos. Especificamente, o número de vizinhos h é incrementado ou decrementado de acordo com o grau de similaridade entre as assinaturas MCB de  $s_q$  e seus vizinhos  $r_j$ .

Neste trabalho, foram considerados índices de similaridade para os espaços *n*-dimensionais dos 10 classificadores utilizados. Dadas as diferenças em termos de precisão destes classificadores, a quantidade máxima de vizinhos avaliada nos experimentos foi limitada ao número de acertos do classificador com menor taxa de reconhecimento no conjunto de validação, além dos critérios OLA e LCA para a delimitação da vizinhança de  $s_q$ . Além disso, os resultados apresentados na Seção 5.3.2, referentes aos experimentos cuja metodologia é descrita na Seção 4.4.1, demonstraram que as medidas de distância não podem ser utilizadas, direta ou indiretamente, nas comparações entre os diferentes espaços de representação *n*-dimensionais para a seleção dos classificadores, até mesmo quando tais distâncias estejam normalizadas.

Assim, as versões KNORA-E-W e KNORA-U-W propostas por Ko *et al.* [64, 65] e as propostas originais de Giacinto e Roli [36] para os métodos *a priori* e *a posteriori* não foram utilizadas. Isto porque nestas versões, as distâncias são utilizadas como pesos em uma combinação ponderada dos votos dos classificadores e das probabilidades dos vizinhos, respectivamente. Neste ponto, ao se tomar o terceiro e quarto fatores inicialmente identificados, a combinação das decisões dos classificadores ocorreu por meio de oito diferentes regras, tal como apresentado na Seção 4.5.



**Figura 4.6:** Métodos baseados em *local accuracy*: (a) vizinhança da amostra questionada  $s_q$ ; (b) ordenação da vizinhança segundo o critério da distância Euclidiana entre os vizinhos  $r_j$  e  $s_q$ .

O primeiro método de seleção dinâmica de classificadores proposto neste trabalho está baseado no fato de que os métodos que consideram o critério LCA para a delimitação da vizinhança de  $s_q$  geralmente apresentam melhores taxas de reconhecimento quando comparados com aqueles que empregam o critério OLA [35][146]. Assim, este primeiro método proposto mantém todas as definições originais do método MCB OLA, exceto pela troca do critério OLA pelo critério LCA para a delimitação da vizinhança de  $s_q$  durante a seleção do classificador  $C^*$ , no último estágio do método MCB OLA (Seção 2.4.2.1).

Denominado MCB LCA (Pseudo-código 4.5), para este novo método, se  $C_k$  classificar  $s_q$  como pertencente à classe  $Cl_l$ , a vizinhança de  $s_q$  será composta apenas pelas  $h_l$  referências  $r_j$  do conjunto de validação também pertencentes à  $Cl_l$ . A partir disto, durante o processo final do método, ao se tomar as assinaturas  $MCB(r_j)$ , para cada classificador  $C_k$ , contabiliza-se os acertos  $h_{lk}$  para os  $h_l$  vizinhos (referências) mais próximos à  $s_q$  e pertencentes à classe  $Cl_l$ . Por fim, tal como ilustrado na Equação 2.56, o classificador  $C^*$  que apresentar a maior taxa de classificações corretas, dentre todos os classificadores  $C_k$ , é selecionado.

Pseudo-código 4.5. Método MCB LCA.

Detalhes: classificadores abstratos, critério LCA para delimitação da vizinhança.					
<b>Entradas:</b> conjunto de validação, rótulos associados por cada classificador $C_k$ para					
todo o conjunto de validação, tamanho $h$ da vizinhança, rótulo da classe $Cl_l$					
associada por $C_k$ à $s_q$ .					
Saída: classificador $C_k$ que maximiza a taxa de vizinhos corretamente classificados.					
1: crie vetor $MCB(s_i)$ , conforme Eq. 2.61, para cada amostra $s_i$ dos conjuntos					
de teste e validação					
2: ordene os elementos do conjunto de validação considerando sua similaridade					
com $s_q$ (Eq. 2.62), em ordem decrescente					
3: selecione os elementos do conjunto de validação com o índice de similaridade					
maior ou igual ao do $h$ -ésimo elemento					
4: para cada classificador $C_k$ faça					
5: selecione os $h_l$ elementos da vizinhança previamente selecionada no passo 3					
6: conte os $h_{lk}$ vizinhos corretamente classificados por $C_k$ na vizinhança					
previamente selecionada no passo 5					
7: calcule a taxa de vizinhos corretamente classificados por $C_k$ (Eq. 2.56)					
8: fim-para					
9: selecione $C_k$ que maximiza a taxa de vizinhos corretamente classificados					
calculada nos passos 4-8.					

O segundo e o terceiro métodos propostos neste trabalho reúnem os potenciais inerentes aos métodos baseados em MCB, ao uso de probabilidades e também a possibilidade quanto ao emprego de diferentes regras de combinação devido à utilização de classificadores probabilísticos (*vide* Seção 4.5). Tais propostas estão embasadas no fato de que Giacinto e Roli [36] provaram que as acurácias dos métodos *a priori* e *a posteriori* são equivalentes ou superiores às acurácias dos métodos OLA e LCA apresentados por Woods *et al.* [146]. Assim, os critérios OLA e LCA, utilizados pelos métodos MCB OLA e MCB LCA na delimitação da vizinhança de  $s_q$  durante a seleção do classificador  $C^*$ , foram trocados pelos utilizados nos métodos *a priori* e *a posteriori*, respectivamente.

Em decorrência das trocas anteriores, as taxas de acertos (classificadores abstratos) deram lugar aos resultados da combinação das predições corretas de classificadores probabilísticos. Assim, os dois novos métodos são denominados MCB *a priori* (Pseudo-código 4.6) e MCB *a posteriori* (Pseudo-código 4.7), para os quais as vizinhanças são limitadas aos  $h_k$  e  $h_{lk}$  vizinhos do conjunto de validação, respectivamente. Como definido anteriormente,  $h_k$  refere-se à quantidade de vizinhos corretamente classificados por  $C_k$ , bem como  $h_{lk}$  refere-se à quantidade de vizinhos corretamente classificados por  $C_k$  e pertencentes à classe  $Cl_l$ , para a qual  $s_q$  foi predita por  $C_k$  [64, 65, 146].

Neste ponto destaca-se a dinamicidade quanto ao tamanho da vizinhança utilizada por cada classificador  $C_k$ . De forma geral, a vizinhança é limitada aos  $h_k$  e  $h_{lk}$  vizinhos do conjunto de validação decorrentes dos critérios OLA e LCA, respectivamente. Tal vizinhança torna-se ainda mais restrita devido ao emprego do subconjunto de vizinhos determinado pelo índice de similaridade S definido por Giacinto e Roli [36]. Ao se tomar o subconjunto de vizinhos determinado pelo índice de similaridade S, a quantidade final de vizinhos será ainda reduzida de acordo com a taxa de classificações corretas de cada classificador neste subconjunto por serem utilizadas apenas as predições corretas dos

Pseudo-código 4.6. Método MCB a priori.				
<b>Detalhes:</b> classificadores probabilísticos, critério OLA para delimitação da vizinhança				
e restritos somente aos $h_k$ corretamente classificados por cada classificador $C_k$ .				
Entradas: conjunto de validação, probabilidades a posteriori associadas por cada				
classificador $C_k$ para todo o conjunto de validação, tamanho $h$ da vizinhança.				
<b>Saída:</b> classificador $C_k$ que maximiza as probabilidades <i>a posteriori</i> dos $h_k$				
vizinhos mais próximos $r_j$ ponderadas pela distância Euclidiana $d_j$ entre $s_q$ e $r_j$ .				
1: crie vetor $MCB(s_i)$ , conforme Eq. 2.61, para cada amostra $s_i$ dos conjuntos				
de teste e validação				
2: ordene os elementos do conjunto de validação considerando sua similaridade				
com $s_q$ (Eq. 2.62), em ordem decrescente				
3: selecione os elementos do conjunto de validação com o índice de similaridade				
maior ou igual ao do $h$ -ésimo elemento				
4: para cada classificador $C_k$ faça				
5: selecione os $h_k$ elementos corretamente classificados da vizinhança				
previamente selecionada no passo 3				
6: calcule a média ponderada das probabilidades <i>a posteriori</i> (Eq. 2.58) para				
os $h_k$ elementos				
7: fim-para				
8: Selecione $C_k$ que maximiza a média ponderada calculada nos passos 4-7.				

classificadores probabilísticos.

Cabe destacar que, assim como os métodos OLA, LCA, a priori, a posteriori, KNORA-E e KNORA-U, todos os métodos propostos nesta seção podem ser aplicados no espaço de características. No entanto, a abordagem utilizada neste trabalho e também representada no modelo da Figura 4.1 impõem algumas alterações. A partir das definições anteriores, ao se tomar o contexto deste trabalho e o fato da classificação ocorrer no espaço de dissimilaridade, as assinaturas  $MCB(s_i) = \{C_1(s_i), C_2(s_i), ..., C_k(s_i), ..., C_K(s_i)\}$  passam a ser  $MCB(Z_{u,v}) = \{C_1(Z_{u,v}), C_2(Z_{u,v}), ..., C_k(Z_{u,v}), ..., C_K(Z_{u,v})\}$  com as predições  $C_k(Z_{u,v})$ do classificador  $C_k(k = [1, K])$  para cada instância  $Z_{u,v}$  dos conjuntos de Teste  $(Z_{q,j})$ e Validação  $(Z_{u,v})$ . Conforme afirmado no início da Seção 4.4, o índice de similaridade definido por Giacinto e Roli [36] passa de  $S(s_q, r_j)$  para  $S(Z_{q,j}, Z_{u,v})$ , tal como definido nas Equações 4.3 e 4.4.

$$S(Z_{q,j}, Z_{u,v}) = \frac{1}{K} \sum_{k=1}^{K} T_k(Z_{q,j}, Z_{u,v})$$
(4.3)

$$T_k(Z_{q,j}, Z_{u,v}) = \begin{cases} 1, & \text{se } C_k(Z_{q,j}) = C_k(Z_{u,v}) \\ 0, & \text{se } C_k(Z_{q,j}) \neq C_k(Z_{u,v}) \end{cases}$$
(4.4)

# 4.5 Combinação de Classificadores

As regras para combinação de classificadores apresentadas na Seção 2.4.1 foram empregadas nas etapas de Seleção e Fusão (Figura 4.1). Em ambas, os elementos considerados constituem os vetores de dissimilaridade  $Z_{q,j}$  gerados para  $s_q$  e não a própria  $s_q$ . Na etapa de **seleção** de classificadores, cada um dos métodos utiliza diferentes subconjuntos das

$\mathbf{Ps}$	eudo-código 4.7. Método MCB a posteriori.
De	talhes: classificadores probabilísticos, critério LCA para delimitação da vizinhança
e	restritos somente aos $h_{lk}$ corretamente classificados por cada classificador $C_k$ .
$\mathbf{En}$	tradas: conjunto de validação, probabilidades a posteriori associadas por cada
c	lassificador $C_k$ para todo o conjunto de validação, tamanho h da vizinhança,
r	ótulo da classe $Cl_l$ associada por $C_k$ à $s_q$ .
Sai	ida: classificador $C_k$ que maximiza as probabilidades a posteriori dos $h_{lk}$
v	izinhos mais próximos $r_j$ ponderadas pela distância Euclidiana $d_j$ entre $s_q \in r_j$ .
1:	crie vetor $MCB(s_i)$ , conforme Eq. 2.61, para cada amostra $s_i$ dos conjuntos
	de teste e validação
2:	ordene os elementos do conjunto de validação considerando sua similaridade
	$\operatorname{com} s_q$ (Eq. 2.62), em ordem decrescente
3:	selecione os elementos do conjunto de validação com o índice de similaridade
	maior ou igual ao do $h$ -ésimo elemento
4:	para cada classificador $C_k$ faça
5:	selecione os $h_{lk}$ elementos corretamente classificados da vizinhança
	previamente selecionada no passo 3
6:	calcule a média ponderada das probabilidades a posteriori (Eq. 2.60) para
	os $h_{lk}$ elementos
7:	fim-para
8:	Selecione $C_k$ que maximiza a média ponderada calculada nos passos 4-7.

regras de combinação apresentadas. Woods *et al.* [146] (OLA e LCA), Giacinto e Roli [36] (MCB OLA) e também o método proposto MCB LCA consideram apenas a contagem de acertos, num processo de seleção baseado em kNN ou voto majoritário. Ko *et al.* [64, 65] utilizam o mesmo critério para a seleção de subconjuntos de classificadores para os métodos KNORA-E e KNORA-U, bem como votos ponderados pela distância entre a amostra questionada e seus vizinhos para os métodos KNORA-E-W e KNORA-U-W. Giacinto e Roli [35] (*a priori* e *a posteriori*), assim como os métodos propostos MCB *a priori* e MCB *a posteriori*, utilizam apenas a probabilidade média, ou a mesma probabilidade com média ponderada pela distância entre a amostra questionada e seus vizinhos, para selecionar  $C^*$ .

Considerando que as diversas abordagens testadas com critérios de seleção baseados em medidas de distância (vide Seção 4.4.1) não obtiveram sucesso (vide Seção 5.3.2), concluiu-se que não é possível aplicar a probabilidade média ponderada nem os votos ponderados. Dado que diferentes regras de combinação, tais como as apresentadas por Jain et al. [56] e Kittler et al. [62] (vide Seção 2.4.1), produzem resultados diversos dependendo das características do problema em questão, para todos os métodos que utilizaram classificadores probabilísticos foi empregado um conjunto de regras de combinação mais amplo e composto por: voto majoritário, borda count, soma, média, produto, máximo, mínimo e mediana [8, 48, 56, 62]. O método KNORA constitui uma exceção nesta etapa. Para este método, inicialmente realizou-se a contagem dos acertos dos classificadores na vizinhança de  $Z_{q,j}$ . Posteriormente, para os casos com mais de um classificador selecionado, as decisões individuais foram combinadas por meio das regras anteriormente mencionadas.

Na etapa de **fusão**, as decisões parciais  $D(Z_{q,j})$  são combinadas para obter a decisão

final  $D(s_q)$  para  $s_q$ . Tal combinação é consequência da transformação do espaço de características para o espaço de dissimilaridade, sendo necessária para retornar ao espaço de características e obter as taxas de reconhecimento, tal como descrito nas Seções 2.3.1 e 4.1. Ao final do processo, a classe candidata  $Cl_l$  (no espaço de características) que maximizar as probabilidades para a classe positiva  $Cl_+$  será definida como a classe predita  $Cl_p$ . Ou seja, neste processo de combinação são consideradas apenas as probabilidades para a classe  $Cl_+$ , enquanto que a classe  $Cl_-$  é ignorada.

Destaca-se que, tanto na etapa de seleção quanto na etapa de fusão, os métodos de seleção dinâmica de classificadores que consideraram as probabilidades dos vizinhos corretamente classificados e o método KNORA (durante a combinação dos classificadores selecionados) utilizaram a mesma regra de combinação.

Para analisar a efetividade dos métodos de seleção dinâmica de classificadores, testes com a combinação de agrupamentos de classificadores também realizados. Nesta avaliação foram testadas todas as possíveis combinações dos 10 classificadores, o que eliminou o estágio de seleção do modelo apresentado no início deste capítulo. Ou seja, o mesmo subconjunto de classificadores foi mantido para todos os vetores  $Z_{q,j}$ .

#### 4.6 Avaliação de Resultados

Para garantir que a escolha das imagens usadas nos conjuntos de treinamento, validação e teste não influenciassem as taxas de reconhecimento, cada experimento foi realizado cinco vezes com diferentes composições para os referidos conjuntos, conforme configurações apresentadas nas Seções 4.3 e 4.4.

Os indicadores utilizados foram obtidos a partir de matrizes de confusão e curvas ROC, sendo expressos por meio de taxas médias de reconhecimento (Equação 2.44) e desvio padrão para avaliar a dispersão entre os resultados de cada execução. Por não ter sido especificado um ponto de operação, todas as classificações consideraram a definição da Equação 2.45.

Durante as avaliações dos resultados, considerou-se as afirmações de Barker [4] quanto à possibilidade de se realizar a avaliação nos diferentes níveis definidos pela Botânica. Para este autor, mesmo especialistas com o domínio dos conhecimentos inerentes à Anatomia da Madeira podem encontrar grande complexidade para realizar a classificação em nível de espécies, principalmente ao se considerar espécies com características intermediárias.

Conforme discutido na Seção 2.1.2, tal situação decorre do fato de que os níveis superiores da hierarquia agrupam elementos dos níveis inferiores com características comuns. Assim, à medida em que se move dos níveis inferiores para os superiores (espécies para filos), o número de classes em cada nível diminui. De modo semelhante é esperado que também diminuam as diferenças internas às classes e aumentem as externas, implicando numa possível elevação das taxas de reconhecimento nos níveis superiores da hierarquia.

As avaliações dos resultados ocorreram nos diferentes níveis e para os diferentes agru-

pamentos em cada um deles. Cabe ressaltar que, os níveis apresentados na Seção 2.1.2 foram definidos para manter uma estrutura única de classificação para todos os elementos existentes na natureza. Alguns deles não contribuem para a diferenciação de certos subconjuntos de elementos, ou o fazem de forma muito restrita, conforme ilustrado nas tabelas do Apêndice A. Consequentemente, os níveis filo, família, gênero e espécie foram utilizados em razão de suas contribuições para a classificação das espécies florestais produtoras de madeira, conforme estratégias descritas nas subseções seguintes.

Os modelos construídos neste trabalho diferenciam as classes positiva e negativa no espaço de dissimilaridade. Entretanto, todos os resultados apresentados consideram a decisão final do sistema representado na Figura 4.1 que se encontra no espaço de características. Assim, o número de classes 'reais' nos níveis filo, família, gênero e espécie são 2, 30, 85 e 112, respectivamente.

# 4.6.1 Avaliação das taxas de reconhecimento nos diferentes níveis definidos pela Botânica

Esta estratégia considerou o fato de que, dependendo da finalidade para a qual a madeira é empregada, não há necessidade de certificação em nível de espécie florestal. Assim, erros de classificação internos a um agrupamento poderiam ser admitidos como acertos, pois em muitos casos tais confusões não prejudicam as partes envolvidas na negociação e/ou as características necessárias ao produto final. Seguindo tal raciocínio e considerando a relação de espécies das tabelas do Apêndice A, para o gênero *Eucalyptus*, erros de classificação entre classes reais e classes preditas que envolvam as espécies *Eucalyptus globulus*, *Eucalyptus grandis* e *Eucalyptus saligna* poderiam ser contabilizados como acertos.

Nesta estratégia, inicialmente considerou-se a classificação no nível de Espécies Florestais. Neste nível, a base de imagens utilizada compreende um total de 112 classes 'reais'. A partir das matrizes de confusão para as 112 espécies florestais, seguindo os agrupamentos ilustrados na Figura 4.7, gerou-se diferentes matrizes de confusão. Tais matrizes de confusão permitiram a apuração dos resultados nos níveis espécie (112×112), gênero ( $85 \times 85$ ), família ( $30 \times 30$ ) e filo ( $2 \times 2$ ).

# 4.6.2 Uso de meta-classes para a abordagem de classificação hierárquica

Neste conjunto de experimentos, optou-se pelos descritores SURF, SIFT e LPQ devido a seus expressivos resultados quando comparados aos demais (*vide* Seção 5.1). Todos os modelos mencionados nesta seção foram criados para as melhores configurações identificadas anteriormente nas Seções 4.2 e 4.3. Ao final, os resultados destas avaliações foram generalizados para os demais descritores.

Esta estratégia focou o uso de subconjuntos menores de características necessários



**Figura 4.7:** Identificação dos agrupamentos (espaços em branco) realizados nas matrizes de confusão durante o deslocamento entre os níveis (a) espécie ( $112 \times 112$ ), (b) gênero ( $85 \times 85$ ), (c) família ( $30 \times 30$ ) e (d) filo ( $2 \times 2$ ).

para alcançar a classificação no nível desejado [27]. Dentre suas vantagens, destaca-se a redução da sobrecarga acarretada pelo uso de informações desnecessárias nos níveis inferiores da hierarquia [27, 49, 55, 140]. Neste sentido, Barker [4] declara que a distinção entre Dicotiledôneas e Gimnospermas é um dos requisitos elementares para a identificação de madeira. O autor ainda complementa com a afirmação de que, de forma geral, tal distinção ocorre facilmente devido às diferenças existentes entre as estruturas especializadas das primeiras (inexistentes em Gimnospermas) e da organização com sobreposição de linhas de células nos Gimnospermas. Seguindo tal linha de raciocínio, o primeiro conjunto de avaliações ocorreu para o nível filo. Diferentes espécies florestais, proporcionalmente distribuídas entre os filos Angiospermas e Gimnospermas, compuseram os conjuntos de treinamento e teste. Especificamente neste caso, houveram duas classes tanto no espaço de dissimilaridade quanto no espaço de características.

Na sequência, outros dois modelos independentes foram construídos. As mesmas espécies florestais que compunham os conjuntos de treinamento e teste do experimento anterior foram mantidas. Porém, tais espécies foram redivididas de acordo com o filo a que pertenciam. Ou seja, do conjunto de treinamento derivou-se dois subconjuntos de treinamento, um para Angiospermas e outro para Gimnospermas. O mesmo ocorreu para o conjunto de teste.

Nas duas avaliações anteriores, seguiu-se o mesmo processo definido pela Figura 4.1. A avaliação das taxas de reconhecimento para os experimentos desta seção considerou apenas os rótulos das classes preditas, isto é, utilizou-se classificadores abstratos. Assim, os acertos foram contabilizados apenas quando os classificadores de ambos os níveis (filo e espécie) realizavam as predições corretamente. A partir dos resultados obtidos, esta estratégia não apresentou contribuições significativas quando comparada com a da seção anterior, não tendo havido outras tentativas para os níveis gênero e família.

### 4.7 Considerações Finais

Este capítulo definiu as etapas e as atividades executadas no desenvolvimento deste trabalho. Também foram apresentados o modelo de classificação proposto, com ênfase na extração de características, na representação no espaço de dissimilaridade e nas estratégias de classificação, seleção e combinação de classificadores.

Também foram apresentados três novos métodos para seleção dinâmica de classificadores, os quais foram aplicados ao problema de identificação de espécies florestais e alcançaram resultados superiores às outras pré-existentes, tal como apresentado no capítulo seguinte.

# CAPÍTULO 5

# RESULTADOS

Este capítulo apresenta os resultados obtidos ao final dos experimentos descritos no capítulo anterior. Inicialmente discute-se os melhores resultados individuais dos classificadores construídos com as configurações previamente identificadas. Na sequência, apresenta-se as avaliações do número de espécies florestais, amostras por espécie e referências por amostra utilizados para a geração dos vetores de dissimilaridade.

Para a seleção dinâmica de classificadores, os métodos apresentados nos Capítulos 2 e 4 foram considerados. Segue-se com uma breve discussão quanto às diferentes regras de fusão utilizadas neste trabalho, destacando-se a superioridade das taxas de reconhecimento alcançadas com a aplicação da regra máximo. Por fim, tem-se as taxas de reconhecimento alcançadas para os níveis espécie, gênero, família e filo, definidos pela Botânica, e as considerações finais do capítulo.

### 5.1 Avaliações dos descritores: melhores resultados individuais

A Tabela 5.1 apresenta um resumo com os melhores resultados alcançados pelos classificadores construídos a partir dos descritores apresentados na Seção 4.2. Além das taxas médias individuais de acerto, desvio padrão e AUC, são apresentados os valores para o Oráculo Acumulado médio e seu desvio padrão. O 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 [63]. Para o cálculo do Oráculo Acumulado, iniciouse com o SURF e seguiu-se agregando cada um dos demais classificadores, ordenados por suas taxas de reconhecimento.

Classificador	Taxa Individual			Oráculo	Oráculo Acumulado		
	%	$\sigma$	AUC	%	σ		
SURF	89,14	2,39	$85,\!17$	89,14	2,39		
MSER-SURF	87,80	$2,\!17$	$82,\!15$	95,77	1,33		
SIFT	$88,\!47$	$1,\!64$	$85,\!44$	$97,\!98$	0,83		
LPQ	86,74	2,07	$80,\!39$	$98,\!84$	0,52		
LPQ-TOP	$86,\!41$	$1,\!36$	80,51	$99,\!13$	0,36		
$LBP_{8,2}^{u2}$	$66,\!25$	$4,\!67$	$64,\!15$	99,29	0,32		
$LBP_{8,2}^{ri}$	50,74	$9,\!54$	$49,\!94$	$99,\!43$	0,32		
GABOR	$25,\!67$	2,53	30,05	99,52	0,27		
$LBP_{8,2}^{riu2}$	$16,\!49$	$17,\!57$	17,70	99,52	0,32		
GLCM	4,09	$1,\!13$	5,26	$99,\!54$	0,28		

Tabela 5.1: Resultados individuais dos classificadores e oráculo acumulado.

A partir das taxas apresentadas na Tabela 5.1, as medidas de desempenho (taxas

médias de reconhecimento e AUC<sup>1</sup>) definem claramente a formação de três agrupamentos distintos. Basicamente, o conjunto formado pelos cinco primeiros classificadores quase permite que se alcance o valor máximo para o 'Oráculo Acumulado'. O grupo intermediário é formado apenas por LBP<sup>u2</sup><sub>8,2</sub> e LBP<sup>ri</sup><sub>8,2</sub>, já apresentando taxas inferiores em mais de 20 pontos percentuais. Embora as diferenças sejam bastante elevadas, principalmente quando se considera o último grupo formado pelos classificadores filtros de Gabor, LBP<sup>riu2</sup> e GLCM, a contribuição de todo o conjunto para com os métodos propostos será demonstrada na Seção 5.3.3.6.

Dada a amplitude de configurações avaliadas para cada um dos 10 descritores, destacase aqui as variações das taxas de reconhecimento alcançadas pelos respectivos classificadores construídos. Para a família LBP, houve vantagem para distância dois, com diferenças de 2,78 pontos percentuais para  $LBP_{8,2}^{u2}$ , 6,1 para  $LBP_{8,2}^{ri}$  e 1,84 para  $LBP_{8,2}^{riu2}$ . Já para LPQ e LPQ-TOP as taxas de reconhecimento apresentaram diferenças de 7,92 e 7,82 pontos percentuais entre o melhor e o pior resultado, respectivamente.

Embora a mesma configuração tenha gerado os melhores resultados nas implementações do descritor SIFT disponibilizadas por Lowe [75] e Vedaldi [143], a segunda implementação garantiu resultados superiores, com 5,25 pontos percentuais de diferença. Para SURF, apenas para a implementação OpenCV as melhores taxas foram obtidas por uma combinação diferente das demais. Contudo, a variação máxima entre as taxas de reconhecimento alcançadas pelas diferentes implementações testadas ficou em 1,51 pontos percentuais.

Apenas as implementações disponibilizadas pela ferramenta MatLab [89] foram utilizadas para a combinação MSER-SURF. Destas, a versão original do descritor SURF obteve taxas de reconhecimento superiores, com diferença de 0,84 pontos percentuais. Para GLCM, os melhores resultados foram obtidos para a distância d = 6 e os piores para d = 1, tendo havido variação de 1,46 pontos percentuais entre o melhor e o pior caso. Destaca-se aqui o fato de que os estudos que empregam imagens macroscópicas têm seus melhores resultados para d = 1. Por fim, filtros de Gabor apresentou uma variação de 0,39 pontos percentuais entre as melhores e as piores taxas.

Na seção 5.1.1 avalia-se a capacidade de (manutenção da) representação das características texturais considerando diferentes dimensões para recortes das imagens originais e dos cantos escuros das imagens. Também realizou-se um estudo quanto à efetividade dos detectores baseados em pontos de atenção, o qual é apresentado na Seção 5.1.2.

<sup>&</sup>lt;sup>1</sup>Neste trabalho, as predições das cinco execuções foram reunidas e as curvas ROC e os valores para AUC foram obtidos uma única vez para todas as rodadas, tal como descrito por Fawcett [31]. Tais valores são expressos no intervalo [0, 100].

# 5.1.1 Avaliação da influência dos cantos escuros das imagens nas taxas de reconhecimento

Após a aquisição das imagens utilizando o microscópio Olympus modelo CX40 (Figura 5.1(a)), visualmente percebeu-se algumas influências da iluminação e do formato das lentes. Estes fatores podem ser melhor percebidos em algumas espécies e geraram um escurecimento nas extremidades (principalmente nos cantos) das imagens, tal como ilustra a Figura 5.1(b). Assim, avaliou-se uma possível influência destes fatores nas taxas de reconhecimento. Para isso, utilizou-se o descritor LPQ<sup>2</sup> e sua configuração que alcançou os melhores resultados (Seção 4.2.2). A partir da imagem da Figura 5.1(b), quatro novos experimentos foram realizados seguindo exatamente a mesma metodologia anterior, exceto pelas dimensões da imagens utilizadas. Para cada experimento, foram eliminadas faixas das bordas das imagens (Figura 5.1(c)), gerando novas imagens com as dimensões apresentadas na Tabela 5.2.



**Figura 5.1:** Avaliação da influência dos cantos escuros: (a) microscópio Olympus modelo CX40, (b) imagem original e (c) imagem em escala de cinza com a identificação dos recortes utilizados.

**Tabela 5.2:** Dimensões das faixas excluídas das imagens originais e dimensões das imagens finais (em pixels) ilustradas na Figura 5.1(c).

Largura da Faixa	Dimensões das Imagens
0	$1.024 \times 768$ (original)
50	$974 \times 718$
100	$924 \times 668$
150	$874 \times 618$
200	$824 \times 568$

A Tabela 5.3 apresenta as taxas de reconhecimento obtidas nestes experimentos. Foram identificadas diferenças de apenas 1,04 e 3,01 pontos percentuais nas taxas com a exclusão de faixas com 50 e 100 pixels, respectivamente, o que representa 11,08% e

<sup>&</sup>lt;sup>2</sup>Os descritores baseados em pontos de atenção SURF, MSER-SURF e SIFT ainda não haviam sido testados no momento em que este conjunto de experimentos foi realizado. Assim, LPQ foi escolhido por ser o descritor para o qual o classificador construído apresentava os melhores resultados naquele momento.

21,51% das imagens originais. Embora os recortes mencionados tenham sido substanciais com relação às dimensões da imagem original, a variação dos resultados foi relativamente pequena.

Ao se considerar a quarta e a quinta linhas da Tabela 5.3, verifica-se diferenças de mais de 10 e 20 pontos percentuais, respectivamente. No entanto, as faixas excluídas nestes casos representam 31,32% e 40,49% das imagens originais.

**Tabela 5.3:** Taxas de reconhecimento obtidas para os diferentes recortes das imagens originais com o descritor LPQ.

Largura da Faixa	Dimensões das Imagens	%	$\sigma$	AUC
0	$1024 \times 768$	$86,\!94$	$2,\!17$	$80,\!39$
50	$974 \times 718$	$85,\!90$	$2,\!60$	$83,\!11$
100	$924 \times 668$	$83,\!93$	2,07	$79,\!69$
150	$874 \times 618$	76, 32	2,94	72,93
200	$824 \times 568$	$63,\!50$	$3,\!19$	$62,\!41$

# 5.1.2 Avaliação quanto ao uso de pontos fixos para os descritores baseados em pontos de atenção

Os algoritmos baseados em pontos de atenção dividem o processo em duas etapas, isto é, detecção de pontos e extração das características para os pontos detectados. Diante disto, avaliou-se a efetividade do algoritmo de detecção SURF e a significância dos pontos por ele identificados.

Os experimentos para os descritores SURF e SURF-128 foram repetidos considerando a implementação disponibilizada pela ferramenta MatLab [89]. Em cada repetição, empregou-se um conjunto diferente de pontos fixos para todas as imagens, o qual variou entre 1.000 e 20.000 pontos por imagem. Para cada conjunto, inicialmente definiu-se o espaçamento entre os pontos a serem utilizados. Para isso, o número total de pixels das imagens ( $1024 \times 768 = 786.432$ ) foi dividido pelo número de pontos existentes no conjunto. Partindo da coordenada (1,1) das imagens e seguindo com o incremento do espaçamento previamente definido, os pontos foram identificados e as características foram extraídas.

Da mesma forma que no experimento original (Seção 4.2.4), utilizou-se os momentos estatísticos média, variância, obliquidade e curtose, tendo sido gerados vetores com dimensões de 64 ou 128 elementos para cada um deles. Também aqui, as diferentes combinações entre tais vetores foram testadas, com os descritores finais variando de 64 à 256 elementos para SURF e de 128 à 512 para SURF-128. Por ter sido considerado o mesmo conjunto de pontos para todas as imagens, a quantidade de pontos detectados nas imagens (que compunha os vetores de características nos experimentos originais) foi descartada nestes experimentos.

As melhores taxas foram obtidas para o conjunto de 15.000 pontos, tanto para a versão padrão quanto para SURF-128, mais uma vez com vantagens para a segunda. A Tabela 5.4
apresenta as taxas de reconhecimento alcançadas pela versão SURF-128. Estas são 0,42 pontos percentuais superiores às apresentadas na Tabela 5.1, quando foi utilizado SURF para a detecção dos pontos de interesse e também para a extração de suas características. Mesmo com esta pequena diferença, avaliou-se a combinação dos resultados de ambas as abordagens (Tabela 5.5) e também foi identificado um ganho de 1,38 pontos percentuais com relação às taxas apresentadas na Tabela 5.1.

**Tabela 5.4:** Resultados obtidos para o conjunto de 15.000 pontos fixos igualmente distribuídos pelas imagens com o descritor SURF-128.

Regra de combinação	%	$\sigma$	AUC
Média	$73,\!88$	$_{3,25}$	$70,\!65$
Máximo	$89,\!56$	1,03	$86,\!28$

**Tabela 5.5:** Resultados da combinação das abordagens avaliadas para SURF cujos resultados foram apresentadas nas Tabelas 5.1 e 5.4.

Regra de combinação	%	$\sigma$	AUC
Média	82,88	2,32	77,74
Máximo	$90,\!52$	$1,\!24$	$87,\!97$

Mesmo com as diferenças e complementaridades encontradas, foi necessário empregar 15.000 pontos para obter taxas de reconhecimento próximas àquelas alcançadas ao se usar SURF como detector e descritor dos pontos de interesse. Como apresentado na Tabela 5.6, este número caracteriza quase que o dobro do número máximo de pontos identificados ao se utilizar SURF como detector. Tal fato conduziu à avaliação dos custos inerentes a ambos os processos.

**Tabela 5.6:** Estatísticas referentes ao número de pontos detectados pela implementação do algoritmo SURF disponibilizada pela ferramenta MatLab [89].

# Pontos	s
Máximo	8.893
Mínimo	990
Média	4.805
Desvio Padrão	1.345
Mediana	4.796
Moda	5.143

Embora tenha-se eliminado a etapa de detecção de pontos de interesse nestes experimentos, a extração de características pode incorrer em um custo mais elevado pela necessidade de se utilizar mais pontos por imagem do que a média identificada pelo próprio SURF. Assim, seguindo as definições anteriores e as da Seção 4.2.8, o custo médio apenas para a extração das características dos 15.000 pontos foi de 0,48 segundos por imagem, num total de 1.075 segundos para as 2.240 imagens. Pela Tabela 4.1, ao se utilizar SURF como detector e descritor, o custo total dos passos de detecção e extração de características foi inferior, com 0,38 segundos por imagem, num total de 851 segundos para as 2.240 imagens. Os valores apresentados no parágrafo anterior confirmaram a efetividade do SURF em termos de detecção de pontos de interesse. Ao mesmo tempo, ficou claro que o emprego dos conjuntos de pontos fixos leva à necessidade de um número de pontos por imagem muito maior do que a média identificada pelo próprio SURF. Portanto, é plausível concluir pela inviabilidade de se empregar os conjuntos de pontos fixos devido a seu maior custo, mesmo utilizando apenas a funcionalidade de extração de características do descritor SURF.

## 5.2 Classificação: avaliação dos parâmetros inerentes à representação baseada em vetores de dissimilaridade

Conforme descrito na Seção 4.3, nestes experimentos a base de imagens foi dividida em dois subconjuntos com, respectivamente, 68 e 44 espécies florestais para treinamento e teste. Após as cinco execuções, a avaliação de diferentes quantidades de amostras por espécie e referências por amostra utilizadas na geração dos vetores de dissimilaridade para os conjuntos de treinamento e teste identificou as taxas médias de reconhecimento da Tabela 5.7 como sendo as melhores. Tais taxas foram alcançadas com 12 amostras por espécie e 11 referências por amostra para gerar o conjunto de treinamento, além de 20 amostras por espécie com 19 referências cada uma para gerar o conjunto de teste. Uma avaliação geral de tal influência pode ser realizada por meio da Figura 5.2, na qual se tem variação das taxas médias alcançadas com os modelos de classificação construídos com 12 amostras por espécie e 11 referências por amostra com relação às diferentes configurações utilizadas para a geração dos conjuntos de teste. Basicamente, tal comportamento também foi identificado para os demais modelos construídos com diferentes quantidades de amostras e referências (Seção 4.3), mas com taxas médias de reconhecimento inferiores às apresentadas.

 Tabela 5.7: Melhores taxas de reconhecimento obtidas para as variações dos experimentos desta seção.

Regra de combinação	%	$\sigma$	AUC
Média	$63,\!83$	2,34	59,24
Máximo	$86,\!74$	2,07	80,39

A partir dos resultados anteriores, a avaliação da influência do número de espécies empregadas para gerar o conjunto de treinamento (Figura 5.3) identificou a necessidade de empregar basicamente todas as classes disponíveis para maximizar as taxas de reconhecimento. Tais resultados confirmam aqueles apresentados na Tabela 5.7 como sendo os melhores. Além disso, pela Figura 5.3, também se percebe que o aumento do número de classes utilizadas para gerar o conjunto de treinamento conduz à redução do valor do desvio padrão.

Durante a avaliação da robustez dos modelos (Figura 5.4), ao se partir do conjunto



**Figura 5.2:** Avaliação da influência do número de amostras por espécie florestal e referências por amostra nas taxas de reconhecimento.



Figura 5.3: Avaliação da influência do número de espécies florestais do conjunto de treinamento nas taxas de reconhecimento.

original de teste com 44 espécies florestais para subconjuntos com apenas nove delas, as taxas de reconhecimento são elevadas de 86,74% ( $\sigma = 2,07$ ) para 95,44% ( $\sigma = 1,47$ ). Tais diferenças eram esperadas em decorrência da variação do número de espécies, embora relatos de trabalhos com dissimilaridade mostrem que estas diferenças são minimizadas à medida que o número de classes do conjunto de testes assume valores na casa das centenas.

Devido à limitação das espécies florestais disponíveis, não foi possível avaliar tal tendência. Contudo, os valores do desvio padrão se mantêm relativamente estáveis no intervalo  $\sigma = [1, 47..3, 14]$ , similares à maior parte dos classificadores apresentados na Tabela 5.1.



**Figura 5.4:** Avaliação da influência do número de espécies florestais candidatas do conjunto de teste nas taxas de reconhecimento.

## 5.3 Seleção e Combinação de Classificadores

Para facilitar a compreensão dos experimentos realizados envolvendo os sistemas formados por múltiplos classificadores, os estágios de seleção e combinação de classificadores foram agrupados nesta seção. Assim, nas subseções seguintes são apresentados os resultados obtidos com a combinação de diferentes subconjuntos dos 10 classificadores utilizados neste trabalho e pelas técnicas de seleção dinâmica de classificadores descritas nas Seções 2.4.2 e 4.4. Inserida no contexto dos métodos de seleção dinâmica de classificadores, a Seção 5.3.4 apresenta uma discussão quanto à influência das diferentes regras de fusão empregadas no decorrer deste trabalho para a combinação das decisões individuais dos classificadores selecionados para os vetores de dissimilaridade.

#### 5.3.1 Combinação de agrupamentos de classificadores

Estes experimentos consideraram todas as possíveis combinações entre os 10 classificadores avaliados por meio das regras voto majoritário, *borda count*, soma, média, produto, máximo, mínimo e mediana. Os melhores resultados alcançados para os agrupamentos com k (k = 1..10) classificadores são apresentados na Tabela 5.8. Embora tenham sido avaliadas oito diferentes regras de combinação, todos os resultados apresentados foram obtidos com a regra Máximo.

Diante da amplitude da avaliação realizada, verificou-se uma maior influência dos classificadores que obtiveram as melhores taxas de reconhecimento. Exceto por filtros de Gabor, todas as demais inclusões nos conjuntos de classificadores da Tabela 5.8 seguiram a sequência apresentada na Tabela 5.1.

Conforme afirmado na discussão dos dados da Tabela 5.1, os cinco melhores classi-

	0					
Agrupamento	%	$\sigma$		AUC		
(a)	89,14	2,39		$85,\!17$		
(b)	$90,\!10$	$1,\!65$		$87,\!26$		
(c)	$90,\!51$	$2,\!38$		$86,\!83$		
(d)	$90,\!57$	2,26		$86,\!56$		
(e)	$90,\!71$	$2,\!45$		$86,\!62$		
(f)	$90,\!66$	$2,\!44$		$86,\!62$		
$(\mathbf{g})$	$90,\!61$	$2,\!33$		$86,\!60$		
(h)	$90,\!48$	$2,\!34$		$86,\!58$		
(i)	$81,\!28$	$10,\!42$		$78,\!24$		
(j)	$59,\!37$	$20,\!07$		$57,\!03$		
(a) SURF;						
(b) SURF e MSER-SUI	RF;					
(c) SURF, MSER-SUR	F e SIFT;					
(d) SURF, MSER-SURF, SIFT e LPQ;						
(e) SURF, MSER-SURF, SIFT, LPQ e LPQ-TOP;						
(f) SURF, MSER-SURF, SIFT, LPQ, LPQ-TOP e Gabor;						

**Tabela 5.8:** Resultados da combinação de agrupamentos com k (k = 1..10) classificadores, sendo todos alcançados pela regra de combinação máximo.

ficadores quase permitem que se alcance o valor máximo para o 'Oráculo Acumulado' e aqui compuseram o conjunto de classificadores para o qual se alcançou as melhores taxas. Combinados, os classificadores SURF, MSER-SURF, SIFT, LPQ e LPQ-TOP alcançaram 90,71% ( $\sigma$ =2,45; AUC=86,62) por meio da regra de combinação máximo, melhorando as taxas individuais dos classificadores em 1,57 pontos percentuais.

(g) SURF, MSER-SURF, SIFT, LPQ, LPQ-TOP, LBP<sup>u2</sup><sub>8,2</sub> e Gabor;
(h) SURF, MSER-SURF, SIFT, LPQ, LPQ-TOP, LBP<sup>u2</sup><sub>8,2</sub>, LBP<sup>ri</sup><sub>8,2</sub> e Gabor;
(i) SURF, MSER-SURF, SIFT, LPQ, LPQ-TOP, LBP<sup>u2</sup><sub>8,2</sub>, LBP<sup>ri</sup><sub>8,2</sub>, LBP<sup>riu2</sup><sub>8,2</sub> e Gabor;
(j) SURF, MSER-SURF, SIFT, LPQ, LPQ-TOP, LBP<sup>u2</sup><sub>8,2</sub>, LBP<sup>riu2</sup><sub>8,2</sub>, GLCM e Gabor.

# 5.3.2 Métodos de seleção dinâmica de classificadores baseados na distribuição das instâncias no espaço de dissimilaridade

Nesta seção são apresentadas as alternativas avaliadas para a seleção dinâmica de classificadores tomando como base apenas a distribuição das instâncias no espaço de dissimilaridade.

# 5.3.2.1 Seleção dinâmica de classificadores baseada na distância entre a instância questionada e os centróides das classes do conjunto de validação

A partir do método proposto na Seção 4.4.1.1, as melhores taxas de reconhecimento foram obtidas para Média (61,48%;  $\sigma$ =1,51; AUC=59,20) e Máximo (55,11%;  $\sigma$ =1,43; AUC=56,91). O mesmo experimento foi repetido considerando apenas a classe positiva em cada espaço de representação, alcançando taxas similares às anteriores, também com as regras Média (60,00%;  $\sigma$ =1,75; AUC=58,60) e Máximo (56,48%;  $\sigma$ =1,61; AUC=57,68).

Ao se considerar as taxas da Tabela 5.1, tomou-se apenas os sete melhores classificadores e obteve-se os melhores resultados para Média (69,20%;  $\sigma$ =2,15; AUC=66,01) e Máximo (76,48%;  $\sigma$ =2,55; AUC=74,85). Já para os cinco melhores classificadores, tem-se Média (70,23%;  $\sigma$ =1,82; AUC=65,36) e Máximo (79,89%;  $\sigma$ =1,78; AUC=77,59). Em decorrência da restrição a classificadores com melhores taxas houve um aumento também nas taxas decorrentes da seleção de classificadores, mas as taxas ainda são inferiores àquelas do melhor classificador (SURF).

Tais resultados conduziram à análise de cada espaço de representação e os dados apresentados na Figura 5.5 justificam as baixas taxas deste processo de seleção. Como se pode perceber, GLCM apresentou menor valor para a distância média entre as instâncias questionadas  $Z_{q,j}$  e os centróides selecionados C, enquanto  $LBP_{8,2}^{riu2}$  situa-se no outro extremo com os maiores valores para a distância média e o desvio padrão. Embora caracterizem os dois extremos quanto à distância entre as instâncias questionadas e os centróides selecionados e estejam dentre os três piores resultados do conjunto de 10 classificadores, GLCM e  $LBP_{8,2}^{riu2}$  foram os dois mais selecionados (Tabela 5.9). Mesmo com a maior distância média para  $LBP_{8,2}^{riu2}$ , o alto valor para o desvio padrão o levou a ser o segundo com maior número de seleções.



Figura 5.5: Distância média e desvio padrão entre as instâncias questionadas  $Z_{q,j}$  e os centróides (C+ ou C-) das classes selecionadas nos diferentes espaços de representação.

A Figura 5.6, com maiores detalhes nas Tabelas 5.10 e 5.11, confirma a inviabilidade quanto ao uso da distância entre a instância questionada e os centróides das classes no conjunto de validação. As instâncias questionadas estão mais próximas dos centros das classes selecionadas (corretas ou incorretas) do que daquelas que indicariam a solução ótima ('Corretos'), isto é, com a predição correta e  $d(Z_{q,i}, C)$  mínima.

Tomando ainda a Figura 5.6, ao se considerar apenas os classificadores 'Selecionados', dividiu-se suas instâncias em dois grupos. O grupo 'Acertos' compreende as instâncias

	# Classificadores					
Classificador		0	7	•	5	
selecionado	%	$\sigma$	%	$\sigma$	%	$\sigma$
LPQ	5,11	0,55	14,72	1,18	22,18	$3,\!39$
SIFT	$1,\!45$	0,36	7,77	$0,\!81$	$10,\!93$	0,92
SURF	$1,\!80$	0,32	12,04	$1,\!00$	$19,\!23$	0,97
MSER-SURF	$2,\!25$	$0,\!41$	$9,\!89$	$0,\!67$	$14,\!91$	$1,\!43$
LPQ-TOP	$6,\!93$	0,92	22,94	$4,\!59$	32,76	$2,\!45$
$LBP_{8,2}^{u2}$	$0,\!80$	0,02	$^{5,17}$	$0,\!34$	-	-
$LBP_{8,2}^{ri}$	$7,\!61$	0,77	$27,\!47$	$3,\!67$	-	-
$LBP_{8,2}^{\tilde{riu}2}$	$15,\!46$	$1,\!32$	-	-	-	-
GLCM	50,22	$7,\!44$	-	-	-	-
Gabor	$^{8,38}$	$1,\!01$	-	-	-	-

**Tabela 5.9:** Taxa de seleção dos classificadores para os diferentes subconjuntos considerados nos experimentos com seleção dinâmica de classificadores baseada nas distâncias  $d(Z_{q,j}, C)$ .

para as quais os classificadores selecionados acertaram a predição, enquanto 'Erros' compreende o conjunto de instâncias incorretamente classificadas. As predições corretas ('Acertos') caracterizam-se por ter suas instâncias questionadas mais distantes das classes para as quais foram preditas do que as incorretas ('Erros').



Figura 5.6: Distância média e desvio padrão entre as instâncias questionadas e os centróides das classes selecionadas, considerando todos os espaços de representação.

# 5.3.2.2 Seleção dinâmica de classificadores baseada na distância entre a instância questionada e as fronteiras dos modelos de classificação

Seguindo os procedimentos descritos na Seção 4.4.1.2, alcançou-se as melhores taxas de reconhecimento para Média (61,25%;  $\sigma$ =1,49; AUC=59,58) e Máximo (60,57%;  $\sigma$ =1,89;

**Tabela 5.10:** Estatísticas das distâncias entre as instâncias questionadas  $Z_{q,j}$  corretamente classificadas e os centróides (C+ ou C-) das classes selecionadas nos diferentes espaços de representação.

Classificador	Mínimo	Máximo	Média	Mediana	D. Padrão
LPQ	0,07012	$0,\!63622$	0,21236	0,19996	0,07463
SIFT	0,07438	$0,\!66885$	$0,\!23770$	0,22914	0,06412
SURF	0,08015	0,82974	0,23025	0,21728	0,07309
MSER-SURF	0,06855	0,78291	0,23011	0,21415	0,07967
LPQ-TOP	0,07091	0,55565	0,20412	$0,\!19277$	0,06686
$LBP_{8,2}^{u2}$	0,06258	0,92920	0,25520	0,23586	$0,\!09665$
$LBP_{8,2}^{ri}$	0,03585	$1,\!46755$	0,25124	0,20166	$0,\!15376$
$LBP_{8,2}^{riu2}$	0,01703	1,52734	0,25724	0,19192	$0,\!17557$
GLCM	0,02409	1,73905	$0,\!17559$	$0,\!14880$	$0,\!11435$
Gabor	0,06444	$1,\!28513$	$0,\!23958$	0,20982	0,11280

**Tabela 5.11:** Estatísticas das distâncias entre as instâncias questionadas  $Z_{q,j}$  incorretamente classificadas e os centróides (C+ ou C-) das classes selecionadas nos diferentes espaços de representação.

Classificador	Mínimo	Máximo	Média	Mediana	D. Padrão
LPQ	0,07147	0,61283	$0,\!12506$	0,11342	0,04301
SIFT	0,07759	$0,\!39408$	$0,\!15740$	$0,\!15158$	0,04019
SURF	0,08564	$0,\!68014$	$0,\!15907$	$0,\!14673$	0,04941
MSER-SURF	0,07326	0,55333	$0,\!14357$	$0,\!13423$	0,04530
LPQ-TOP	0,06794	0,53050	$0,\!11867$	0,10787	0,03891
$LBP_{8,2}^{u2}$	0,07291	$0,\!65413$	$0,\!15994$	$0,\!14705$	0,04904
$LBP_{8,2}^{ri}$	0,03826	0,82684	0,14926	0,13324	0,06182
$LBP_{8,2}^{riu2}$	0,01812	0,99306	$0,\!14657$	$0,\!13030$	0,08080
GLCM	0,02489	$1,\!67183$	0,11325	0,09986	$0,\!05496$
Gabor	$0,\!05991$	$0,\!68235$	$0,\!14063$	$0,\!12813$	0,04899

AUC=57,44). Como antes, analisou-se cada espaço de representação na tentativa de justificar as baixas taxas. Os dados apresentados na Figura 5.7 nos auxiliam neste processo.  $LBP_{8,2}^{riu2}$  apresentou maior valor para a distância média entre as instâncias questionadas e as fronteiras dos modelos de classificação, além de também ter apresentado maior variação (desvio padrão), enquanto GLCM situa-se no outro extremo com distância média e desvio padrão muito baixos. Embora  $LBP_{8,2}^{riu2}$  e GLCM caracterizem os dois extremos quanto à distância entre a instância questionada e a fronteira e também quanto à quantidade de vezes em que foram selecionados (Tabela 5.12), ambos estão dentre os três piores desempenhos no conjunto de 10 classificadores.

A partir dos resultados apresentados para esta estratégia, identificou-se taxas de reconhecimento inferiores à maioria dos classificadores individualmente. Considerando as taxas da Tabela 5.1, ao se tomar os sete melhores classificadores, alcançou-se os melhores resultados para Média (78,41%;  $\sigma$ =2,09; AUC=71,89) e Máximo (90,23%;  $\sigma$ =1,91; AUC=85,48). Também para os cinco melhores classificadores, obteve-se Média (80,91%;  $\sigma$ =1,61; AUC=72,86) e Máximo (91,36%;  $\sigma$ =2,61; AUC=85,91). Somente com a exclusão dos três piores classificadores do conjunto alcançou-se resultados similares àqueles obtidos com a combinação do melhor subconjunto de classificadores (Seção 5.3.1), mas ainda



Figura 5.7: Distância média e desvio padrão entre as instâncias questionadas  $Z_{q,j}$  e as fronteiras dos modelos f nos diferentes espaços de representação.

**Tabela 5.12:** Taxa de seleção de cada classificador para os diferentes subconjuntos considerados nos experimentos com seleção dinâmica de classificadores baseada nas distâncias  $d(Z_{q,j}, f)$ .

	# Classificadores					
Classificador	10	D	7	7		
selecionado	%	$\sigma$	%	$\sigma$	%	$\sigma$
LPQ	2,83	0,21	12,54	2,47	14,62	1,29
SIFT	$1,\!07$	$0,\!01$	$7,\!11$	$0,\!99$	8,41	0,73
SURF	$1,\!31$	$0,\!02$	$11,\!85$	$2,\!19$	$13,\!20$	$1,\!88$
MSER-SURF	$5,\!28$	$0,\!26$	$31,\!23$	$4,\!96$	$34,\!17$	$^{5,01}$
LPQ-TOP	$^{5,55}$	$0,\!81$	26,83	2,75	$29,\!60$	$3,\!97$
$LBP_{8,2}^{u2}$	$0,\!64$	$0,\!01$	$4,\!05$	$0,\!67$	-	-
$LBP_{8,2}^{ri}$	$0,\!87$	$0,\!01$	$6,\!40$	$0,\!56$	-	-
$LBP_{8,2}^{riu2}$	$81,\!31$	$7,\!98$	-	-	-	-
GLCM	$0,\!00$	$0,\!00$	-	-	-	-
Gabor	$1,\!13$	$0,\!03$	-	-	-	-

cerca de 0,5 pontos percentuais abaixo. Ainda nesta linha de raciocínio, a utilização de apenas os cinco melhores classificadores nesta estratégia conduziu a taxas cerca de 0,6 pontos percentuais acima daqueles obtidos com a combinação do melhor subconjunto de classificadores e 2,22 pontos percentuais melhores que SURF individualmente.

A Figura 5.8, com maiores detalhes nas Tabelas 5.13 e 5.14, confirma a inviabilidade quanto ao uso de  $d(Z_{q,j}, f)$ . Como se pode perceber, numa escala de  $10^{-4}$ , basicamente não há diferenças quanto à distância média e o desvio padrão entre os classificadores escolhidos durante o processo de classificação ('Selecionados') e aqueles que indicariam a solução ótima ('Corretos'). Neste caso, a 'solução ótima' é definida pela seleção do classificador que maximize a distância  $d(Z_{q,j}, f)$  e que tenha sua predição correta. Além disto, mais um indicativo quanto à inviabilidade foi identificado ao se tomar apenas o conjunto de classificadores 'Selecionados' e dividir suas instâncias em dois grupos. O grupo 'Acertos' compreende as instâncias para as quais os classificadores selecionados acertaram a predição, enquanto 'Erros' compreende o conjunto de instâncias incorretamente classificadas. Novamente não houve variação significativa na distância média e desvio padrão para uma escala de  $10^{-4}$ .



**Figura 5.8:** Distância média e desvio padrão entre as instâncias questionadas  $Z_{q,j}$  e as fronteiras dos modelos f, considerando todos os espaços de representação.

**Tabela 5.13:** Estatísticas das distâncias entre as instâncias questionadas  $Z_{q,j}$  corretamente classificadas e as fronteiras f nos diferentes espaços de representação.

Classificador	Mínimo	Máximo	Média	Mediana	D. Padrão
LPQ	0,00002	6,09867	1,50255	1,41439	0,71811
SIFT	0,00001	4,39536	$1,\!20742$	$1,\!19692$	$0,\!59840$
SURF	0,00001	$4,\!38717$	$1,\!31711$	$1,\!27144$	$0,\!69246$
MSER-SURF	0,00001	5,90550	1,72261	$1,\!64491$	0,82044
LPQ-TOP	0,00001	5,70286	1,73352	$1,\!67729$	0,81411
$LBP_{8,2}^{u2}$	0,00004	4,25985	$1,\!06105$	1,04088	0,52368
$LBP_{8,2}^{ri}$	0,00000	$4,\!64067$	$1,\!17416$	1,21231	0,51938
$LBP_{8,2}^{riu2}$	0,00003	$16,\!38230$	$4,\!95869$	4,91049	2,50267
GLCM	0,00000	0,06663	0,00404	0,00223	0,00592
Gabor	0,00001	$4,\!87142$	0,98909	0,91171	$0,\!65791$
Os valores expr	essos nesta t	abela deven	ı ser multi	plicados por	$10^{-4}$ .

# 5.3.2.3 Seleção dinâmica de classificadores baseada na dispersão das referências dos conjuntos de validação

Seguindo os procedimentos descritos na Seção 4.4.1.3, as melhores taxas de reconhecimento foram obtidas por meio das regras de fusão Média (48,30%;  $\sigma$ =1,02; AUC=50,13) e Máximo (34,66%;  $\sigma$ =1,53; AUC=34,52). Ao se considerar as taxas da Tabela 5.1 e os sete melhores classificadores, alcançou-se os melhores resultados para Média (65,23%;  $\sigma$ =1,68; AUC=62,57) e Máximo (85,57%;  $\sigma$ =1,75; AUC=79,57). Novamente, para os

Classificador	Mínimo	Máximo	Média	Mediana	D. Padrão
LPQ	0,00017	4,79930	0,95010	0,76593	0,71588
SIFT	0,00039	3,06219	0,56990	$0,\!45948$	$0,\!41903$
SURF	0,00007	2,75995	$0,\!56357$	0,46456	$0,\!38150$
MSER-SURF	0,00009	4,35424	0,90272	0,74506	$0,\!63665$
LPQ-TOP	0,00011	4,78654	0,99228	0,80595	0,73497
$LBP_{8,2}^{u2}$	0,00023	$3,\!65285$	$0,\!68374$	0,55833	0,50295
$LBP_{8,2}^{ri}$	0,00037	3,71405	0,77682	$0,\!64413$	0,56101
$LBP_{8,2}^{riu2}$	0,00522	$12,\!43300$	$3,\!27257$	3,02212	1,92326
GLCM	0,00000	0,06142	0,00056	0,00038	0,00123
Gabor	0,00021	$2,\!83577$	$0,\!62318$	$0,\!55132$	$0,\!38151$
Os valores expre	essos nesta t	abela deven	n ser multi	plicados por	$10^{-4}$ .

**Tabela 5.14:** Estatísticas das distâncias entre as instâncias questionadas  $Z_{q,j}$  incorretamente classificadas e as fronteiras f nos diferentes espaços de representação.

cinco melhores classificadores, identificou-se as regras de fusão Média (67,16%;  $\sigma$ =1,19; AUC=64,52) e Máximo (88,52%;  $\sigma$ =2,23; AUC=83,87) com as melhores taxas. Em decorrência da restrição a classificadores com melhores taxas houve um aumento também nas taxas decorrentes da seleção de classificadores, mas as taxas são inferiores àquelas do melhor classificador (SURF). Tais resultados podem ser melhor compreendidos com as ilustrações das Figuras 5.9 e 5.10. As menores dispersões médias foram obtidas para o pior classificador em termos de resultados individuais (Tabela 5.1), o que gerou as taxas de seleção de classificadores da Tabela 5.15.



Figura 5.9: Dispersão média das referências  $Z_{u,v}$  e desvio padrão nos diferentes espaços de representação.

A Figura 5.10, com maiores detalhes nas Tabelas 5.16 e 5.17, confirma a inviabilidade quanto ao uso da dispersão das referências como critério de seleção. Como se pode perceber, basicamente não há diferenças quanto à dispersão média e o desvio padrão entre os classificadores escolhidos durante o processo de classificação ('Selecionados') e aqueles que indicariam a solução ótima ('Corretos'). Neste caso, a 'solução ótima' é definida pela

	# Classificadores					
Classificador	1	0	7	,	5	
selecionado	%	σ	%	$\sigma$	%	$\sigma$
LPQ	6,83	0,93	$13,\!65$	1,54	$15,\!88$	1,42
SIFT	$0,\!00$	$0,\!00$	$6,\!94$	$1,\!11$	$9,\!17$	0,91
SURF	$2,\!27$	$0,\!31$	$11,\!37$	$1,\!85$	$13,\!64$	0,92
MSER-SURF	$2,\!27$	$0,\!19$	6,79	$0,\!63$	$9,\!07$	$1,\!07$
LPQ-TOP	29,53	$2,\!69$	47,70	$6,\!87$	$52,\!24$	$9,\!60$
$LBP_{8,2}^{u2}$	$0,\!00$	$0,\!00$	$0,\!00$	$0,\!00$	-	-
$\mathrm{LBP}_{8,2}^{ri}$	$^{6,82}$	$1,\!01$	$13,\!55$	$2,\!04$	-	-
$LBP_{8,2}^{riu2}$	$0,\!00$	$0,\!00$	-	-	-	-
GLCM	$50,\!00$	$^{8,77}$	-	-	-	-
Gabor	$2,\!27$	$0,\!13$	-	-	-	-

**Tabela 5.15:** Taxa de seleção de cada classificador para os diferentes subconjuntos considerados nos experimentos com seleção dinâmica de classificadores baseada na dispersão das referências  $Z_{u,v}$ .

seleção do classificador que minimize a dispersão das referências e que tenha sua predição correta. Além disto, mais um indicativo quanto à inviabilidade foi identificado ao se tomar apenas o conjunto de classificadores 'Selecionados' e dividir suas instâncias em dois grupos. O grupo 'Acertos' compreende as instâncias para as quais os classificadores selecionados acertaram a predição, enquanto 'Erros' compreende o conjunto de instâncias incorretamente classificadas. Novamente não houve variação significativa na dispersão média e desvio padrão.



Figura 5.10: Dispersão média e desvio padrão das referências considerando todos os espaços de representação.

Classificador	Mínimo	Máximo	Média	Mediana	D. Padrão
LPQ	0,05225	0,31955	0,11842	0,10881	0,05577
SIFT	0,06159	0,23252	$0,\!12546$	$0,\!12856$	0,03627
SURF	0,07062	$0,\!27054$	$0,\!13030$	$0,\!11944$	0,04471
MSER-SURF	0,06190	0,26664	$0,\!12676$	0,12170	$0,\!04570$
LPQ-TOP	0,05581	0,25829	0,10781	0,09873	0,04736
$LBP_{8,2}^{u2}$	0,08057	$0,\!30613$	0,16985	0,16554	0,05283
$LBP_{8,2}^{ri}$	$0,\!05487$	$0,\!37043$	0,16822	0,16204	$0,\!05788$
$LBP_{8,2}^{riu2}$	0,05868	$0,\!40913$	$0,\!17936$	$0,\!17442$	0,06430
GLCM	0,02511	0,39542	0,09823	0,09151	$0,\!05394$
Gabor	0,06860	$0,\!29850$	$0,\!13863$	$0,\!12341$	0,04620

**Tabela 5.16:** Estatísticas das dispersões das referências  $Z_{u,v}$  nos diferentes espaços de representação para os classificadores corretamente selecionados.

**Tabela 5.17:** Estatísticas das dispersões das referências  $Z_{u,v}$  nos diferentes espaços de representação para os classificadores incorretamente selecionados.

Classificador	Mínimo	Máximo	Média	Mediana	D. Padrão
LPQ	0,05269	0,31955	0,09890	0,09033	0,03962
SIFT	0,06360	0,23252	$0,\!12167$	$0,\!11637$	0,03457
SURF	0,07068	$0,\!27083$	$0,\!12238$	$0,\!11363$	0,03970
MSER-SURF	0,06190	$0,\!27119$	$0,\!11492$	$0,\!10676$	0,04061
LPQ-TOP	$0,\!05581$	0,25829	$0,\!08905$	0,07536	0,03350
$LBP_{8,2}^{u2}$	0,08228	$0,\!30613$	0,16184	$0,\!15880$	0,04818
$LBP_{8,2}^{ri}$	$0,\!05765$	0,37043	0,16837	$0,\!15649$	0,05632
$LBP_{8,2}^{riu2}$	$0,\!05918$	$0,\!40913$	$0,\!18237$	0,16195	0,06392
GLCM	0,02779	0,39542	0,08902	0,08094	0,04308
Gabor	0,06930	0,29850	0,12688	0,11584	0,04241

# 5.3.3 Métodos de seleção dinâmica de classificadores baseados nas decisões para as vizinhanças das instâncias questionadas

Nesta seção são apresentados os resultados das alternativas avaliadas para a seleção dinâmica de classificadores baseadas na distribuição das amostras no espaço de dissimilidade e nas decisões tomadas para a vizinhança (em uma base de validação) das amostras questionadas. Embora os tamanhos das vizinhanças variem de acordo com os critérios (OLA ou LCA) e classificadores utilizados, nas seções seguintes a representação nos gráficos está limitada a 75 vizinhos, o que não prejudica a identificação de comportamentos e tendências inerentes a cada método de seleção.

## 5.3.3.1 Avaliação dos métodos OLA e LCA

Este conjunto de experimentos avaliou os métodos propostos por Woods *et al.* [146] para a seleção dinâmica de classificadores. Como se pode perceber (Figura 5.11), os métodos OLA e LCA alcançaram resultados similares para todos os tamanhos de vizinhança avaliados. Apesar de tal similaridade em termos de taxas de reconhecimento, em geral, houve pequena vantagem para o método OLA, o que contraria as referências encontradas na literatura que indicam superioridade do critério LCA sobre o OLA.

Os melhores resultados obtidos com LCA foram 84,86% ( $\sigma$ =2,56; AUC=79,91; k=1) e 69,41% ( $\sigma$ =2,06; AUC=65,91; k=45) para as regras de fusão máximo e média, respectivamente. Além do melhor desempenho geral, OLA também alcançou taxas de reconhecimento superiores, com 86,19% ( $\sigma$ =1,76; AUC=83,06; k=300) e 71,58% ( $\sigma$ =2,40; AUC=68,02; k=30) para as regras de fusão máximo e média, respectivamente.

Considerando os resultados com a aplicação da regra de fusão máximo e as vizinhanças identificadas anteriormente, a Figura 5.12 apresenta os gráficos ROC para as configurações em que os dois métodos alcançaram suas melhores taxas de reconhecimento. Neste caso, identificou-se a superioridade do critério OLA sobre o LCA.



**Figura 5.11:** Taxas de reconhecimento alcançadas pelos métodos OLA e LCA para a regra de fusão máximo e as vizinhanças entre um e 75 elementos.

#### 5.3.3.2 Avaliação dos métodos a priori e a posteriori

Nesta seção são apresentados os resultados obtidos pelos métodos propostos por Giacinto e Roli [35]. Como se pode concluir ao analisar as Figuras 5.11 e 5.13, estes métodos obtiveram resultados superiores àqueles alcançados por OLA e LCA. Contrariando os comportamentos dos métodos OLA e LCA, ao se considerar a Figura 5.13, constatase que *a posteriori* possui taxas de reconhecimento superiores que *a priori* para todos os tamanhos de vizinhança avaliados, inclusive com maior estabilidade das taxas com relação à variação do tamanho da vizinhança.

Os melhores resultados obtidos com o método *a priori* foram 90,28% ( $\sigma$ =1,69; AUC=86,24; k=15) e 79,25% ( $\sigma$ =1,61; AUC=74,25; k=1) para as regras de fusão máximo e média, respectivamente. Por sua vez, o método *a posteriori* atingiu 92,86% ( $\sigma$ =2,29; AUC=89,61; k=8) e 87,78% ( $\sigma$ =2,18; AUC=81,24; k=135), também para as mesmas regras de fusão.



**Figura 5.12:** Gráfico ROC para as vizinhanças com os melhores resultados para os métodos OLA e LCA e regra de fusão máximo.

Considerando os resultados com a aplicação da regra de fusão máximo e as vizinhanças identificadas anteriormente, a Figura 5.14 apresenta os gráficos ROC para os melhores resultados dos métodos *a priori* e *a posteriori*. Também neste caso, identificou-se a superioridade do critério LCA sobre o OLA.



**Figura 5.13:** Taxas de reconhecimento alcançadas pelos métodos *a priori* e *a posteriori* para a regra de fusão máximo e as vizinhanças entre um e 75 elementos.



**Figura 5.14:** Gráfico ROC para as vizinhanças com os melhores resultados para os métodos *a priori* e *a posteriori* e regra de fusão máximo.

# 5.3.3.3 Avaliação dos métodos baseados no comportamento de múltiplos classificadores

Proposto por Giacinto e Roli [36], MCB OLA alcançou taxas de reconhecimento de 84,36% ( $\sigma$ =2,52; AUC=80,09; k=4) e 75,21% ( $\sigma$ =3,36; AUC=70,32; k=4) para as regras de fusão máximo e média, respectivamente. O primeiro método proposto neste trabalho e denominado MCB LCA atingiu taxas de reconhecimento de 86,27% ( $\sigma$ =1,77; AUC=81,75; k=135) e 78,17% ( $\sigma$ =1,38; AUC=72,50; k=135) para as regras de fusão máximo e média, respectivamente.

A Figura 5.15 confirma a superioridade identificada no parágrafo anterior do critério LCA sobre o OLA, a qual ocorreu para todos os tamanhos de vizinhança avaliados, validando a hipótese inicial apresentada na Seção 4.4.2. Assim, o método proposto restringiu a vizinhança por meio do critério LCA e apresentou taxas com comportamentos e tendências mais estáveis diante da variação dos tamanhos das vizinhanças.

Considerando os resultados com a aplicação da regra de fusão máximo e as vizinhanças identificadas anteriormente, a Figura 5.16 apresenta os gráficos ROC para os melhores resultados dos métodos MCB OLA e MCB LCA. Mais uma vez constatou-se a superioridade do critério LCA sobre o OLA, validando a hipótese inicial (*vide* Seção 4.4.2).

## 5.3.3.4 Avaliação dos métodos MCB a priori e MCB a posteriori

Os métodos MCB *a priori* e MCB *a posteriori* também foram propostos neste trabalho. Para o primeiro atingiu-se taxas de reconhecimento de 86,78% ( $\sigma$ =2,09; AUC=80,40;



**Figura 5.15:** Taxas de reconhecimento alcançadas pelos métodos MCB OLA e MCB LCA para a regra de fusão máximo e as vizinhanças entre um e 75 elementos.



**Figura 5.16:** Gráfico ROC para as vizinhanças com os melhores resultados para os métodos MCB OLA e MCB LCA e regra de fusão máximo.

k=180) e 83,45% ( $\sigma$ =1,20; AUC=77,27; k=120) para as regras de fusão máximo e média, respectivamente. Por meio das mesmas regras de fusão, o método MCB *a posteriori* atingiu 93,03% ( $\sigma$ =1,36; AUC=89,37; k=8) e 90,00% ( $\sigma$ =1,30; AUC=83,39; k=75), respectivamente.

As Figuras 5.17 e 5.18 ilustram a superioridade do critério LCA sobre o OLA para todos os tamanhos de vizinhança avaliados. Além disso, ao se comparar as Figuras 5.13 e 5.17, facilmente se percebe que o método MCB *a priori* é mais estável que o método *a priori*, enquanto os métodos *a posteriori* e MCB *a posteriori* possuem resultados muito similares, validando a hipótese inicial (*vide* Seção 4.4.2).

Considerando os resultados com a aplicação da regra de fusão máximo e as vizinhanças identificadas anteriormente, a Figura 5.18 apresenta os gráficos ROC para os melhores resultados dos métodos MCB *a priori* e MCB *a posteriori*.



**Figura 5.17:** Taxas de reconhecimento alcançadas pelos métodos MCB *a priori* e MCB *a posteriori* para a regra de fusão máximo e as vizinhanças entre um e 75 elementos.



**Figura 5.18:** Gráfico ROC para as vizinhanças com os melhores resultados para os métodos MCB *a priori* e MCB *a posteriori* e regra de fusão máximo.

### 5.3.3.5 Avaliação dos métodos KNORA-E e KNORA-U

Nesta seção são apresentados os resultados obtidos pelos métodos propostos por Ko *et al.* [64, 65]. KNORA-E alcançou taxas de reconhecimento de 88,30% ( $\sigma$ =3,73; AUC=84,70; k=30) e 87,82% ( $\sigma$ =1,66; AUC=80,64; k=1) para as regras de fusão máximo e média,

respectivamente. Por meio das mesmas regras, o método KNORA-U atingiu, respectivamente, taxas de 64,49% ( $\sigma$ =17,73; AUC=61,74; k=1) e 88,38% ( $\sigma$ =1,69; AUC=80,95; k=90).

Cabe salientar que Ko *et al.* [64, 65] definiu que na versão KNORA-U, cada classificador  $C_i$  terá direito a um voto para cada vizinho  $r_j$  por ele corretamente classificado dentre os k vizinhos mais próximos (no conjunto de validação) à amostra questionada. Ou seja, a precisão de  $C_i$  no conjunto de validação é utilizada como peso durante a fusão dos classificadores disponíveis e o número final de votos será definido pela soma do número de vizinhos corretamente preditos pelos classificadores  $C_i$ .

Devido ao uso de um conjunto mais amplo de regras de fusão, para cada amostra questionada, a predição de  $C_i$  foi repetida para cada vizinho  $r_j$  corretamente classificado por  $C_i$  na vizinhança da amostra questionada. Assim, manteve-se a definição de que a precisão de  $C_i$  no conjunto de validação deva ser utilizada como peso durante a fusão dos classificadores na versão KNORA-U.

Pela Figura 5.19, confirma-se a superioridade identificada anteriormente para a combinação da versão KNORA-U e a regra de fusão média para todos os tamanhos de vizinhança avaliados. Diante de tais resultados, tem-se que tal combinação permite que os classificadores menos precisos também sejam utilizados, mas impõe a combinação dos classificadores com a aplicação de pesos inerentes ao número de seus acertos na vizinhança do conjunto de validação. Assim, amplia-se a possibilidade de se ter classificadores com maior nível de complementaridade enquanto restringe-se a influência dos piores classificadores por meio dos referidos pesos.

Já para a regra máximo, a versão KNORA-U apresentou as piores taxas de reconhecimento. Isso é consequência da incorporação dos classificadores menos precisos ao conjunto considerado. Tais classificadores podem gerar probabilidades superiores àqueles que apresentam as melhores taxas de reconhecimento e a regra máximo não é influenciada pelo número dos acertos dos classificadores no conjunto de validação como as demais.

Por restringir o conjunto de classificadores àqueles com melhores resultados na vizinhança da amostra questionada no conjunto de validação, a versão KNORA-E gerou melhores taxas de reconhecimento quando combinada com a regra máximo. Neste ponto, destaca-se os gráficos ROC na Figura 5.20 para os melhores resultados dos métodos KNORA-E e KNORA-U, respectivamente, para as regras máximo e média. Neste caso, constatou-se a superioridade do método KNORA-E sobre o KNORA-U ao se considerar os gráficos ROC e o valor para a AUC.

A Tabela 5.18 nos auxilia na compreensão dos resultados previamente apresentados por meio da taxa de seleção de cada um dos classificadores utilizados. Especificamente para estes métodos, a soma das taxas de seleção dos classificadores ultrapassa o valor de 100%. Isso decorre do fato de que as versões KNORA-E e KNORA-U selecionam pelo menos um classificador para cada amostra questionada, podendo inclusive selecionar todos os classificadores disponíveis.



**Figura 5.19:** Taxas de reconhecimento alcançadas pelos métodos KNORA-E e KNORA-U para as regras de fusão máximo e média e as vizinhanças entre um e 75 elementos.



**Figura 5.20:** Gráfico ROC para as vizinhanças com os melhores resultados para os métodos KNORA-E e KNORA-U e as regras de fusão máximo e média, respectivamente.

Como demonstrado na Tabela 5.18, há uma alta dependência dos melhores classificadores. Embora isso também ocorra para os demais métodos de seleção (*vide* seção seguinte), as versões do KNORA são ainda prejudicadas por combinarem os classificadores selecionados, dentre os quais muitas vezes estão aqueles com baixas taxas de reconhecimento.

Para a versão KNORA-U, exceto para as vizinhanças com quantidades de vizinhos muito reduzidas, todos os classificadores foram utilizados para cada uma das amostras questionadas. Embora na versão KNORA-U as taxas de seleção de todos os classificadores indiquem 100% para a maioria das vizinhanças avaliadas, ao se tomar os dados da Tabela 5.18, tem-se a dimensão efetiva da importância de cada um dos classificadores na fase

	# Vizinhos								
Classificador	3	0	9	0					
selecionado	%	σ	%	$\sigma$					
LPQ	$15,\!28$	$3,\!88$	11,99	$9,\!65$					
SIFT	$26,\!97$	$6,\!91$	$25,\!59$	$^{8,89}$					
SURF	26,21	$10,\!91$	24,77	$14,\!38$					
MSER-SURF	$24,\!96$	$^{8,19}$	$23,\!68$	$10,\!49$					
LPQ-TOP	$27,\!44$	$7,\!23$	22,10	$10,\!39$					
$LBP_{8,2}^{u2}$	$6,\!30$	2,50	$1,\!60$	$0,\!93$					
$LBP_{8,2}^{ri}$	$13,\!24$	$6,\!95$	7,06	$^{8,35}$					
$LBP_{8,2}^{riu2}$	4,74	2,28	1,28	0,78					
GLCM	$^{5,80}$	$2,\!43$	$1,\!54$	$1,\!38$					
Gabor	$3,\!85$	2,10	0,51	$0,\!80$					

**Tabela 5.18:** Taxas de seleção dos classificadores para o método KNORA-E, considerando os 30 e os 90 vizinhos dos conjuntos de validação mais próximos às instâncias questionadas.

final de combinação definida por este método.

# 5.3.3.6 Avaliação geral dos métodos para seleção dinâmica de classificadores baseada nas decisões para as vizinhanças das instâncias questionadas

A Tabela 5.19 apresenta a caracterização dos métodos de seleção dinâmica de classificadores apresentados nas Seções 2.4.2.1 e 4.4.2 seguindo os critérios quanto a definição da vizinhança, delimitação da vizinhança e seleção do classificador. A definição da vizinhança considera o uso de distância Euclidiana entre duas amostras ou o índice de similaridade entre suas assinaturas MCB como definido por Giacinto e Roli [36]. A delimitação da vizinhança, por sua vez, considera os critérios OLA e LCA definidos por Woods *et al.* [146]. Para o terceiro critério, as possibilidades compreendem a maximização das taxas de acerto no conjunto de validação proposta por Woods *et al.* [146] e a aplicação das regras de combinação às predições corretas de classificadores probabilísticos no conjunto de validação proposta por Giacinto e Roli [35].

		Seleção do classificador					
Definição da	Delimitação da	Taxas de a	acerto	Probabilidad	les		
vizinhança	vizinhança	Método	%	Método	%		
	OLA	OLA	86,19	a priori	90,28		
Distância		KNORA-E	$88,\!30$				
Euclidiana		KNORA-U	$88,\!38$				
	LCA	LCA	84,86	a posteriori	$92,\!86$		
Similaridade das	OLA	MCB OLA	84,36	MCB a priori	$86,\!78$		
assinaturas MCB	LCA	MCB LCA	$86,\!27$	MCB a posteriori	93,03		

**Tabela 5.19:** Caracterização dos métodos segundo os critérios: (a) definição da vizinhança, (b) delimitação da vizinhança e (c) seleção do classificador.

De forma geral, os métodos baseados no critério LCA alcançaram resultados superio-

res àqueles baseados no critério OLA, com exceção dos próprios métodos OLA e LCA. Da mesma forma, os métodos que aplicam as regras de combinação às predições corretas de classificadores probabilísticos no conjunto de validação foram superiores aos que selecionam os classificadores que maximizam as taxas de acerto no conjunto de validação. Estes resultados confirmam as referências encontradas na literatura e validam as hipóteses identificadas na Seção 4.4.2 para a proposição dos métodos MCB LCA, MCB *a priori* e MCB *a posteriori*. Com exceção do método MCB *a priori*, quando comparado com o *a priori*, todos os métodos propostos obtiveram taxas de reconhecimento superiores aos demais métodos que assumem as mesmas condições para cada um dos três critérios previamente identificados.

Dado o melhor desempenho geral dos métodos de seleção dinâmica de classificadores baseados no critério LCA, estes são analisados na sequência. As Figuras 5.21 e 5.22 mostram que os métodos baseados no conceito MCB alcançaram taxas similares ou superiores àqueles baseados somente na performance de um único classificador para realizar a seleção. Esta diferença aumenta se tomarmos apenas os critérios baseados na porcentagem de vizinhos corretamente classificados no conjunto de validação. De forma contrária, ao se considerar os métodos baseados em estimativas de probabilidades *a posteriori*, verifica-se a equivalência entre os métodos *a posteriori* e MCB *a posteriori*, com vantagem para o segundo na maior parte dos tamanhos de vizinhança avaliados.



**Figura 5.21:** Taxas de reconhecimento alcançadas pelo métodos baseados no critério LCA para a delimitação da vizinhança da instância questionada, a regra de fusão máximo e as vizinhanças entre um e 75 elementos.

A Tabela 5.20 apresenta uma análise da frequência de seleção dos classificadores e o desvio padrão para cada um dos métodos de seleção dinâmica após a realização das cinco execuções. Primeiramente, identifica-se que os cinco melhores classificadores em termos de performance foram selecionados entre 96,66% e 99,90% das vezes. Tal comportamento demonstra que todos os métodos são dependentes dos melhores classificadores.



**Figura 5.22:** Gráfico ROC para as vizinhanças com os melhores resultados para os métodos baseados no critério LCA para a delimitação da vizinhança da instância questionada e a regra de fusão máximo.

Tomando as taxas individuais de seleção dos classificadores, os métodos LCA, MCB LCA e MCB *a posteriori* apresentaram comportamentos semelhantes, principalmente ao se considerar LPQ, SIFT e SURF. Destaca-se o fato destes terem apontado o classificador LPQ como o melhor a ser escolhido em cerca de 80% dos casos. Por fim, o método *a posteriori* apresentou menor concentração das seleções dentre os cinco melhores classificadores quando comparados aos demais métodos.

-	5 1									
		L								
Classificador	Α		E	3	C	2	D	D		
selecionado	%	$\sigma$	%	$\sigma$	%	$\sigma$	%	$\sigma$		
LPQ	84,12	$3,\!10$	$53,\!95$	9,31	78,44	$7,\!95$	$83,\!37$	4,44		
SIFT	$12,\!65$	$2,\!15$	25,79	4,04	$12,\!55$	7,02	$12,\!33$	$4,\!37$		
SURF	$2,\!27$	$0,\!52$	$14,\!56$	7,01	3,74	$1,\!12$	$2,\!10$	0,26		
MSER-SURF	$0,\!67$	$0,\!35$	2,93	0,77	1,11	$0,\!51$	1,07	$0,\!44$		
LPQ-TOP	$0,\!18$	$0,\!11$	$1,\!66$	0,52	0,82	$0,\!50$	$0,\!63$	$0,\!18$		
$LBP_{8,2}^{u2}$	$0,\!07$	$0,\!04$	$0,\!24$	0,11	0,16	$0,\!12$	0,11	$0,\!13$		
$LBP_{8,2}^{ri}$	0,02	0,01	$0,\!18$	0,14	0,39	0,31	0,09	0,09		
$LBP_{8,2}^{riu2}$	$0,\!00$	$0,\!00$	$0,\!19$	0,19	1,92	$1,\!04$	0,07	0,08		
GLCM	$0,\!00$	$0,\!00$	$0,\!48$	0,16	0,76	$0,\!43$	0,23	$0,\!07$		
Gabor	$0,\!00$	$0,\!00$	0,02	0,01	0,11	$0,\!11$	0,00	$0,\!00$		
A = LCA										
$\mathbf{B} = A \ posteriori$										
C = MCB LCA										
D = MCB a poste	riori									

**Tabela 5.20:** Taxas de seleção dos classificadores para cada um dos métodos baseados no critério LCA para a delimitação da vizinhança de  $s_q$ .

Os apontamentos identificados nos parágrafos anteriores conduziram à análise dos comportamentos dos métodos de seleção diante da restrição aos subconjuntos com os melhores classificadores identificados na Seção 5.1. Assim, a Figura 5.23 apresenta os gráficos com a evolução das taxas de reconhecimento para os métodos *a posteriori* e MCB *a posteriori*, considerando todos os 10 classificadores, além dos sete e cinco melhores. Destaca-se que a apresentação deste gráfico considerou o intervalo [90,0..93,5] ao invés de [50..100] utilizado nos demais gráficos. A nova escala permite identificar as variações inferiores a um ponto percentual no intervalo de 15 a 75 vizinhos.

Enquanto o método MCB *a posteriori* obteve taxas de reconhecimento de 93,03% ( $\sigma$ =1,36; AUC=89,37; k=8) para os 10 classificadores, o mesmo atingiu 92,56% ( $\sigma$ =1,30; AUC=89,02; k=30) e 92,27% ( $\sigma$ =1,52; AUC=88,68; k=45) para os sete e cinco melhores classificadores, respectivamente. Considerando a mesma relação para o método *a posteriori*, com os 10 classificadores alcançou-se 92,86% ( $\sigma$ =2,29; AUC=89,61; k=8), enquanto que para os sete e cinco melhores classificadores obteve-se, respectivamente, 92,54% ( $\sigma$ =1,35; AUC=88,98; k=120) e 92,45% ( $\sigma$ =2,23; AUC=89,08; k=15).



**Figura 5.23:** Taxas de reconhecimento alcançadas pelos métodos *a posteriori* e MCB *a posteriori* para a regra de fusão máximo, com diferentes subconjuntos com 10, 7 e 5 classificadores e as vizinhanças entre um e 75 elementos.

A estabilidade das taxas alcançadas por ambos os métodos é confirmada nas estatísticas quanto à seleção dos classificadores apresentadas na Tabela 5.21. Devido à identificação das melhores taxas para o conjunto originalmente testado com os 10 classificadores ter ocorrido com os oito vizinhos mais próximos do conjunto de validação, assumiu-se este tamanho de vizinhança também para os subconjuntos com os sete e cinco melhores classificadores.

As considerações anteriores quanto à concentração de seleções dos primeiros classificadores se mantêm e, como esperado, com pequeno aumento para os subconjuntos menores avaliados. É importante salientar que, mesmo tendo taxas de seleção muito baixas, os classificadores menos precisos também tiveram influência nos métodos baseados nos comportamentos de múltiplos classificadores. Por comporem a assinatura MCB, a identificação de seus erros e acertos auxiliam na identificação de vizinhanças do conjunto de validação com maior nível de similaridade com a instância questionada.

			=	# Classif	icadore	es	
Método de	Classificador	1	)	7		5	
Seleção	selecionado	%	$\sigma$	%	$\sigma$	%	$\sigma$
	LPQ	$83,\!37$	4,44	86,99	2,96	88,13	$3,\!54$
	SIFT	$12,\!33$	$4,\!37$	$^{8,21}$	3,02	$7,\!48$	$_{3,17}$
	SURF	$2,\!10$	0,26	2,32	$1,\!00$	2,31	0,92
	MSER-SURF	$1,\!07$	$0,\!44$	1,21	$0,\!65$	0,94	0,46
MCB	LPQ-TOP	$0,\!63$	$0,\!18$	1,02	0,72	$1,\!15$	0,80
$a \ posteriori$	$LBP_{8,2}^{u2}$	$0,\!11$	$0,\!13$	$0,\!13$	$0,\!17$	-	-
	$\mathrm{LBP}_{8,2}^{ri}$	0,09	0,09	$0,\!11$	0,16	-	-
	$LBP_{8,2}^{riu2}$	0,07	0,08	-	-	-	-
	GLCM	0,23	$0,\!07$	-	-	-	-
	Gabor	0,00	0,00	-	-	-	-
	LPQ	$53,\!95$	9,31	$54,\!15$	9,31	$54,\!30$	9,34
	SIFT	25,79	4,04	$25,\!90$	4,04	25,96	4,03
	SURF	14,56	7,01	$14,\!67$	6,99	14,75	6,96
	MSER-SURF	2,93	0,77	$3,\!07$	0,75	$3,\!16$	0,74
a posteriori	LPQ-TOP	$1,\!66$	0,52	1,75	0,56	1,82	0,59
	$LBP_{8,2}^{u2}$	$0,\!24$	$0,\!11$	$0,\!27$	$0,\!12$	-	-
	$LBP_{8,2}^{\check{r}i}$	$0,\!18$	$0,\!14$	$0,\!20$	0,16	-	-
	$LBP_{82}^{\check{riu2}}$	$0,\!19$	$0,\!19$	-	-	-	-
	GLCM	0,48	0,16	-	-	-	-
	Gabor	0,02	0,01	-	-	-	-

**Tabela 5.21:** Taxas de seleção dos classificadores para os métodos *a posteriori* e MCB *a posteriori*, considerando os oito vizinhos dos conjuntos de validação mais próximos às instâncias questionadas, além de subconjuntos com os 10, 7 e 5 melhores classificadores.

## 5.3.4 Combinação dos classificadores selecionados

Nesta seção avalia-se a utilização de um conjunto de oito regras de fusão identificadas na Seção 2.4.1, seguindo as considerações da Seção 4.5. Destaca-se que, em decorrência de suas melhores taxas de reconhecimento, as regras máximo e média têm sido apresentadas no decorrer deste trabalho. Além disso, por ter provido taxas de reconhecimento inferiores aos melhores resultados individuais dos classificadores, as demais regras de combinação não foram mencionadas no presente capítulo.

A Figura 5.24 apresenta os resultados para as regras máximo e média. Contrariando as proposições de Giacinto e Roli [36], ao se considerar um conjunto mais amplo de regras de fusão, identificou-se que a regra de fusão máximo apresentou resultados muito superiores àqueles resultantes da regra média para todos os tamanhos de vizinhança avaliados. Além da conclusão anterior, com exceção dos métodos OLA e LCA, mais uma vez confirma-se a superioridade dos métodos baseados no critério LCA sobre aqueles baseados no critério OLA também para todos os tamanhos de vizinhança avaliados.



**Figura 5.24:** Taxas de reconhecimento alcançadas com as regras de fusão máximo e média para as vizinhanças entre um e 75 elementos: (a) OLA e LCA, (b) *a priori* e *a posteriori*, (c) MCB OLA e MCB LCA, e (d) MCB *a priori* e MCB *a posteriori*.

### 5.4 Perspectivas empregadas durante a avaliação dos resultados

Considerando os argumentos apresentados na Seção 4.6, apresenta-se aqui os resultados das estratégias que consideraram os diferentes níveis definidos pela Botânica.

# 5.4.1 Avaliação dos resultados nos diferentes níveis definidos pela Botânica

A Tabela 5.22 ilustra os resultados obtidos para os níveis espécie, gênero, família e filo, com suas 112, 85, 30 e 2 classes 'reais', respectivamente. Conforme esperado, as taxas evoluem positivamente quando se desloca entre os níveis espécie e filo. No entanto, as variações entre as taxas obtidas para os níveis espécie, gênero e família não são tão representativas quando comparadas com as variações entre família e filo.

Tomando as taxas de reconhecimento obtidas pelo melhor classificador (SURF) e pelo melhor método de seleção dinâmica de classificadores, verifica-se uma diferença de 3,89 pontos percentuais no nível espécie. No entanto, no nível filo a comparação das taxas obtidas com SURF e os demais itens da Tabela 5.22 conduzem à utilização direta e única deste classificador. Isto por suas taxas de reconhecimento serem equivalentes às obtidas pelo método KNORA-U e também aos custos inerentes aos métodos de seleção.

Ao se considerar os cinco melhores classificadores (Tabela 5.1), percebe-se que a diferença entre suas taxas de reconhecimento caem de 2,73 para 0,96 pontos percentuais quando se vai do nível espécie para filo. De forma geral, as taxas indicam que a maior parte dos erros encontra-se nos próprios filos Angiospermas e Gimnospermas, o que é confirmado pelos testes da seção seguinte.

No outro extremo,  $LBP_{8,2}^{riu^2}$ , GLCM e filtros de Gabor apresentam as piores taxas em todos os níveis, mas ainda com a maior parte dos erros de classificação internamente aos filos. Tomando o pior classificador (GLCM), identificou-se que no nível espécie *Cariniana estrellensis*, *Pithecellobium jupunba* e *Ligustrum lucidum* não tiveram classificações corretas. Enquanto isso, *Dinizia excelsa* obteve 1.205% mais classificações do que o número de imagens para ela existentes, embora esta espécie tenha alcançado apenas 85% de classificações corretas.

Classificador /	$\mathbf{Esp}$	écie	Gên	ero	Fan	nília	Fi	lo
Mét. de seleção / combinação	- %	$\sigma$	- %	$\sigma$	- %	$\sigma$	- %	$\sigma$
SURF	89,14	2,39	89,43	2,12	91,77	1,22	99,11	0,32
MSER-SURF	$87,\!80$	2,17	87,91	2,08	89,75	1,37	98,78	0,72
SIFT	88,47	$1,\!64$	$89,\!54$	0,82	$91,\!45$	1,38	98,15	0,36
LPQ	86,74	2,07	87,50	1,47	90,54	1,20	98,48	0,29
LPQ-TOP	86,41	1,36	87,46	1,24	90,07	$1,\!66$	98,55	$0,\!17$
$LBP_{8,2}^{u2}$	66,25	$^{4,67}$	66,99	$^{4,16}$	$73,\!28$	$^{5,42}$	96,21	0,95
$\mathrm{LBP}^{ri}_{8,2}$	50,74	$9,\!54$	$51,\!87$	9,06	$62,\!07$	$^{5,47}$	$95,\!18$	2,36
Gabor	$25,\!67$	2,53	26,40	2,57	34,23	$^{5,08}$	$86,\!62$	$^{3,35}$
$LBP_{8,2}^{riu2}$	$16,\!49$	$17,\!57$	17,06	$17,\!33$	26,33	15,21	66,73	$21,\!30$
GLCM	4,09	$1,\!13$	4,64	1,32	24,70	10,55	71,51	$^{8,65}$
Combinações	90,71	$2,\!45$	$91,\!31$	1,85	93,12	$1,\!13$	98,91	0,39
KNORA-E	88,30	$^{3,73}$	88,88	$^{3,12}$	90,87	2,16	98,10	0,57
KNORA-U	88,38	$1,\!69$	88,54	$1,\!66$	$91,\!62$	1,62	99, 13	0,32
OLA	86, 19	1,76	$87,\!05$	1,36	89,28	$2,\!48$	98,01	$0,\!60$
LCA	84,86	2,56	85,73	1,89	88,94	1,78	98,26	$0,\!45$
MCB OLA	84,36	2,52	$85,\!05$	1,89	$87,\!84$	$1,\!18$	98,02	$0,\!88$
MCB LCA	86,27	1,77	$86,\!62$	$1,\!62$	88,98	2,34	98,87	$0,\!57$
a priori	90,28	$1,\!69$	$90,\!62$	$1,\!44$	92,49	$0,\!49$	$98,\!84$	$0,\!54$
a posteriori	92,86	2,29	93,11	2,14	$94,\!61$	0,97	98,79	0,50
MCB a priori	86,78	2,09	$87,\!54$	1,47	$90,\!61$	1,06	98,48	0,34
MCB a posteriori	93,03	1,36	93,30	1,24	94,73	$0,\!42$	$98,\!80$	$0,\!60$

**Tabela 5.22:** Taxas de reconhecimento para os níveis definidos pela Botânica espécie, gênero, família e filo com, respectivamente, 112, 85, 30 e 2 classes 'reais'.

# 5.4.2 Uso de meta-classes para a abordagem de classificação hierárquica

A partir dos procedimentos definidos na Seção 4.6.2, obteve-se os resultados apresentados na Tabela 5.23 para os classificadores LPQ, SIFT e SURF. A linha identificada com a meta-classe '*Filos*' contém as taxas de reconhecimento obtidas pelos modelos de classificação construídos para diferenciar Gimnospermas de Angiospermas. Já nas linhas '*Gimnospermas*' e '*Angiospermas*' tem-se os resultados obtidos pelos modelos de classificação construídos, respectivamente, para a diferenciação das espécies florestais pertencentes a cada um destes grupos.

A penúltima linha da Tabela 5.23 combina os resultados obtidos em cada um dos níveis por meio da intersecção dos acertos. Ou seja, acertos foram contabilizados apenas quando os classificadores realizaram as predições corretas em ambos os níveis. Comparando tais resultados com aqueles obtidos pela classificação direta no nível espécies (com 112 classes 'reais'), apresentados na última linha da Tabela 5.23, verificou-se que tal abordagem não contribuiu para a melhoria das taxas de reconhecimento. Além disso, tanto os resultados da seção anterior quanto estes demonstram que a maioria dos erros ocorre internamente aos próprios filos.

**Tabela 5.23:** Comparação dos resultados obtidos pelos modelos de classificação construídos para distinguir as 112 espécies florestais e do processo de classificação hierárquica seguindo os níveis definidos pela Botânica.

						Cla	ssifica	ldor				
			$\boxed{ \mathbf{LPQ}_{r11}}$			SIFT				SURF		
#	Meta-Classes	%	$\sigma$	AUC		%	$\sigma$	AUC	%	$\sigma$	AUC	
2	Filos	$97,\!16$	0,16	83,40		96,75	$0,\!16$	$86,\!35$	96,93	0,16	87,21	
37	Gimnospermas	$86,\!06$	$2,\!86$	$84,\!56$		$87,\!40$	$5,\!60$	$84,\!94$	90,14	$3,\!86$	$86,\!46$	
75	Angiospermas	$86,\!93$	$4,\!33$	$82,\!24$		$89,\!53$	2,77	87,76	$91,\!20$	3,70	$87,\!96$	
112	Clas. 2 Níveis	$86,\!05$	0,97	$81,\!99$		88,26	$0,\!97$	85,71	89,01	$0,\!97$	86,88	
112	Clas. 1 Nivel	86,74	2,07	80,39		88,47	1,64	85,44	89,14	$2,\!39$	$85,\!17$	

### 5.5 Análise dos Erros de Classificação

Dados os resultados anteriores para o nível das espécies florestais, esta seção apresenta considerações quanto aos erros de classificação. As imagens da Figura 5.25 ilustram três classes e suas características texturais, enquanto a Tabela 5.24 apresenta as taxas de erros dos classificadores e das alternativas testadas para seleção dinâmica de classificadores.

Estes exemplos representam casos extremos da base de imagens utilizada, mas não são únicos. As Figuras 5.25(a) e (c) mostram exemplos com as caracterizações bem definidas de suas espécies, as quais são comprovadas por meio das taxas de erros de classificação por espécie (Tabela 5.24). No extremo oposto, a espécie ilustrada na Figura 5.25(b) mostra características das duas anteriores, o que dificulta sua diferenciação das demais espécies. Esta dificuldade é refletida nas taxas de erros de classificação de suas imagens, cujos menores valores foram apresentados pelo classificador LPQ (37,5%) e pelos métodos de seleção dinâmica de classificadores KNORA-E e KNORA-U (27,5%).

Os resultados da Tabela 5.24 também permitem avaliar a acurácia individual dos classificadores. Aqueles construídos com características extraídas com filtros de Gabor,  $LBP_{8,2}^{riu2}$ e GLCM apresentaram dificuldades na diferenciação das espécies florestais, mesmo daquelas melhor definidas em termos de padrões texturais. As colunas 'Conf' da Tabela 5.24 definem a distribuição dos erros de classificação interna e/ou externamente ao filo à que as espécies pertencem. Assim como nos experimentos da Seção 5.4, a análise desta distribuição confirmou que a maioria das confusões ocorre internamente aos filos a que cada espécie pertence.



**Figura 5.25:** Exemplos de erros de classificação ocorridos por espécies florestais: (a) *Pinus caribaea*; (b) *Tibouchiana sellowiana*; (c) *Erisma uncinatum*.

**Tabela 5.24:** Síntese dos erros de classificação ocorridos para as espécies florestais da Figura 5.25.

Classificador /			Esp	écies		
Método de	(a)		()	b)	(	c)
Seleção	%	Conf	%	Conf	%	Conf
SURF			40,0			
MSER-SURF			47,5			
SIFT			47,5			
LPQ			$37,\!5$			
LPQ-TOP			42,5			
$LBP_{8,2}^{u2}$			67,5		$^{32,5}$	
$LBP_{8,2}^{ri}$	25,0		90,0		$57,\!5$	
Gabor	$^{32,5}$		100,0		92,5	
$LBP_{8,2}^{riu2}$	100,0	ie	95,0	ie	100,0	e
GLCM	100,0		100,0	ie	100,0	
KNORA-E			$27,\!5$			
KNORA-U	20,0		$27,\!5$		$^{7,0}$	
OLA			50,0			
LCA			45,0			
MCB OLA	$^{2,5}$		47,5			
MCB LCA			50,0			
a priori	$^{2,5}$		47,5			
$a \ posteriori$			40,0			
MCB a priori			37,5			
MCB a posteriori			32,5			

Espaços em branco na coluna % identificam que todas as amostras da classe foram classificadas corretamente, isto é, 0% de erros. Distribução dos erros (Conf):

(*i*) identifica que a maioria das confusões de classificação ocorre com espécies internas ao próprio filo, tendo sido suprimida desta tabela.

( e ) identifica que a maioria das confusões de classificação ocorre com espécies externas ao próprio filo.

(ie) identifica confusões de classificação relativamente bem distribuídas entre as espécies de ambos os filos.

#### 5.6 Considerações Finais

Neste capítulo foram apresentados os resultados dos experimentos descritos no Capítulo 4. Estes permitiram a identificação dos potenciais dos classificadores de forma individual, da combinação de conjuntos de classificadores e da seleção dinâmica de classificadores no espaço de dissimilaridade.

A partir de tais resultados, o modelo de classificação proposto foi validado por meio da aplicação de diferentes métodos de seleção dinâmica de classificadores. Neste contexto, identificou-se a superioridade dos métodos de seleção dinâmica de classificadores sobre as demais estratégias avaliadas, sendo que os métodos propostos alcançaram taxas de reconhecimento equivalentes ou superiores aos demais para todos os tamanhos de vizinhança avaliados.

Para a combinação de classificadores, verificou-se taxas de reconhecimento superiores para as regras de fusão máximo e média com relação às demais regras de fusão testadas, com grande vantagem para a primeira. Destaca-se que tais diferenças ocorreram tanto na combinação dos subconjuntos de classificadores utilizados para todas as instâncias questionadas quanto na combinação dos classificadores dinamicamente selecionados.

Conforme esperado, a avaliação das taxas de reconhecimento nos diferentes níveis definidos pela Botânica possibilitou a melhoria dos resultados à medida em que se desloca do nível espécie para o nível filo. Neste contexto, por meio das duas estratégias empregadas e da análise dos erros de classificação, identificou-se que a maior parte dos erros de classificação encontra-se no nível filo, o que confirma as asserções de vários autores quanto a este aspecto e ao elevado nível de semelhanças das espécies pertencentes a cada filo. Ainda quanto a esta avaliação, verificou-se que a classificação no nível filo deveria ocorrer apenas por meio do classificador SURF, tanto por suas taxas serem equivalentes àquelas obtidas com o método KNORA-U quanto pela eliminação dos custos inerentes aos métodos de seleção e/ou combinação de classificadores.

## CAPÍTULO 6

## CONSIDERAÇÕES FINAIS

O presente capítulo apresenta uma breve avaliação dos resultados alcançados, tendo como base a motivação, os desafios, os objetivos e as contribuições deste trabalho, tal como identificado no Capítulo 1. Adicionalmente, são apresentadas sugestões para a realização de trabalhos futuros, numa tentativa de complementar o presente trabalho e responder questões que surgiram durante seu desenvolvimento, mas não estavam compreendidas em seu escopo.

#### 6.1 Discussão

Além dos resultados apresentados no Capítulo 5, experimentos exploratórios foram realizados e publicados durante o desenvolvimento deste trabalho. No primeiro, apresentou-se um conjunto compacto de características estruturais para diferenciar as espécies florestais dos filos Angiospermas e Gimnospermas. Tal conjunto era composto por apenas cinco elementos baseados em estatísticas das estruturas dos principais componentes conexos das imagens [86]. Também avaliou-se o uso de descritores de textura extraídos de GLCM [84]. A base de imagens utilizada em todos os experimentos foi publicada em [85]. Nos trabalhos [17] e [87] avaliou-se estratégias para a combinação de descritores texturais para o reconhecimento de espécies florestais. Nos dois últimos, as combinações avaliadas ocorreram tanto por meio da concatenação dos vetores de características quanto da aplicação de regras de fusão aos resultados individuais dos classificadores.

Com relação à questão principal deste trabalho, concluiu-se pela viabilidade quanto à construção de um **sistema robusto para classificação de espécies florestais** utilizando características texturais presentes nas imagens microscópicas de madeira, a representação no espaço de dissimilaridade e sistemas compostos por múltiplos classificadores. É importante destacar que não foram encontradas referências quanto à seleção dinâmica de classificadores no espaço de dissimilaridade na literatura, o que faz desta abordagem um importante diferencial para o presente trabalho. A viabilidade da proposta foi comprovada pelos resultados apresentados no Capítulo 5, os quais são superiores àqueles obtidos nos primeiros experimentos exploratórios sob a abordagem da classificação tradicional e publicados em [17, 84, 85, 86, 87], além de outros trabalhos desenvolvidos com o foco em reconhecimento de espécies florestais [109]. Comparando os resultados apresentados no Capítulo 3 (Tabela 3.1) e no Capítulo 5 (Tabela 5.22), verificou-se a equivalência ou superioridade daqueles alcançados neste trabalho com relação aos identificados na literatura. Destaca-se o número de espécies florestais utilizadas, o qual é pelo menos cinco vezes maior que o máximo identificado na Tabela 3.1, e a possibilidade dos classificadores construídos no espaço de dissimilaridade poderem ser empregados para rotular amostras pertencentes a classes que não estavam presentes durante seu treinamento.

Ao se considerar as taxas alcançadas individualmente e as questões secundárias, verificouse que as representações baseadas em pontos de atenção mostraram-se superiores para a **descrição das características texturais** presentes nas imagens microscópicas de madeira. Como apresentado na Figura 2.2, a grande variação nos tipos e frequência de células provê padrões texturais distintos. Tais padrões também influenciam na quantidade de pontos de máximos e mínimos existentes nas imagens em níveis de cinza e que caracterizam as divisões das células (Tabela 5.6). Esta diversidade em termos de padrões texturais e quantidade de pontos de máximos e mínimos garante também a diversidade de características necessárias para garantir a diferenciação das espécies florestais. A avaliação dos algoritmos de detecção de pontos de interesse comprovou sua efetividade enquanto que a utilização de pontos definidos aleatoriamente na imagem não provêem os mesmos resultados ou o fazem com custos computacionais maiores em decorrência da elevada quantidade de pontos necessários.

Tomando o fato da existência de um elevado número de espécies florestais, o qual chega à casa de milhares, e o reduzido número de amostras por espécie, comprovou-se também para este problema a garantia de independência entre as classes empregadas nos conjuntos de treinamento e teste. Assim, para os classificadores construídos no espaço de dissimilaridade, verificou-se possíveis influências da quantidade de classes, amostras por classe e referências por amostra no processo de classificação. Com o objetivo de avaliar a influência da quantidade de classes na construção dos modelos, foram utilizadas 60% das espécies florestais disponíveis para gerar os conjuntos de treinamento, num total de 68 espécies. Ao final das avaliações, identificou-se a necessidade de se empregar as 68 espécies para garantir a maximização das taxas de reconhecimento. Ao se considerar a quantidade de classes empregadas na geração dos conjuntos de teste, identificou-se queda das taxas à medida em que o número de espécies florestais candidatas aumentava. Embora esperava-se que estas taxas estabilizassem para conjuntos maiores de classes, não foi possível comprovar tal fato por ter atingido o limite de espécies florestais disponíveis para a geração do conjunto de testes. Contudo, os valores similares para o desvio padrão demonstram a estabilidade do modelo proposto.

Ao se empregar os MCSs no processo de classificação, identificou-se ganhos reais com relação às taxas de reconhecimento. A partir dos melhores resultados individuais obtidos para o classificador SURF, com taxas de reconhecimento de 89,14%, alcançou-se 90,71% e 93,03% para a combinação de agrupamentos de classificadores e a seleção de um único classificador, respectivamente. Destaca-se, neste contexto, as vantagens advindas da melhoria das taxas de reconhecimento em quase quatro pontos percentuais. No entanto, agrega-se também as desvantagens inerentes à complexidade e aos custos computacionais decorrentes da necessidade de um conjunto maior de classificadores e do processo de seleção e/ou combinação de classificadores. Sob o contexto dos MCSs, além do modelo de classificação, **três novos métodos para seleção dinâmica de classificadores** foram apresentados e validados. Os novos métodos apresentaram resultados (Tabela 5.19) equivalentes ou superiores àqueles propostos por Woods *et al.* [146], Giacinto e Roli [33] e Ko *et al.* [64, 65], ao se considerar suas caracterizações quanto aos critérios para definição da vizinhança, delimitação da vizinhança e seleção do classificador. Além disso, os métodos propostos e validados no espaço de dissimilaridade também podem ser aplicados para a seleção dinâmica de classificadores no espaço de características, sem a necessidade de qualquer alteração. Também o modelo proposto pode ser utilizado em diferentes domínios de aplicação cuja solução envolva MCSs, com a representação e seleção dos classificadores no espaço de dissimilaridade.

Outra importante questão tratada neste trabalho foi a **avaliação das taxas de** reconhecimento do sistema nos níveis filo, família, gênero e espécie, definidos pela Botânica. Tal estratégia justifica-se pelo elevado número de espécies florestais existentes, pela complexidade imposta pela distinção de espécies muito próximas na hierarquia de níveis definidos pela Botânica e por, algumas vezes, não haver necessidade de se realizar a classificação a nível de espécies. Ao final, concluiu-se que a maior parte dos erros de classificação está compreendida internamente a cada filo. Concluiu-se ainda que, diante da necessidade de classificação no nível filo, a melhor alternativa constitui apenas no uso do classificador SURF devido ao custo e complexidade adicionais ao se trabalhar com os 10 classificadores e métodos para seleção e/ou combinação de classificadores.

A dificuldade de acesso às bases existentes impôs a construção de uma base de imagens própria para o desenvolvimento de pesquisas em classificação de espécies florestais. Esta é também uma importante contribuição deste trabalho, dado que possui número e variedade de espécies muito superior a qualquer outra encontrada na literatura da área, sendo a única com imagens microscópicas que se tem conhecimento. Publicada em [85], a base de imagens pode ser requisitada para o desenvolvimento de pesquisas no endereço eletrônico http://web.inf.ufpr.br/vri/forest-species-database. Destaca-se ainda uma contribuição no contexto social, com a identificação da espécie florestal, independente de fatores que se perdem com o decorrer do tempo, tais como folhas, frutos, casca, cor e odor, dentre outros. Também, sob o contexto tecnológico, a principal contribuição constitui a criação de um sistema robusto para a classificação de espécies florestais. Este sistema compreende a descrição apresentada no Capítulo 4, tendo sido validado pelos experimentos descritos também no Capítulo 4 e seus resultados no Capítulo 5. Sua implantação, por parte de qualquer empresa que comercialize madeiras ou mesmo agências fiscalizadoras, depende apenas da aquisição dos equipamentos e observação dos procedimentos descritos no Apêndice A. Além destas observações, sugere-se uma pessoa treinada para garantir que os procedimentos sejam seguidos corretamente. Enfatiza-se ainda que as peças a serem analisadas, geralmente, possuem dimensões que permitem a identificação dos eixos ilustrados na Figura 2.3(a). Assim, também não haveria a necessidade de um especialista em Anatomia da Madeira para realizar a coleta das amostras.

## 6.2 Trabalhos Futuros

Durante o desenvolvimento do presente trabalho surgiram questões que, embora importantes para o problema, não foram abordadas por não estarem compreendidas em seu escopo.

Diante da falta de conhecimento de outros trabalhos com imagens microscópicas e também da proximidade dos resultados apresentados com aqueles obtidos com imagens macroscópicas, uma possível estratégia poderia combinar abordagens com a aplicação de imagens macroscópicas e microscópicas no processo de reconhecimento, o que permitiria avaliar os níveis de complementaridade das informações obtidas sob estas diferentes perspectivas.

Durante os experimentos, diferentes subconjuntos de espécies florestais foram considerados na avaliação da robustez dos modelos de classificação, sempre respeitando a proporção das espécies existentes nos filos Gimnospermas e Angiospermas. No entanto, nenhuma avaliação foi realizada quanto às semelhanças e diferenças entre as espécies. Neste sentido, surge a questão: "Quais as espécies adequadas para a construção dos modelos de classificação, considerando a variação da madeira em cada espécie florestal e entre as espécies?". Para identificar as espécies florestais mais adequadas para a construção de um modelo mais robusto baseado em dissimilaridade poder-se-ia empregar técnicas bio-inspiradas como Otimização de Agrupamentos de Partículas (*Particle Swarm Optimization*) ou Algoritmos Genéticos.

A questão anterior também poderia sanar o problema inerente ao número de espécies florestais utilizadas para gerar os conjuntos de treinamento e teste. No primeiro caso, basicamente foi necessário utilizar as 68 espécies disponíveis para maximizar as taxas de reconhecimento. Mesmo com o reduzido número de espécies utilizado na geração dos conjuntos de testes, modelos criados com subconjuntos de espécies mais adequadas poderiam garantir maior estabilidade às taxas de reconhecimento.

Diante da impossibilidade de se otimizar os subconjuntos utilizados na geração dos conjuntos de treinamento e teste, ainda ter-se-ia a ampliação da base de imagens, tanto em número de espécies florestais quanto de amostras por espécie. Mesmo diante de sua amplitude quando comparada com outras bases disponíveis, o total de 112 espécies florestais representa uma amostra muito reduzida com relação às milhares de espécies existentes. Embora esta questão esteja relacionada às duas questões anteriores, a mesma caracteriza um ponto passível de investigação independente dos resultados obtidos para as demais.

Outra possibilidade de investigação relaciona-se à seleção de atributos. Neste ponto, tem-se claro que muitas vezes alguns elementos que compõem os vetores de características gerados por um descritor não contribuem para a melhoria das taxas de reconhecimento. Além dos fato de que tais elementos possam afetar negativamente os resultados, há a certeza do custo computacional adicional se estes forem mantidos.

## REFERÊNCIAS

- T. Ahonen, J. Matas, C. He, e M. Pietikäinen. Rotation invariant image description with local binary pattern histogram fourier features. *Computer Science*, 5575(3):61– 70, 2009.
- [2] D. S. Amorim. Fundamentos de Sistemática Filogenética. Holos, Ribeirão Preto, 2002.
- [3] M. R. Banham e A. K. Katsaggelos. Digital image restoration. Signal Processing Magazine, IEEE, 14(2):24–41, 1997.
- [4] J. A. Barker. A Prototype Interative Identification Tool to Fragmentary Wood From Eastern Central Australia, and its Application to Aboriginal Australian Ethnographic Artefacts. Tese de Doutorado, School of Earth and Environmental Sciences, Adelaide University, 2005.
- [5] H. Bay, A. Ess, T. Tuytelaars, e L. Van Gool. Speeded-up robust features (surf). Comput. Vis. Image Underst., 110(3):346–359, 2008.
- [6] H. Bay, T. Tuytelaars, e L. Van Gool. Surf: Speeded up robust features. In ECCV, páginas 404–417, 2006.
- [7] D. Bertolini, L. S. Oliveira, E. Justino, e R. Sabourin. Reducing forgeries in writerindependent off-line signature verification through ensemble of classifiers. *Pattern Recognition*, 43:387–396, 2010.
- [8] D. Black. The Theory of Committees and Elections. Cambridge University Press, London, 2 edition, 1958.
- [9] G. Bradski. The opency library. Dr. Dobb's Journal of Software Tools, 2000.
- [10] L. Breiman. Bagging predictors. Machine Learning, 24(2):123–140, 1996.
- [11] P. Brodatz. Textures: A Photographic Album for Artists and Designers. Dover Publications, 1999.
- [12] C. C. Brunner, A. G. Maristany, e D. A. Butler. Wood species identification using spectral reflectance. *Forest Products Journal*, 46(2):82–85, 1996.
- [13] D. N. Buechler e D. K. Misra. Subsurface detection of small voids in low-loss solids. First ISA/IEEE Conference Sensor for Industry, páginas 281–284, 2001.
- [14] L. M. Burger e H. G. Richter. Anatomia da Madeira. Nobel, São Paulo, 1991.

- [15] D. A. Butler, C. C. Brunner, e J. W. Funck. Wood-surface feature classification using extended-color information. *Holz als Roh- und Werkstoff*, 59(6):475–482, 2001.
- [16] A. CaronDecloquement. Extractives from Sitka spruce. Tese de Doutorado, Department of Chemistry, University of Glasgow, 2010.
- [17] P. R. Cavalin, M. N. Kapp, J. Martins, e L. E. S. Oliveira. A multiple feature vector framework for forest species recognition. *Proceedings of the 28th Annual* ACM Symposium on Applied Computing, SAC '13, páginas 16–20, New York, NY, USA, 2013.
- [18] C-C. Chang e C-J. Lin. Libsvm: A library for support vector machines. ACM Transactions on Intelligent Systems and Technology, 2:1–27, 2011.
- [19] R. I. Chaplin, R. M. Hodgson, e S. Gunetileke. Automatic wane detection in the images of planks using a neural network. *Fifth International Symposium on Signal Processing and its Applications*, 2:657–659, 1999.
- [20] L. Chen e J. Gasteiger. Knowledge discovery in reaction databases: Landscaping organic reactions by a self-organizing neural network. *Journal of the American Chemical Society*, 119(17):4033–4042, 1997.
- [21] A. Conci, E. Azevedo, e F. R. Leta. Computação Gráfica: teoria e prática, volume 2. Elsevier, Rio de Janeiro, 2008.
- [22] R. W. Conners, D. E. Kline, P. A. Araman, e T. H. Drayer. Machine vision technology for the forest products industry. *Computer*, 30(7):43–48, 1997.
- [23] D. L. Davies e D. W. Bouldin. A cluster separation measure. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 1(2):224–227, 1979.
- [24] T. G. Dietterich. Ensemble methods in machine learning. Proceedings of the First International Workshop on Multiple Classifier Systems, MCS '00, páginas 1–15, London, UK, 2000. Springer-Verlag.
- [25] R. O. Duda, P. E. Hart, e D. G. Stork. *Pattern classification*. John Wiley & Sons, Inc., New York, 2 edition, 2001.
- [26] R. P. W. Duin e E. Pekalska. The dissimilarity space: bridging structural and statistical pattern recognition. *Pattern Recognition Letters*, 33(7):826–832, 2012.
- [27] R. P. W. Duin, E. Pekalska, P. Paclík, e D. M. J. Tax. The dissimilarity representation, a basis for a domain-based pattern recognition? *Pattern representation and* the future of pattern recognition, a program for action, páginas 43–56, 2004.
- [28] G. Eskander, R. Sabourin, e E. Granger. On the dissimilarity representation and prototype selection for signature-based bio-cryptographic systems. E. Hancock e M. Pelillo, editors, *Similarity-Based Pattern Recognition*, volume 7953 of *Lecture Notes in Computer Science*, páginas 265–280. Springer Berlin Heidelberg, 2013.
- [29] G. S. Eskander, R. Sabourin, e E. Granger. A bio-cryptographic system based on offline signature images. *Information Sciences*, 259:170–191, 2014.
- [30] P. A. Estevez, M. Fernandez, R. J. Alcock, e M. S. Packianather. Selection of features for the classification of wood board defects. *Ninth International Conference* on Artificial Neural Networks, 1:347–352, 1999.
- [31] T. Fawcett. An introduction to roc analysis. Pattern Recognition Letters, 27:861– 874, 2006.
- [32] P.-E. Forssen e D.G. Lowe. Shape descriptors for maximally stable extremal regions. Computer Vision, 2007. ICCV 2007. IEEE 11th International Conference on, páginas 1–8, 2007.
- [33] G. Giacinto e F. Roli. Adaptive selection of image classifiers. Alberto Bimbo, editor, Image Analysis and Processing, volume 1310 of Lecture Notes in Computer Science, páginas 38–45. Springer Berlin Heidelberg, 1997.
- [34] G. Giacinto e F. Roli. Ensembles of neural networks for soft classification of remotesensing images. Proc. of the European Symposium on Intelligent Techniques, páginas 166–170, 1997.
- [35] G. Giacinto e F. Roli. Methods for dynamic classifier selection. Proceedings of the 10th International Conference on Image Analysis and Processing, ICIAP '99, páginas 659–665, Washington, DC, USA, 1999. IEEE Computer Society.
- [36] G. Giacinto e F. Roli. Dynamic classifier selection based on multiple classifier behaviour. *Pattern Recognition*, 34:1879–1881, 2001.
- [37] G. Giacinto, F. Roli, e G. Fumera. Selection of image classifiers. *Electronics Letters*, 36(5):420–422, 2000.
- [38] L. Goldfarb. What is distance and why do we need the metric model for pattern learning? *Pattern Recognition*, 25(4):431–438, 1992.
- [39] R. C. Gonzalez e R. E. Woods. *Digital Image Processing*. Prentice Hall, New Jersey, 3 edition, 2008.
- [40] S. E. Grigorescu, N. Petkov, e P. Kruizinga. Comparison of texture features based on gabor filters. *IEEE Transactions on Image Processing*, 11(10):1160–1167, 2002.

- [41] O. Hagman. Multivariate prediction of wood surface features using an imaging spectrograph. *Holz als Roh- und Werkstoff*, 55(6):377–382, 1997.
- [42] S. Haker, W. M. Wells III, S. K. Warfield, I-F. Talos, J. G. Bhagwat, D. Goldberg-Zimring, A. Mian, L. Ohno-Machado, e K. H. Zou. *Combining Classifiers using their Receiver Operating Characteristics and Maximum Likelihood Estimation*, capítulo Part I, páginas 506–514. Springer-Verlag, Berlin Heidelberg - Germany, 2005.
- [43] R. Hanusiak, L. Oliveira, E. Justino, e R. Sabourin. Writer verification using texture-based features. International Journal on Document Analysis and Recognition, páginas 1–14, 2011.
- [44] R. M. Haralick. Statistical and structural approaches to texture. 67(5):786–804, 1979.
- [45] R. M. Haralick, K. Shanmugam, e I. Dinstein. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6):610–621, 1973.
- [46] J. Heikkila, V. Ojansivu, e E. Rahtu. Improved blur insensitivity for decorrelated local phase quantization. *Pattern Recognition (ICPR)*, 2010 20th International Conference on, páginas 818–821, 2010.
- [47] T. K. Ho. The random subspace method for constructing decision forests. 20(8):832– 844, 1998.
- [48] T. K. Ho, J. J. Hull, e S. N. Srihari. Decision combination in multiple classifier systems. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16(1):66–75, 1994.
- [49] R. B. Hoadley. Identifying Wood: accurate results with simple tools. Taunton Press, Newtown, CT, 1990.
- [50] R. B. Hoadley. Understanding wood: a craftsman's guide to wood technology. Taunton Press, Newtown, CT, 2000.
- [51] Y. S. Huang, K. Liu, e C. Y. Suen. The combination of multiple classifiers by a neural network approach. International Journal of Pattern Recognition and Artificial Intelligence, 9(3):579–597, 1995.
- [52] Y.S. Huang e C.Y. Suen. A method of combining multiple experts for the recognition of unconstrained handwritten numerals. *Pattern Analysis and Machine Intelligence*, *IEEE Transactions on*, 17(1):90–94, 1995.
- [53] H. A. Huber. Economics of cutting hardwood lumber by two different methods. Dissertação de Mestrado, University of Michigan, Michigan, 1969.

- [54] H. A. Huber. A computerized economic comparison of a conventional furniture rough mill with a new system of processing. *Forest Products Journal*, 21(2):34–39, 1971.
- [55] K. Ioannou, D. Birbilis, e P. Lefakis. A pilot prototype decision support system for recognition of greek forest species. *Operational Research*, 3(9):141–152, 2009.
- [56] A. K. Jain, R. P. W. Duin, e J. Mao. Statistical pattern recognition: a review. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 22(1):4–37, 2000.
- [57] A. K. Jain, A. Ross, e S. Pankanti. Biometrics: A tool for information security. *IEEE Transactions on Information Forensics and Security*, 1(2):125–143, 2006.
- [58] H. Kauppinen. A two stage defect recognition method for parquet slab grading. 15th International Conference on Pattern Recognition (ICPR'00), 4:803–806, 2000.
- [59] M. Khalid, E. L. Y. Lee, R. Yusof, e M. Nadaraj. Design of an intelligent wood species recognition system. International Journal of Simulation Systems, Science & Technology Special Issue on: Artificial Intelligence, páginas 9–17, 2008.
- [60] W. Khreich. Towards Adaptive Anomaly Detection Systems using Boolean Combination of Hidden Markov Models. Tese de Doutorado, École de Technologie Supérieure, Université du Québec, Montreal, 2011.
- [61] W. Khreich, E. Granger, A. Miri, e R. Sabourin. Iterative boolean combination of classifiers in the roc space: An application to anomaly detection with hmms. *Pattern Recognition*, 43(8):2732–2752, 2010.
- [62] J. Kittler, M. Hatef, R. P. W. Duin, e J. Matas. On combining classifiers. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 20:226–239, 1998.
- [63] A. H. R. Ko, R. Sabourin, A. Britto, e L. S. Oliveira. Pairwise fusion matrix for combining classifiers. *Pattern Recognition*, 40(8):2198–2210, 2007.
- [64] A. H. R. Ko, R. Sabourin, e A. S. Britto, Jr. From dynamic classifier selection to dynamic ensemble selection. *Pattern Recognition*, 41:1718–1731, 2008.
- [65] A. H. R. Ko, R. Sabourin, e A. de Souza Britto. K-nearest oracle for dynamic ensemble selection. *Document Analysis and Recognition*, 2007. ICDAR 2007. Ninth International Conference on, volume 1, páginas 422–426, 2007.
- [66] L. I. Kuncheva. Combining Pattern Classifiers: Methods and Algorithms. Wiley-Interscience, 2004.

- [67] R. D. Labati, M. Gamassi, V. Piuri, e F. Scotti. A low-cost neural-based approach for wood types classification. *Computational Intelligence for Measurement Systems* and Applications, 2009. CIMSA '09. IEEE International Conference on, páginas 199–203, 2009.
- [68] Forest Products Laboratory. Wood Handbook: wood as an engineering material. General Technical Report FPL-GTR-190. Department of Agriculture, Forest Service, Forest Products Laboratory, Madison, WI: U.S., 2010.
- [69] M. Lades, J. C. Vorbrüggen, J. Buhmann, J. Lange, C. von der Malsburg, R. P. Würtz, e W. Konen. Distortion invariant object recognition in the dynamic link architecture. *IEEE Transactions on Computers*, 42(3):300–311, 1993.
- [70] M. Lambers e C. Veenman. Forensic authorship attribution using compression distances to prototypes. Z. Geradts, K. Franke, e C. Veenman, editors, *Computational Forensics*, volume 5718 of *Lecture Notes in Computer Science*, páginas 13–24. Springer Berlin Heidelberg, 2009.
- [71] B. K. Lavine, C. E. Davidson, A. J. Moores, e P. R. Griffiths. Raman spectroscopy and genetic algorithms for the classification of wood types. *Applied Spectroscopy*, 55(8):960–966, 2001.
- [72] P. K. Lebow, C. C. Brunner, A. G. Maristany, e D. A. Butler. Classification of wood surface features by spectral reflectance. Wood and Fiber Science, 28(1):74–90, 1996.
- [73] I. R. Lewis, N. W. Daniel Jr, N. C. Chaffin, e P. R. Griffiths. Raman spectrometry and neural networks for the classification of wood types - 1. Spectrochimica Acta Part A: Molecular Spectroscopy, 50(11):1943–1958, 1994.
- [74] M-X. Li, C-D. Wu, e Y. Yue. Automatic visual inspection and classification based on rough sets and neural network. *International Conference on Machine Learning* and Cybernetics, 2, páginas 3095–3099, 2003.
- [75] D. G. Lowe. Object recognition from local scale-invariant features. Proceedings of the International Conference on Computer Vision, volume 2 of ICCV '99, páginas 1150-, Washington, DC, USA, 1999. IEEE Computer Society.
- [76] D. G. Lowe. Distinctive image features from scale-invariant keypoints. International Journal of Computer Vision, 60(2):91–110, 2004.
- [77] G. A. P. Lópes. Aforapro: reconhecimento de objetos invariante sob transformações afins. Dissertação de Mestrado, Escola Politécnica da Universidade de São Paulo, São Paulo, 2011.

- [78] D. M. Lyons e D. F. Hsu. Combining multiple scoring systems for target tracking using rank-score characteristics. *Information Fusion*, 10, páginas 124–136, 2009.
- [79] T. Maenpää e M. Pietikäinen. Texture Analysis with Local Binary Patterns, capítulo 2.6, páginas 197–216. World Scientific, Singapore, 3 edition, 2005.
- [80] S. G. Mallat. A theory for multiresolution signal decomposition: the wavelet representation. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 11(7):674–693, 1989.
- [81] J. N. C. Marchiori. Dendrologia das Gimnospermas. Editora da UFSM, Santa Maria - RS, 1996.
- [82] J. N. C. Marchiori. Dendrologia das Angiospermas: das magnoliáceas às flacurtiáceas. Editora da UFSM, Santa Maria - RS, 1997.
- [83] C. Marrocco, M. Molinara, e F. Tortorella. On linear combinations of dichotomizers for maximizing the area under the roc curve. Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on, 41(3):610–620, 2011.
- [84] J. G. Martins, Y. M. G. Costa, D. B. Gonçalves, e L. E. S. Oliveira. Uso de descritores de textura extraídos de glcm para o reconhecimento de padrões em diferentes domínios de aplicação. XXXVII Conferencia Latinoamericana de Informática, páginas 637–652, 2011.
- [85] J. G. Martins, L. E. S. Oliveira, S. Nisgoski, e R. Sabourin. A database for automatic classification of forest species. *Machine Vision and Applications*, páginas 1–12, 2012.
- [86] J. G. Martins, L. E. S. Oliveira, P. L. Paula Filho, e S. Nisgoski. Classificação automática de grupos de espécies florestais. VII Workshop de Visão Computacional, páginas 28–33, 2011.
- [87] J. G. Martins, L.S. Oliveira, e R. Sabourin. Combining textural descriptors for forest species recognition. *IECON 2012 - 38th Annual Conference on IEEE Industrial Electronics Society*, páginas 1483–1488, 2012.
- [88] J. Matas, O. Chum, U. Martin, e T. Pajdla. Robust wide baseline stereo from maximally stable extremal regions. Proc. of the British Machine Vision Conference, 1:384–393, 2002.
- [89] MATLAB. version 7.14 (R2012a). The MathWorks Inc., Natick, Massachusetts, 2012.
- [90] T. Mäenpää, T. Ojala, M Pietikäinen, e M. Soriano. Robust texture classification by subsets of local binary patterns. 15th International Conference on Pattern Recognition, páginas 947–950, 2000.

- [91] P. Mishra, R. Chatterjee, e V. Mahapatra. Texture Segmentation Using Gabor Filters and Wavelets. Tese de Doutorado, Department of Computer Science and Engineering, National Institute of Technology, Deemed University, Rourkela, Índia, 2010.
- [92] G. Müller, C. Schöpper, H. Vos, A. Kharazipour, e A. Polle. Ftir-atr spectroscopic analyses of changes in wood properties during particle- and fibreboard production of hard- and softwood trees. *BioResources*, 4(1):49–71, 2009.
- [93] J. Moody e P. Klinkhachorn. Automated lumber processing system (alps): an industrial prototype. *Thirtieth Southeastern Symposium on System Theory*, páginas 476–479, 1998.
- [94] J. P. R. do Nascimento. Análise e classificação de imagens baseadas em características de textura utilizando matrizes de co-ocorrência. Dissertação de Mestrado, Programa de Pós-Graduação em Informática, Universidade Federal do Paraná (UFPR), Curitiba, 2003.
- [95] M. Nasirzadeh, A. A. Khazael, e M. B Khalid. Woods recognition system based on local binary pattern. Second International Conference on Computational Intelligence, Communication Systems and Networks, páginas 308–313, 2010.
- [96] J. R. Nault. Differentiation of some Canadian coniferous woods by combined diffuse and specular reflectance Fourier transform infrared spectroscopy. Tese de Doutorado, Departament of Forestry, The University of British Columbia, 1989.
- [97] J. R. Nault e J. F. Manville. Differentiation of some canadian coniferous woods by combined diffuse and specular reflectance fourier transform infrared spectroscopy. *Wood and Fiber Science*, 24(4):424–431, 1992.
- [98] J. R. Nault e J. F. Manville. Species differentiation of two common lumber mixes by diffuse reflectance fourier transform infrared (drift) spectroscopy. Wood and Fiber Science, 29(1):2–9, 1997.
- [99] D. Nilsson. Prediction of Wood Species and Pulp Brightness from Roundwood Measurements. Tese de Doutorado, Faculty of Science and Technology, Department of Chemistry, Umeå University, Umeå, 2005.
- [100] D. Nilsson e U. Edlund. Pine and spruce roundwood species classification using multivariate image analysis on bark. *Holzforschung*, 59(6):589–706, 2005.
- [101] M. S. Nixon e A. S. Aguado. Feature Extraction and Image Processing. Elsevier, London, UK, 2 edition, 2008.

- [102] M. H. Nuopponen, G. M. Birch, R. J. Sykes, S. J. Lee, e D. Stewart. Estimation of wood density and chemical composition by means of diffuse reflectance midinfrared fourier transform (drift-mir) spectroscopy. *Journal of Agricultural and Food Chemistry*, 54(1):34–40, 2006.
- [103] T. Ojala, M. Pietikainen, e T. Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 24(7):971–987, 2002.
- [104] T. Ojala, M. Pietikäinen, e D. Harwood. A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, 29(1):51 – 59, 1996.
- [105] V. Ojansivu e J. Heikkilä. Blur insensitive texture classification using local phase quantization. Proceedings of the 3rd international conference on Image and Signal Processing, ICISP '08, páginas 236–243, Berlin, Heidelberg, 2008. Springer-Verlag.
- [106] J. Päivärinta, E. Rahtu, e J. Heikkilä. Volume local phase quantization for blurinsensitive dynamic texture classification. *Proceedings of the 17th Scandinavian conference on Image analysis*, SCIA'11, páginas 360–369, Berlin, Heidelberg, 2011. Springer-Verlag.
- [107] C. Palm. Color texture classification by integrative co-occurrence matrices. Pattern Recognition, 37(5):965–976, 2004.
- [108] D. Partridge e W. B. Yates. Engineering multiversion neural-net systems. Neural Comput., 8(4):869–893, 1996.
- [109] P. L. Paula Filho. Reconhecimento de espécies florestais através de imagens macroscópicas. Tese de Doutorado, Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, Curitiba-PR, 2012.
- [110] P. L. Paula Filho, L. E. S. Oliveira, e A. S. Britto Jr. A database for forest species recognition. XXII Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens, páginas 1–2, 2009.
- [111] P. L. Paula Filho, L. E. S. Oliveira, A. S. Britto Jr., e R. Sabourin. Forest species recognition using color-based features. 20th International Conference on Pattern Recognition (ICPR2010), páginas 4178–4181, 2010.
- [112] H. Pedrini e W. R. Schwartz. Análise de Imagens Digitais: princípios, algoritmos e aplicações. Thomson Learning, São Paulo, 2008.

- [113] E. Pekalska e R. P. W. Duin. Classification on dissimilarity data: a first look. Annual Conference of the Advanced School for Computing and Imaging, páginas 221–228, 2000.
- [114] E. Pekalska e R. P. W. Duin. Dissimilarity representations allow for building good classifiers. *Pattern Recognition Letters*, 23(8):943–956, 2002.
- [115] D. T. Pham e R. J. Alcock. Automated visual inspection of birch wood boards. IEE Colloquium on Artificial Intelligence in Manufacturing, páginas 1–4, 1997.
- [116] V. Piuri e F. Scotti. Design of an automatic wood types classification system by using fluorescence spectra. *IEEE Transactions on Systems, Man, and Cybernetics, Part C*, 40(3):358–366, 2010.
- [117] Y. Plasencia, E. B. García-Reyes, R. P. W. Duin, H. Mendez-Vazquez, C. S. Martín, e C. Soto. Dissimilarity representations for thermal signature recognition at a distance. 15th Annual Conf. of the Advanced School for Computing and Imaging, páginas 1–7, 2009.
- [118] I. Podolak e A. Roman. Cores: fusion of supervised and unsupervised training methods for a multi-class classification problem. *Pattern Analysis & Applications*, páginas 1–19, 2011.
- [119] S. Radovan, P. George, M. Panagiotis, G. Manos, A. Robert, e D. Igor. An approach for automated inspection of wood boards. *International Conference on Image Processing*, 1:798–801, 2001.
- [120] P. V. W. Radtke, E. Granger, R. Sabourin, e D. O. Gorodnichy. Adaptive ensemble selection for face re-identification under class imbalance. 11th International Workshop on Multiple Classifier Systems, páginas 95–108, Nanjing, China, 2013.
- [121] P. V. W. Radtke, E. Granger, R. Sabourin, e D. O. Gorodnichy. Skew-sensitive boolean combination for adaptive ensembles: an application to face recognition in video surveillance. páginas 1–18. Elsevier, 2013.
- [122] E. Rahtu, J. Heikkilä, V. Ojansivu, e T. Ahonen. Local phase quantization for blur-insensitive image analysis. *Image and Vision Computing*, 30(8):501–512, 2012.
- [123] E. D. Rinnhofer, E. Deutschl, R. Benes, e A. delBianco. Visible-and near infrared imaging spectroscopy for wood inspection: preliminary results. 3rd IWSS, páginas 63–69, 1998.
- [124] D. Rivard. Multi-feature approach for writer-independent offline signature verification. Dissertação de Mestrado, École de Technologie Supérieure, Université du Québec, Montreal, 2010.

- [125] D. Rivard, E. Granger, e R. Sabourin. Multi-feature extraction and selection in writer-independent off-line signature verification. *International Journal on Docu*ment Analysis and Recognition (IJDAR), 16(1):83–103, 2013.
- [126] B. Rosen. Ensemble learning using decorrelated neural networks. Connection Science, 8:373–384, 1996.
- [127] D. Ruta e B. Gabrys. An overview of classifier fusion methods. volume 1, páginas 1–10. University of Paisley, 2000.
- [128] A. Santana, R. G. F. Soares, A. M. P. Canuto, e M. C. P. Souto. A dynamic classifier selection method to build ensembles using accuracy and diversity. *Neural Networks*, 2006. SBRN '06. Ninth Brazilian Symposium on, páginas 36–41, 2006.
- [129] S. Santini e R. Jain. Similarity measures. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 21(9):871–883, 1999.
- [130] E. M. Santos. Static and Dynamic Overproduction and Selection of Classifier Ensembles with Genetic Algorithms. Tese de Doutorado, École de Technologie Supérieure, Université du Québec, Montreal, 2008.
- [131] R. E. Schapire, Y. Freund, P. Bartlett, e W. S. Lee. Boosting the margin: A New Explanation for the Effectiveness of Voting Methods. *The Annals of Statistics*, 26(5):1651–1686, 1998.
- [132] E. Stamatatos. A survey of modern authorship attribution methods. J. Am. Soc. Inf. Sci. Technol., 60(3):538–556, 2009.
- [133] J. Tarrío-Saavedra, S. Naya, M. Francisco-Fernández, J. López-Beceiro, e R. Artiaga. Functional nonparametric classification of wood species from thermal data. *Journal of Thermal Analysis and Calorimetry*, 104(1):87–100, 2011.
- [134] L. Thomas, L. Mili, C. A. Shaffer, e E. Thomas. Defect detection on hardwood logs using high resolution three-dimensional laser scan data. *International Conference* on Image Processing - ICIP, páginas 243–246, 2004.
- [135] J. Y. Tou, P. Y. Lau, e Y. H. Tay. Computer vision-based wood recognition system. International Workshop on Advanced Image Technology, páginas 197–202, 2007.
- [136] J. Y. Tou, Y. H. Tay, e P. Y. Lau. Gabor filters and grey-level co-occurrence matrices in texture classification. MMU International Symposium on Information and Communications Technologies, páginas 197–202, 2007.
- [137] J. Y. Tou, Y. H. Tay, e P. Y. Lau. One-dimensional grey-level co-occurrence matrices for texture classification. *International Symposium on Information Technology* (*ITSim 2008*), páginas 1–6, 2008.

- [138] J. Y. Tou, Y. H. Tay, e P. Y. Lau. A comparative study for texture classification techniques on wood species recognition problem. *International Conference on Natural Computation*, 5, páginas 8–12, 2009.
- [139] J. Y. Tou, Y. H. Tay, e P. Y. Lau. Rotational invariant wood species recognition through wood species verification. *First Asian Conference on Intelligent Information* and Database Systems, páginas 115–120, 2009.
- [140] G. Tsoumis. Science and Technology of Wood: structure, properties, utilization. Champan & Hall, New York, 1991.
- [141] M. Tuceryan e A. K. Jain. Texture Analysis, capítulo 2.1, páginas 235–276. World Scientific, Singapore, 1 edition, 2005.
- [142] V. N. Vapnik. Statistical learning theory. Adaptive and Learning Systems for Signal Processing, Communications, and Control, New York, 1998. John Wiley & Sons Inc.
- [143] A. Vedaldi e B. Fulkerson. VLFeat: An open and portable library of computer vision algorithms, 2008.
- [144] A. C. Wiedenhoeft e R. B. Miller. Structure and Function of Wood, capítulo 2, páginas 9–33. CRC Press, Washington, D.C., 2005.
- [145] E. O. Wiley. Phylogenetics: the theory and practice of phylogenetic systematics. John Wiley & Sons, Inc., US, 1981.
- [146] K. Woods, W. P. Kegelmeyer, Jr., e K. Bowyer. Combination of multiple classifiers using local accuracy estimates. *IEEE Trans. Pattern Anal. Mach. Intell.*, 19(4):405– 410, 1997.
- [147] H. Yang, I. R. Lewis, e P. R. Griffiths. Raman spectrometry and neural networks for the classification of wood types. 2. kohonen self-organizing maps. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 55(14):2783–2791, 1999.
- [148] Y. Yang e S. Newsam. Comparing sift descriptors and gabor texture features for classification of remote sensed imagery. *Image Processing*, 2008. ICIP 2008. 15th IEEE International Conference on, páginas 1852–1855, 2008.
- [149] W. Yu, G. Sommer, e K. Daniilidis. Using skew gabor filter in source signal separation and local spectral multi-orientation analysis. 1:I-462-I-469, 2004.
- [150] J. Zhang e T. Tan. Brief review of invariant texture analysis methods. Pattern Recognition, 35(3):735–747, 2002.

- [151] G. Zhao e M. Pietikäinen. Dynamic texture recognition using local binary patterns with an application to facial expressions. *IEEE Transactions on Pattern Analysis* and Machine Intelligence, 29(6):915–928, 2007.
- [152] J. Zhu, S. C.H. Hoi, M. R. Lyu, e S. Yan. Near-duplicate keyframe retrieval by nonrigid image matching. *Proceedings of the 16th ACM international conference on Multimedia*, MM '08, páginas 41–50, New York, NY, USA, 2008. ACM.
- [153] J. Zhu, M. Vai, e P. Mak. A new enhanced nearest feature space (enfs) classifier for gabor wavelets features-based face recognition. David Zhang e AnilK. Jain, editors, *Biometric Authentication*, volume 3072 of *Lecture Notes in Computer Science*, páginas 124–130. Springer Berlin Heidelberg, 2004.

## APÊNDICE A

## BASE DE IMAGENS

Durante o desenvolvimento deste trabalho, identificou-se um reduzido número de bases construídas com foco no reconhecimento de espécies florestais, sendo CAIRO e FRIM as mais referenciadas nesta área (*vide* Capítulo 3). Diante da dificuldade para ter acesso a estas bases e por não ter encontrado referências a bases compostas por imagens microscópicas, optou-se pela elaboração de um novo conjunto de imagens. A base elaborada foi publicada em [85] e pode ser requisitada para o desenvolvimento de pesquisas no endereço eletrônico *http://web.inf.ufpr.br/vri/forest-species-database*. Esta é composta por 112 espécies florestais, cada uma com 20 amostras, num total de 2.240 imagens. Estas foram capturadas pelo Laboratório de Anatomia da Madeira, do curso de Engenharia Florestal da Universidade Federal do Paraná (UFPR).

Seguindo as definições inerentes à Anatomia da Madeira (Seção 2.1), as imagens que compõem a base proposta podem ser agrupadas de diferentes formas (Tabelas A.1 e A.2). Considerando a divisão baseada no mais alto nível possível tem-se os 2 filos, 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.

Tais imagens, como as apresentadas na Figura A.1, foram adquiridas por meio dos seguintes procedimentos:

- Extração de amostras de peças maiores de madeira para cada uma das espécies, sendo estas amostras caracterizadas por pequenos blocos com aproximadamente  $2cm^3$ ;
- Cozimento dos blocos de madeira, por tempo variado de acordo com a espécie florestal, para seu amolecimento;
- Realização dos cortes histológicos (pequenas amostras) de madeira, com espessura de aproximadamente 25 micras<sup>1</sup>, de forma paralela à seção transversal (eixo X na Figura 2.3(a)) e com o emprego de um micrótomo de deslizamento;
- Coloração dos cortes histológicos de madeira pelo processo de tripla coloração com as substâncias acridina vermelha, crisoidina e azul de astra<sup>2</sup>;
- Desidratação em série alcoólica ascendente;

<sup>&</sup>lt;sup>1</sup>Uma micra equivale à milionésima parte do metro ou  $1 \times 10^{-6}$  metro.

 $<sup>^2 {\</sup>rm Devido}$ a este procedimento de coloração não é possível utilizar características relacionadas à cor para a diferenciação das espécies.

- Montagem da lâmina para observação com a fixação dos cortes histológicos de madeira entre lâmina e lamínula; e
- Coleta das imagens com o auxílio de um microscópio Olympus modelo CX40, produzindo imagens com aproximação ótica de 100 vezes e resolução de 1024×768 pixels, tais como as apresentadas na Figura A.1.



Figura A.1: Amostras da Base de Imagens: (a) Gimnosperma; (b) Angiosperma.

Observando os exemplos de imagens microscópicas e macroscópicas de uma mesma espécie na Figura A.2, pode-se perceber diferenças substanciais em seus padrões texturais. Neste sentido, Burger e Richter [14] destacam que muitos aspectos anatômicos da madeira podem ser identificados macroscopicamente, mas que a observação de imagens microscópicas permite melhor identificação das estruturas apresentadas.



Figura A.2: Amostras de 'Araucaria angustifolia': (a) Microscópica; (b) Macroscópica.

Diante de tal contexto, a abordagem baseada em padrões texturais permite que sejam utilizados os mesmos descritores empregados nos trabalhos com foco em imagens macroscópicas. Neste sentido, a Seção 4.2 identifica os parâmetros avaliados e os valores selecionados para cada descritor apresentado na Seção 2.2.

ID	Classe	Ordem	Família	Gênero	Espécie
1	Ginkgofita	Ginkgoales	Ginkgoaceae	Ginkgo	biloba
2	Pinopsida	Pinales	Araucariaceae	A gath is	becarii
3	Pinopsida	Pinales	Araucariaceae	Araucaria	angustifolia
4	Pinopsida	Pinales	Cephalotaxaceae	Cephalotaxus	drupacea
5	Pinopsida	Pinales	Cephalotaxaceae	Cephalotaxus	harring tonia
6	Pinopsida	Pinales	Cephalotaxaceae	Torreya	nucifera
7	Pinopsida	Pinales	Cupressaceae	Calocedrus	decurrens
8	Pinopsida	Pinales	Cupressaceae	Chamae cyparis	formos ensis
9	Pinopsida	Pinales	Cupressaceae	Chamae cyparis	pisifera
10	Pinopsida	Pinales	Cupressaceae	Cupressus	arizonica
11	Pinopsida	Pinales	Cupressaceae	Cupressus	lindleyi
12	Pinopsida	Pinales	Cupressaceae	Fitzroya	cupressoides
13	Pinopsida	Pinales	Cupressaceae	Larix	lariciana
14	Pinopsida	Pinales	Cupressaceae	Larix	leptolepis
15	Pinopsida	Pinales	Cupressaceae	Larix	sp
16	Pinopsida	Pinales	Cupressaceae	Tetraclinis	articulata
17	Pinopsida	Pinales	Cupressaceae	Widdringtonia	cupressoides
18	Pinopsida	Pinales	Pinaceae	Abies	religios a
19	Pinopsida	Pinales	Pinaceae	Abies	vejari
20	Pinopsida	Pinales	Pinaceae	Cedrus	at lantica
21	Pinopsida	Pinales	Pinaceae	Cedrus	libani
22	Pinopsida	Pinales	Pinaceae	Cedrus	sp
23	Pinopsida	Pinales	Pinaceae	Keteleeria	fortunei
24	Pinopsida	Pinales	Pinaceae	Picea	abies
25	Pinopsida	Pinales	Pinaceae	Pinus	arizonica
26	Pinopsida	Pinales	Pinaceae	Pinus	caribaea
27	Pinopsida	Pinales	Pinaceae	Pinus	elliottii
28	Pinopsida	Pinales	Pinaceae	Pinus	gregii
29	Pinopsida	Pinales	Pinaceae	Pinus	maximinoi
30	Pinopsida	Pinales	Pinaceae	Pinus	taeda
31	Pinopsida	Pinales	Pinaceae	Pseudotsuga	macrolepsis
32	Pinopsida	Pinales	Pinaceae	Tsuga	can a densis
33	Pinopsida	Pinales	Pinaceae	Tsuga	sp
34	Pinopsida	Pinales	Podocarpaceae	Podocarpus	lambertii
35	Pinopsida	Pinales	Taxaceae	Taxus	baccata
36	Pinopsida	Pinales	Taxodiaceae	Sequoia	s empervirens
37	Pinopsida	Pinales	Taxodiaceae	Taxodium	distichum

Tabela A.1: Gimnospermas: classificação Botânica das espécies.

ID	Classe	Ordem	Família	Gênero	Espécie
38	Gnetopsida	Ephedrales	Ephedraceae	Ephedra	californica
39	Magnoliopsida	Ericales	Lecythidaceae	Cariniana	estrellensis
40	Magnoliopsida	Ericales	Lecythidaceae	Couratari	sp
41	Magnoliopsida	Ericales	Lecythidaceae	Eschweilera	matamata
42	Magnoliopsida	Ericales	Lecythidaceae	Eschwele ira	chartaceae
43	Magnoliopsida	Ericales	Sapotaceae	Chrysophyllum	sp
44	Magnoliopsida	Ericales	Sapotaceae	Micropholis	guian ensis
45	Magnoliopsida	Ericales	Sapotaceae	Pouteria	pachy carpa
46	Magnoliopsida	Fabales	Fabaceae	Copai fera	trapez i folia
47	Magnoliopsida	Fabales	Fabaceae	Eperua	falcata
48	Magnoliopsida	Fabales	Fabaceae	Hymenaea	courbaril
49	Magnoliopsida	Fabales	Fabaceae	Hymenaea	sp
50	Magnoliopsida	Fabales	Fabaceae	Schizolobium	parahyba
51	Magnoliopsida	Fabales	Fabaceae	Pterocarpus	violaceus
52	Magnoliopsida	Fabales	Fabaceae	A cacia	tucunamensis
53	Magnoliopsida	Fabales	Fabaceae	An a denanthera	colubrina
54	Magnoliopsida	Fabales	Fabaceae	An a denanthera	peregrina
55	Magnoliopsida	Fabales	Fabaceae	Dalbergia	ja caranda
56	Magnoliopsida	Fabales	Fabaceae	Dalbergia	spruce ana
57	Magnoliopsida	Fabales	Fabaceae	Dalbergia	variabilis
58	Magnoliopsida	Fabales	Fabaceae	Dinizia	excelsa
59	Magnoliopsida	Fabales	Fabaceae	Enterolobium	schomburgkii
60	Magnoliopsida	Fabales	Fabaceae	Inga	sessilis
61	Magnoliopsida	Fabales	Fabaceae	Leucaena	leucocephala
62	Magnoliopsida	Fabales	Fabaceae	Lonchocarpus	subglaucescens
63	Magnoliopsida	Fabales	Fabaceae	Mimosa	bimucronata
64	Magnoliopsida	Fabales	Fabaceae	Mimosa	scabrella
65	Magnoliopsida	Fabales	Fabaceae	Ormosia	excelsa
66	Magnoliopsida	Fabales	Fabaceae	Parapipta denia	rigida
67	Magnoliopsida	Fabales	Fabaceae	Parkia	multijuga
68	Magnoliopsida	Fabales	Fabaceae	Piptadenia	excelsa
69	Magnoliopsida	Fabales	Fabaceae	Pithecellobium	jupunba
70	Magnoliopsida	Gentianales	Rubiaceae	Psychotria	carthagenensis
71	Magnoliopsida	Gentianales	Rubiaceae	Psychotria	longipes
72	Magnoliopsida	Lamiales	Bignoniaceae	Tabebuia	rosea alba
73	Magnoliopsida	Lamiales	Bignoniaceae	Tabebuia	sp
74	Magnoliopsida	Lamiales	Oleaceae	Ligustrum	lucidum
75	Magnoliopsida	Laurales	Lauraceae	Nectandra	rigida
76	Magnoliopsida	Laurales	Lauraceae	Nectandra	sp
77	Magnoliopsida	Laurales	Lauraceae	Ocotea	porosa
78	Magnoliopsida	Laurales	Lauraceae	Persea	racemosa
79	Magnoliopsida	Magnoliales	Annonaceae	Porcelia	macrocarpa
80	Magnoliopsida	Magnoliales	Magnoliaceae	Magnolia	grandiflora

Tabela A.2: Angiospermas: classificação Botânica das espécies.

Continua na próxima página

ID	Classe	Ordem	Família	Gênero	Espécie
81	Magnoliopsida	Magnoliales	Magnoliaceae	Talauma	ovata
82	Magnoliopsida	Myrtales	Melastomataceae	Tibouchiana	sellowiana
83	Magnoliopsida	Myrtales	Myristicaceae	Virola	oleifera
84	Magnoliopsida	Myrtales	Myrtaceae	Campomanesia	xan tho carpa
85	Magnoliopsida	Myrtales	Myrtaceae	Eucalyptus	globulus
86	Magnoliopsida	Myrtales	Myrtaceae	Eucalyptus	grand is
87	Magnoliopsida	Myrtales	Myrtaceae	Eucalyptus	saligna
88	Magnoliopsida	Myrtales	Myrtaceae	Myrcia	racemulos a
89	Magnoliopsida	Polygalales	Vochysiaceae	Erisma	uncinatum
90	Magnoliopsida	Polygalales	Vochysiaceae	Qualea	sp
91	Magnoliopsida	Polygalales	Vochysiaceae	Vochysia	laurifolia
92	Magnoliopsida	Proteales	Proteaceae	Grevillea	robusta
93	Magnoliopsida	Proteales	Proteaceae	Grevillea	sp
94	Magnoliopsida	Proteales	Proteaceae	Roupala	sp
95	Magnoliopsida	Rosales	Moraceae	Bagassa	guian ensis
96	Magnoliopsida	Rosales	Moraceae	Brosimum	alicastrum
97	Magnoliopsida	Rosales	Moraceae	Ficus	gomelle ira
98	Magnoliopsida	Rosales	Rhamnaceae	Hovenia	dulc is
99	Magnoliopsida	Rosales	Rhamnaceae	Rhamnus	frangula
100	Magnoliopsida	Rosales	Rosaceae	Prunus	sellowii
101	Magnoliopsida	Rosales	Rosaceae	Prunus	serotina
102	Magnoliopsida	Rubiales	Rubiaceae	Faramea	occidental is
103	Magnoliopsida	Sapindales	Meliaceae	Cabralea	can jerana
104	Magnoliopsida	Sapindales	Meliaceae	Carapa	guian ensis
105	Magnoliopsida	Sapindales	Meliaceae	Cedrela	fissilis
106	Magnoliopsida	Sapindales	Meliaceae	Khaya	ivorensis
107	Magnoliopsida	Sapindales	Meliaceae	Melia	azed arach
108	Magnoliopsida	Sapindales	Meliaceae	Swietenia	macrophylla
109	Magnoliopsida	Sapindales	Rutaceae	Balfour oden dron	riedelianum
110	Magnoliopsida	Sapindales	Rutaceae	Citrus	aurantium
111	Magnoliopsida	Sapindales	Rutaceae	Fagara	rhoifolia
112	Magnoliopsida	Sapindales	Simaroubaceae	Simarouba	amara

continuação da página anterior