

PEDRO LUIZ DE PAULA FILHO

**RECONHECIMENTO DE ESPÉCIES FLORESTAIS  
ATRAVÉS DE IMAGENS MACROSCÓPICAS**

Texto apresentado ao Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, como requisito parcial para a obtenção do título de doutor.

Orientador: Prof. Dr. Luiz Eduardo Soares de Oliveira

Co-orientador: Profa. Dra. Silvana Nisgoski

CURITIBA

2012

PEDRO LUIZ DE PAULA FILHO

**RECONHECIMENTO DE ESPÉCIES FLORESTAIS  
ATRAVÉS DE IMAGENS MACROSCÓPICAS**

Texto apresentado ao Programa de Pós-Graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, como requisito parcial para a obtenção do título de doutor.

Orientador: Prof. Dr. Luiz Eduardo Soares de Oliveira

Co-orientador: Profa. Dra. Silvana Nisgoski

CURITIBA

2012

# CONTEÚDO

<b>LISTA DE FIGURAS</b>	<b>iv</b>
<b>LISTA DE TABELAS</b>	<b>vi</b>
<b>LISTA DE ABREVIATURAS</b>	<b>vii</b>
<b>RESUMO</b>	<b>viii</b>
<b>ABSTRACT</b>	<b>ix</b>
<b>1 INTRODUÇÃO</b>	<b>1</b>
1.1 Motivação . . . . .	3
1.2 Desafios . . . . .	4
1.3 Objetivos . . . . .	4
1.4 Contribuições . . . . .	5
1.5 Organização do Documento . . . . .	6
<b>2 FUNDAMENTAÇÃO TEÓRICA</b>	<b>7</b>
2.1 Propriedades Organolépticas da Madeira . . . . .	7
2.2 Propriedades Anatômicas da Madeira . . . . .	9
2.3 Cor . . . . .	11
2.4 Textura . . . . .	13
2.4.1 Abordagem Estatística . . . . .	17
2.4.1.1 Medidas baseadas na distribuição de níveis de cinza . . . . .	17
2.4.1.2 Matriz de coocorrência . . . . .	20
2.4.2 Abordagem Estrutural . . . . .	25
2.4.2.1 Fractais . . . . .	26
2.4.2.2 LBP - <i>Local Binary Pattern</i> . . . . .	36
2.4.2.3 <i>Local Phase Quantization</i> - LPQ . . . . .	40
2.4.2.4 Histograma da orientação da borda - <i>Edge Orientation Histogram</i> - EOH . . . . .	42
2.4.3 Abordagem Espectral . . . . .	43
2.4.3.1 Filtro de Gabor . . . . .	44
2.5 Combinação de Classificadores . . . . .	48
<b>3 ESTADO DA ARTE</b>	<b>52</b>
3.0.1 Reconhecimento de Espécies Florestais . . . . .	52

3.0.2	Problemas relacionados . . . . .	57
3.0.2.1	Conclusão . . . . .	62
<b>4</b>	<b>BASES DE DADOS</b>	<b>63</b>
4.1	Protocolo em Campo . . . . .	63
4.2	Protocolo em Laboratório . . . . .	64
<b>5</b>	<b>MÉTODO PROPOSTO</b>	<b>69</b>
5.1	Subdivisão da imagem . . . . .	70
5.2	Extração de características . . . . .	71
5.2.1	Abordagem estatística . . . . .	72
5.2.1.1	Análise de cor . . . . .	72
5.2.1.2	Matriz de coocorrência - GLCM . . . . .	73
5.2.2	Abordagem espectral . . . . .	73
5.2.2.1	Filtros de Gabor . . . . .	73
5.2.3	Abordagem estrutural . . . . .	74
5.2.3.1	Fractais . . . . .	74
5.2.3.2	<i>Local Binary Pattern</i> - LBP . . . . .	74
5.2.3.3	<i>Local Phase Quantization</i> - LPQ . . . . .	74
5.2.3.4	Histograma da orientação da borda . . . . .	75
5.3	Classificação . . . . .	75
5.4	Fusão de classificadores - Baixo Nível (Camada 5) . . . . .	76
5.5	Fusão das subimagens - Alto Nível (Camada 6) . . . . .	76
<b>6</b>	<b>RESULTADOS EXPERIMENTAIS</b>	<b>78</b>
6.1	Imagem Inteira . . . . .	78
6.2	Fusão de classificadores da Imagem Inteira - Baixo Nível . . . . .	79
6.3	Divisão das imagens - Método <i>dividir para conquistar</i> . . . . .	80
6.4	Divisão das imagens e Fusão dos pedaços . . . . .	83
6.5	Divisão das imagens, Fusão dos pedaços e fusão dos classificadores - Pro- posta Completa . . . . .	85
6.6	Comparações usando-se o protocolo de campo e de laboratório . . . . .	86
<b>7</b>	<b>CONCLUSÃO</b>	<b>93</b>
7.1	Trabalhos Futuros . . . . .	94
	<b>BIBLIOGRAFIA</b>	<b>105</b>

## LISTA DE FIGURAS

2.1	Ipê ( <i>Handroanthus</i> sp - esquerda) e Cedro ( <i>Cedrela fissilis</i> - direita) . . . . .	8
2.2	Planos de Corte [41] . . . . .	9
2.3	Exemplo de planos de corte de <i>Pittosporum angustifolium</i> - (escala = 125 $\mu\text{m}$ ) [10] . . . . .	9
2.4	Exemplo da classificação de textura na área madeireira . . . . .	10
2.5	Estruturas anatômicas - Angelim ( <i>Hymenolobium petraeum</i> ) - sendo que A representa o parênquima, B os vasos, C os raios e D fibra . . . . .	11
2.6	Estruturas anatômicas - Goiabão ( <i>Planchonela pachycarpa</i> ) - sendo que A representa os vasos, B os parênquimas (linhas), C os raios (colunas) e a faixa apontada em D representa anel de crescimento . . . . .	11
2.7	Modelos de cor RGB e HSV . . . . .	12
2.8	Modelos de cor XYZ, CIELAB e CIELUV . . . . .	14
2.9	Exemplo da importância do tratamento da textura de uma imagem [95] . . . . .	15
2.10	Tipos de Textura [18] . . . . .	16
2.11	Relacionamento entre técnicas estatísticas de segunda ordem e a imagem Original [111] . . . . .	18
2.12	Ângulos utilizados para cálculo da matriz de coocorrência. Adaptado de [40] . . . . .	21
2.13	Representações das relações espaciais para a matriz de coocorrência [47] . . . . .	24
2.14	Vizinhança proposta para a matriz de coocorrência 3D [108] . . . . .	24
2.15	Exemplos de fotos microscópicas de espécies florestais . . . . .	25
2.16	Demonstração do funcionamento da dimensão <i>box counting</i> [74] . . . . .	28
2.17	Divisões em uma imagem em tons de cinza para o cálculo da $D_B$ [18] . . . . .	28
2.18	Determinação da dimensão de correlação. a) Sondagem da esfera no conjunto. b) plotagem do $\log(r) \times \log(C_r)$ [74] . . . . .	30
2.19	Representação das formas de movimentação do <i>Gliding-box</i> (GB) [77] . . . . .	31
2.20	Exemplo do cálculo da lacunaridade usando o método <i>Gliding-box</i> (GB) [77] . . . . .	32
2.21	Representação dos cubos empilhados do método <i>Gliding-box</i> (GB) [77] . . . . .	32
2.22	Demonstração da Sucolaridade [74] . . . . .	33
2.23	Demonstração da pressão na sucolaridade [74] . . . . .	34
2.24	Cálculo do LBP original para medição de contraste [97] . . . . .	36
2.25	Exemplo do conjunto circularmente simétrico dos vizinhos do LBP [66] . . . . .	37
2.26	Diferentes primitivas de textura detectáveis pelo LBP [66] . . . . .	38
2.27	Os 58 padrões invariantes de rotação que podem ocorrer em uma vizinhança circular $(8, R)$ [2] . . . . .	39
2.28	Exemplo de um histograma da orientação da borda [118] . . . . .	43

2.29	Variação dos parâmetros $\mu = 0, 1, \dots, 7$ e $\nu = 0, 1, \dots, 4$ [62] . . . . .	45
2.30	Exemplo da função Gabor com mesmo $\sigma$ e diferentes tamanhos de onda [56]	46
2.31	Cobertura espacial do domínio de frequência por um banco de filtros Gabor [56] . . . . .	48
2.32	Abordagens para a construção de conjuntos em combinação de classificadores [103] . . . . .	49
3.1	Agrupamento das técnicas utilizadas nos trabalhos descritos no estado da arte . . . . .	62
4.1	Exemplo de amostras de madeira . . . . .	63
4.2	Esquema da estrutura para aquisição das imagens . . . . .	64
4.3	Exemplos das amostras da base de dados colhidas com o protocolo de campo	66
4.4	Estereomicroscópio - Marca Zeiss - Modelo Discovery 12 . . . . .	67
4.5	Exemplos das amostras da base de dados colhidas com o protocolo de laboratório . . . . .	67
4.6	Imagens de <i>Acrocarpus</i> - <i>Acrocarpus fraxinifolius</i> , adquiridas através das duas abordagens . . . . .	67
5.1	Fluxograma do Método Proposto . . . . .	70
5.2	Exemplo de amostras mal preparadas (Marupá - <i>Simarouba amara</i> ) . . . . .	70
5.3	Representação da estratégia da divisão da imagem . . . . .	71
5.4	Exemplo do comportamento do histograma no modelo RGB, canal G . . . . .	73
5.5	Exemplo da classificação <i>pairwise</i> . . . . .	75
5.6	Representação da fusão por votação . . . . .	77
6.1	Representação da estratégia da fusão da imagem inteira . . . . .	80
6.2	Impacto da variação da quantidade de subimagens . . . . .	81
6.3	Efeito da variação da quantidade de subimagens - Fusão votação . . . . .	82
6.4	Matriz de Confusão da Combinação classificadores - Fusão por Soma - 25 pedaços - Protocolo de Campo . . . . .	90
6.5	Exemplo de imagem de Eucalipto (a) e três imagens de Cumaru (b-d) classificadas como eucalipto . . . . .	90
6.6	Matriz de Confusão da Combinação classificadores - Fusão por Soma e Votação - 25 pedaços - Protocolo de Laboratório . . . . .	91
6.7	Imagens que geraram confusão - Protocolo de Laboratório . . . . .	92

## LISTA DE TABELAS

2.1	Descritores de Haralick [40] . . . . .	22
2.2	Resultados da Sucolaridade da Figuras 2.23a e 2.23b [74] . . . . .	35
3.1	Síntese dos trabalhos de reconhecimento de espécies florestais apresentados	57
4.1	Composição da base de imagens final . . . . .	65
4.2	Descrição da codificação das amostras de imagens macroscópicas do Este- reomicroscópio - Marca Zeiss . . . . .	68
5.1	Resumo dos descritores . . . . .	72
6.1	Resultados imagens inteiras . . . . .	79
6.2	Resultados fusão inteira, ordenado usando-se soma . . . . .	80
6.3	Resultados fusão inteira, ordenado usando-se votação . . . . .	80
6.4	Avaliação da variação da quantidade de pedaços ( $n$ ) . . . . .	81
6.5	Avaliação da variação da quantidade de pedaços ( $n$ ) - Fusão por votação .	82
6.6	Avaliação da variação da quantidade de pedaços - Fusão por soma . . . . .	82
6.7	Combinação de classificadores - Regra da votação . . . . .	83
6.8	Combinação de classificadores - Regra da soma . . . . .	83
6.9	Classificação das subimagens - 25 e 36 pedaços . . . . .	84
6.10	Fusão por Votação dos classificadores das subimagens - 25 e 36 pedaços . .	84
6.11	Fusão por Soma dos classificadores das subimagens - 25 e 36 pedaços . . .	84
6.12	Combinação classificadores - Fusão por Votação - 25 pedaços . . . . .	85
6.13	Combinação classificadores - Fusão por Soma - 25 pedaços . . . . .	86
6.14	Combinação classificadores - Fusão por Votação - 36 pedaços . . . . .	86
6.15	Combinação classificadores - Fusão por Soma - 36 pedaços . . . . .	86
6.16	Composição da união das duas bases . . . . .	87
6.17	Taxas de reconhecimento individuais dos descritores para as duas bases . .	88
6.18	Combinação classificadores - Imagem inteira - Protocolo laboratório . . . .	88
6.19	Combinação classificadores - Imagem inteira - Protocolo campo . . . . .	88
6.20	Combinação classificadores - Fusão por Votação - 25 pedaços - Protocolo de Campo . . . . .	89
6.21	Combinação classificadores - Fusão por Soma - 25 pedaços - Protocolo de Campo . . . . .	89
6.22	Combinação classificadores - Fusão por Votação - 25 pedaços - Protocolo de Laboratório . . . . .	91

6.23 Combinação classificadores - Fusão por Soma - 25 pedaços - Protocolo de  
Laboratório . . . . . 91

## LISTA DE ABREVIATURAS

ROI	<i>Region of Interest</i>	Região de Interesse
GLCM	<i>Gray Level Co-occurrence Matrices</i>	Matriz de Co-ocorrência dos Níveis de Cinza
CBIR	<i>Content-based image retrieval</i>	Recuperação de imagens baseado em conteúdo
RNA	Rede Neural Artificial	
MLP	<i>Multi Layer Perceptron</i>	
CAIRO	Centro de Inteligência Artificial e Robótica - Universidade Tecnológica da Malásia	
HSV	Sistema de cor ( <i>Hue, Saturation e Value</i> )	
LRE	<i>long run emphasis</i>	
EPLH	<i>Energy proportion of horizontal low-frequency</i>	Energia da Baixa Frequência Horizontal
LBP	<i>Local Binary Pattern</i>	
LPQ	<i>Local Phase Quantization</i>	
EOH	<i>Edge Orientation Histogram</i>	Histograma da orientação da borda
SVM	<i>Support Vector Machines</i>	
SOM	<i>Self Organized Maps</i>	Redes neurais auto-organizáveis

## RESUMO

A identificação de espécies é uma necessidade primordial para as atividades de comércio e preservação de florestas. Entretanto, devido à escassez de dados e bases de imagens florestais, os estudos computacionais relacionados a esse tema são raros e recentes. Outros fatores que influenciam a raridade desses estudos estão relacionados à falta de técnicas computacionais comprovadamente eficazes para essa tarefa e ao custo para a aquisição de imagens para a construção das bases e modelos computacionais, uma vez que equipamentos sofisticados e caros são utilizados. Tendo em vista esse contexto e com objetivo de minimizar os custos relacionados ao processo de identificação de espécies florestais, é proposta uma nova abordagem para essa tarefa, com a qual a identificação poderá ser realizada em campo e com equipamentos de baixo valor, agregando maior mobilidade e agilidade à execução dessa tarefa. Para avaliar e validar essa proposta, foram construídas duas bases de imagens macroscópicas a partir de amostras de madeira de espécies florestais encontradas no território nacional, considerando dois métodos diferentes: *abordagem tradicional em laboratório* e *abordagem em campo*, sendo esta última, a proposta deste trabalho. Um protocolo modular baseado na estratégia de *dividir para conquistar* foi proposto, nele as imagens são divididas em subimagens, com o intuito de que problemas locais não afetem a classificação geral da imagem. A partir delas, são extraídas informações de cor e textura que são utilizadas para a construção de conjuntos de treinamento, teste e validação de classificadores. Para extração desses atributos são avaliadas diversas técnicas consagradas como análises de cor, GLCM, histograma de borda, Fractais, LBP, LPQ e Gabor. Após a classificação de cada conjunto de atributos das subimagens, seus resultados passam por duas camadas de fusões (baixo e alto nível), para se chegar à decisão final de qual espécie a amostra pertence. Inicialmente, a avaliação experimental foi realizada com a base de imagens obtidas a partir da *abordagem em campo* uma vez que dessa maneira os resultados são mais conservadores devido à presença de ruídos nos conjuntos de dados e ao não tratamento das amostras adquiridas. A taxa de reconhecimento obtida nessa etapa foi 95,82%. Após a validação do método proposto, os modelos de classificação foram reconstruídos e avaliados a partir da base de imagens criada com a *abordagem tradicional em laboratório*. Com esse novo modelo, a taxa de classificação foi de 99,49%. A partir da análise dos resultados, observa-se a viabilidade da abordagem proposta neste trabalho, que além de apresentar uma excelente taxa de classificação, muito próxima da obtida com técnicas mais sofisticadas e de alto custo, ainda agrega a mobilidade para a classificação de espécies em campo. Ressalta-se ainda, a construção e disponibilização das bases de imagens florestais, contribuindo, desta forma, para trabalhos futuros nesta área.

## ABSTRACT

Identifying species is a capital task related to the forestry commerce and preservations activities. However, due to the insufficiency of data and forestry image databases, studies concerning this subject are still rare and recent. Furthermore, the scarceness of these studies is enforced in the absence of effective computational techniques and the high costs involving image acquisition and models construction, since sophisticated and expensive equipment are needed. Regarding this context, we propose a new approach aiming at minimizing the costs involved in the automatic identification of forestry species, by which one can conduct this task in the field and using low cost equipment, aggregating at the same time, financial economy, mobility and agility. To evaluate the proposed approach we built two databases from samples of macroscopic images of wood species that can be found in the Brazilian territory. The databases were built using two different methods, namely standard laboratory approach and field approach, being the last one proposed in this research. A Divide-and-Conquer strategy was used to elaborate a modular protocol, where the images are divided into sub-images in order to avoid local factors influence during the image classification. Color and texture information are extracted from the images to form the training, test and validation sets used to evaluate the classifiers performance. Several techniques were used for the feature extraction, such as color analysis, GLCM, border histogram, fractals, LBP, LPQ and Gabor. After the classification of each feature set, the results are combined through two fusion layers (low and high level) to form the final image classification, assigning a specimen label to the current image example. The experimental evaluation was performed in two phases, first considering the field approach to build the image database and after, the standard laboratory approach. It is worth noting that using the field approach the results represent conservative estimates, since it might exists a high level of noisy in the dataset due to the fact that no preprocessing or filter was used to enhance the images. Nevertheless, the recognition rate achieved using this approach was 95.82%. Afterwards, the classification models were re-built using the dataset obtained with the standard laboratory approach, achieving 99.49% recognition rate. From these results, its is possible to conclude the feasibility of the proposed approach, which in spite of the high classification rate very close to the more sophisticated and expensive technique, decreases the cost and aggregates mobility (conducted in the field) to the task of forestry species classification. It is also worth to mention another important contribution of this research work, which is the construction of macroscopic forestry images databases, from now on available for future work in this research area.

# CAPÍTULO 1

## INTRODUÇÃO

A identificação correta das espécies é uma necessidade primordial para a atividade do manejo florestal. Este só é sustentável quando garante a manutenção das diversas espécies existentes na área de exploração. A identificação botânica também proporciona uma supervisão mais precisa do manejo florestal e um comércio mais seguro das espécies madeiras. A identificação das árvores na floresta é fácil devido às flores, frutas e folhas, porém, a partir do momento que está cortada, sua identificação torna-se complexa [54].

Estudos anatômicos das madeiras têm sido utilizados, na sua grande maioria, com vistas ao respaldo e subsídio à taxonomia, em pequena escala, relacionados com a fisiologia e ecologia e, em alguns casos, puramente acadêmicos [91].

Para Paula *et al* [93], visando determinar possíveis aplicações de diferentes espécies de madeira, é primordial um estudo detalhado de sua estrutura anatômica. Desta forma, é possível classificar e agrupar espécies, direcionando-as, então, para estudos tecnológicos específicos, visando confirmar ou não a indicação obtida através da análise da estrutura anatômica. Para a identificação de espécies desconhecidas, em geral, usam-se chaves dicotômicas ((Menon, 1993) *apud* [54]).

Tou *et al* [112] citam que a identificação da madeira é importante em várias áreas, como: 1) na indústria, antes de se gerar um novo produto; 2) em construções, pois ao se fazer um telhado, caso a madeira não seja forte o suficiente, este pode cair; 3) evitando-se fraudes, quando algum revendedor de madeira possa misturar uma espécie mais barata, a uma carga de espécies nobres; 4) na conservação, identificando espécies que estão em extinção. Os autores ainda citam que o processo de identificação feito por humanos pode ser tedioso e consumir bastante tempo, o que torna inviável checar todas as cargas de exportação.

A identificação pode ser útil em outras áreas, como na determinação da espécie de um fragmento de madeira em uma cena de crime, ou o material usado por uma arquitetura antiga ou ferramenta, entender a ecologia e informações geológicas para estudar o relacionamento entre espécies, identificar o material usado em um objeto para restauração, entre outros [54, 112].

Atualmente, o reconhecimento é feito por especialistas muito bem treinados, porém, leva-se muito tempo para tornar uma pessoa competente na identificação de espécies florestais, além de que a examinação manual pode ser muito subjetiva, e por isso, o número de profissionais não é abundante para atender à demanda da indústria, gerando assim, uma lacuna que a computação pode preencher [112].

Segundo o IPT (Instituto de Pesquisas Tecnológicas do Estado de São Paulo) [25], mesmo para técnicos especializados é difícil distinguir uma madeira de outra, dentro da enorme variedade de espécies encontradas no Brasil. No fim da década de 90, o IPT contava com um acervo de 18.000 amostras de madeiras, pertencentes a 1.000 espécies, 600 gêneros e 100 famílias.

Segundo Pedrini & Schwartz [94], o desenvolvimento de programas computacionais autônomos que consigam assemelhar-se ao sistema visual humano é ainda um desafio. A meta é analisar e/ou interpretar imagens, obtendo informações suficientes para distinguir objetos de interesse de forma confiável. Esta área de estudo denomina-se visão computacional, e tem sido utilizada na indústria madeireira, desde os anos 80, porém, seu uso tem se restringido a identificar a qualidade da madeira ou busca por defeitos, e para isso, têm sido utilizados dispositivos como ultrassom, micro-ondas, ressonância magnética, raios-X, laser, câmeras e espectrômetros, o que, em geral, é bastante caro (Connors, 1997) *apud* [54].

Para Tou *et al* [114], o reconhecimento de espécies florestais, através da madeira, envolve não só técnicas simples de análise de textura, pois as espécies são naturalmente similares. Segundo Khalid *et al* [54] este tipo de estudo é recente e, conseqüentemente, a quantidade de sistemas computacionais que visem, efetivamente, o reconhecimento é pequeno, e isso ocorre devido a alguns fatores como:

- Dificuldade na obtenção de uma base de imagens;
- Disponibilidade e alto custo de equipamentos para aquisição e análise das amostras;
- Falta de técnicas computacionais comprovadas no reconhecimento de espécies florestais;
- Falta de especialistas em classificação nos países em desenvolvimento.

Apesar dos laboratórios de anatomia de madeira possuírem xilotecas (coleções de referência de espécies florestais), o problema para a obtenção da base se deve à escassez de amostras de cada espécie, para formar os conjuntos de imagens para treinamento, teste e validação. Além disso, os conjuntos de imagens disponíveis são usualmente obtidas por meio de equipamentos de alto custo e com pouca mobilidade, não permitindo que estas amostras sejam adquiridas em campo. Já em relação às técnicas computacionais, está em aberto um grande leque de abordagens que podem ser úteis para esse problema, dentre elas, destaca-se a textura.

Buscando contribuir na resolução de alguns destes fatores, foi proposta a abordagem deste trabalho.

## 1.1 Motivação

No Brasil são poucos os laboratórios especializados no reconhecimento de espécies florestais, entre eles, IPT, FURB, IBAMA, UFPR, INPA, UnB/Serviço Florestal Brasileiro. O reconhecimento de espécies florestais, através da madeira, é útil para várias áreas, mas com o crescimento dos desmatamentos, em que se derrubam espécies nativas e em vias de extinção para sua comercialização ilegal, a fiscalização através de órgãos como IBAMA e Polícia Federal tem se tornado mais frequente e presente.

Porém, ainda faltam ferramentas que os ajudem em campo, pois, por exemplo, descobrir a qual espécie florestal uma tábua em uma serraria pertence não é uma atividade fácil. Uma ferramenta computacional que permita uma taxa razoável de reconhecimento em campo, dá subsídios aos fiscais à tomarem as medidas cabíveis aos infratores. Atualmente, se a fiscalização identifica uma possível irregularidade, até que a comprove, leva-se um tempo muito grande, o que dificulta a aplicação de penas ou sanções aos infratores.

Outro exemplo no qual a ferramenta de reconhecimento seria relevante é na exportação, pois grandes navios saem com seus porões cheios de madeiras e a identificação de espécies de aparência semelhante, porém com propriedades físicas e valores bem distintos, é complexa, como ipê (*Handroanthus* sp) e cumaru (*Dipteryx* sp). O uso da ferramenta permitiria a identificação imediata de irregularidades, evitando transtornos e prejuízos financeiros a compradores e exportadores.

Dentre as informações visuais que podem ser extraídas da imagem de uma amostra de madeira, a que se mostra bastante promissora na possível identificação de espécies florestais, é a textura, sendo a característica visual mais importante para identificação de estruturas homogêneas em uma imagem, pois suas propriedades representam a superfície ou estrutura de um objeto [115, 107].

Maenpaa [66] afirma que para a inspeção da superfície da madeira a textura pode ser usada realçando características de cor. Segundo Ilea & Whelan [43] as informações que cor e textura trazem têm fortes referências à percepção humana, e em vários cenários, somente tais informações não são robustas o suficiente para descrever, de forma correta, o conteúdo de uma imagem.

A análise de textura tem sido usada desde os anos 60, sendo frequentemente atribuída à percepção humana e, alguns estudos mostram que para o reconhecimento de objetos no mundo real, o sistema visual humano depende parcialmente da percepção de consistência e diferença textural [66, 83, 6].

Para tanto, justifica-se o presente estudo, bem como a comparação de técnicas de extração de características que permitam analisar textura de uma forma ampla, aplicada a esse tipo de problema.

## 1.2 Desafios

Tou *et al* [114] comentam que o reconhecimento de espécies florestais, através da madeira, é um problema mais desafiador que uma simples análise de textura, porque este tipo de característica é naturalmente similar, levando a confusões.

Problemas de textura em imagens gerais, segundo Angelo [6], vêm sendo estudados desde os anos 60. Para testar novas técnicas, utilizam-se bases de imagens já consagradas, como a VisTex<sup>1</sup> do MIT (*Massachusetts Institute of Technology*), a Outex<sup>2</sup> da *University of Oulu*, entre outras. Para estas bases, existem inúmeros experimentos e, conseqüentemente, resultados prévios que permitem avaliar sua eficiência. Porém, para a análise de espécies florestais existem alguns problemas, como:

- Inexistência de bases disponíveis para comparar resultados, conseqüentemente, não se tem protocolos de aquisição bem definidos, principalmente, em campo.
- Devido ao pequeno número de projetos de pesquisa vinculados a esta área, não se tem parâmetros efetivos de quais técnicas de visão computacional se adaptam melhor a este tipo de problema e que, conseqüentemente, devem ser experimentadas para analisar quais obtêm melhores percentuais de acerto.
- Devido à grande variedade de espécies florestais, muitas amostras são semelhantes entre si (semelhança extraclasse) e amostras de mesma espécie podem apresentar diferenças significativas, devido a questões como clima e solo (diferença intraclasse).
- Amostras não tratadas tendem a ter problemas (batidas, manchas naturais, diferença entra cerne e alburno, entre outros), o que pode comprometer o reconhecimento.
- Fazer análise das espécies em campo, sem os recursos de laboratório.

## 1.3 Objetivos

O objetivo deste trabalho é fazer o reconhecimento de espécies florestais através de técnicas de análise de cor e textura usando imagens macroscópicas da madeira. As técnicas devem ser robustas o suficiente para permitir sua identificação em campo (menos recursos) ou em laboratório (mais recursos). Para tanto, as seguintes etapas foram definidas:

- Propor um protocolo de aquisição das imagens macroscópicas de madeira, de forma que possa ser reproduzido em campo sem a necessidade de equipamentos sofisticados, como câmeras de alta resolução, micrótomos, entre outros.

---

<sup>1</sup>Disponível em: [vismod.media.mit.edu/vismod/imagery/VisionTexture/](http://vismod.media.mit.edu/vismod/imagery/VisionTexture/)

<sup>2</sup>Disponível em: [www.outex.oulu.fi](http://www.outex.oulu.fi)

- Criar duas bases de imagens macroscópicas de espécies florestais que permitam estudos anatômicos das madeiras, bem como dar subsídios a novas pesquisas em computação para problemas similares a este, sendo uma delas adquirida através de um dispositivo de baixo custo (campo) e outra em laboratório (mais recursos).
- Definir técnicas de extração de características para as imagens adquiridas que permitam uma melhor identificação, sendo estas tanto de cor, como de textura (estatísticas, espectrais e estruturais).
- Definir uma estratégia de classificação baseada em cor e textura para diferenciar imagens de espécies florestais de forma robusta, capaz de lidar com a variabilidade das espécies.
- Comparar o desempenho das estratégias propostas nas duas bases criadas.
- Desenvolver um protótipo para validar todos os experimentos.

## 1.4 Contribuições

As contribuições com o desenvolvimento desta pesquisa podem ser divididas em :

### **Sociais :**

- A criação das duas bases de imagens macroscópicas de espécies florestais (nativas e exóticas) presentes no território nacional.
- A diminuição de serviço dos órgãos competentes na identificação de madeira, dando subsídios aos órgãos fiscalizadores para tomar as medidas cabíveis de forma imediata, através de uma ferramenta que dê um grau de certeza no reconhecimento de espécies florestais, permitindo uma avaliação em campo.

### **Científicas :**

- Definição de um protocolo de aquisição das imagens em campo e sua comparação ao protocolo de laboratório, mostrando os limites de um sistema baseado em equipamentos de baixo custo.
- Análise de extratores de características de cor e textura para o problema em questão.
- Definição de uma abordagem baseada em estratégia de *dividir para conquistar* para resolução de problemas na aquisição das imagens.
- Publicações / socialização das bases de imagens adquiridas, seguindo dois protocolos distintos:

- Definição da estratégia de *dividir para conquistar* [24]
- Socialização parcial da base de imagens [22].
- Tratamento de cor e textura e regra de fusão por votação [23].
- Socialização das bases de imagens <sup>3</sup>.

## 1.5 Organização do Documento

O Capítulo 2 é composto pela fundamentação teórica dos aspectos estruturais da madeira e uma revisão sobre cor e textura; o capítulo 3 apresenta uma revisão bibliográfica acerca do reconhecimento de espécies florestais, reconhecimento de problemas em madeiras e análise de textura de forma geral, abordando as técnicas e resultados atingidos que deram subsídios e serviram de inspiração nas abordagens deste trabalho; já no capítulo 4 são apresentadas as bases de imagens criadas, bem como os protocolos para sua captura; o capítulo 5 apresenta a proposta do trabalho, descrevendo as técnicas e parâmetros usados para a resolução do problema; no 6º capítulo são apresentados os resultados experimentais, com as devidas taxas de reconhecimento que nortearam o trabalho; no capítulo 7 tem-se as conclusões e trabalhos futuros.

---

<sup>3</sup>Disponível em: [web.inf.ufpr.br/vri/forest-species-database-macroscopic](http://web.inf.ufpr.br/vri/forest-species-database-macroscopic)

## CAPÍTULO 2

### FUNDAMENTAÇÃO TEÓRICA

Grande parte das espécies florestais nacionais são provenientes da região Amazônica e, tanto toras, tábuas e lâminas são tratadas através de nomes populares comuns a cada localidade, podendo a mesma espécie possuir nomes populares distintos. Cada espécie possui particularidades que determinam as suas possibilidades de uso e o seu reconhecimento permite predizer quais são os melhores usos desta espécie florestal em questão, evitando gastos e problemas futuros [81].

Existem milhares de espécies florestais, porém o foco na identificação restringe-se a algumas centenas de madeiras comerciais, e sendo feito, de forma geral, através da observação de um conjunto de estruturas que as descreve, como frutas, flores e folhas, ou seja, a identificação assume que todas as partes relevantes da estrutura da planta estão presentes, porém, às vezes somente parte está disponível [10].

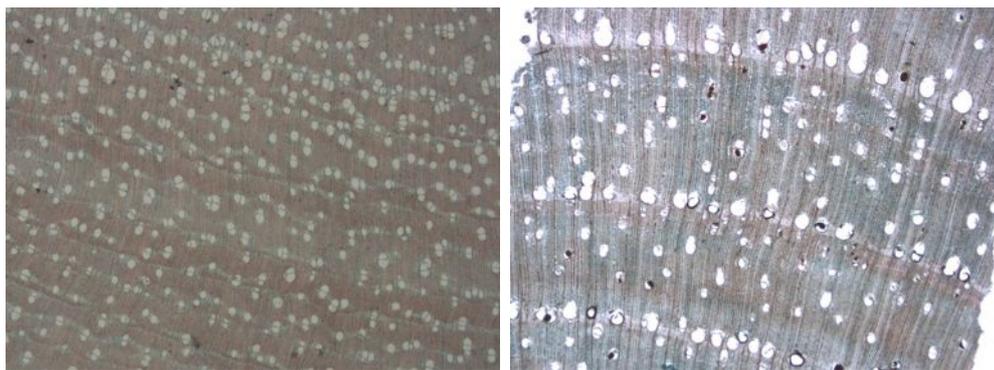
Core *et al* (1979) *apud* [81] afirmam que o processo de identificação científica de uma amostra de madeira é complexo, envolvendo diversas etapas. Inicialmente, são observadas características como cor, desenhos e densidade da amostra. Na sequência, é feita uma visualização anatômica macroscópica de itens como anéis de crescimento, raios, vasos e parênquima. Deve-se analisar, ainda, tipo de porosidade, largura e altura de raio, presença de estratificações, arranjo dos vasos e parênquima. Porém, mesmo assim, algumas espécies ainda precisam ser identificadas através de uma análise microscópica.

Para o entendimento de algumas dessas características, o presente capítulo se apresenta, e são abordadas as formas de como as espécies são identificadas pelos especialistas em anatomia da madeira.

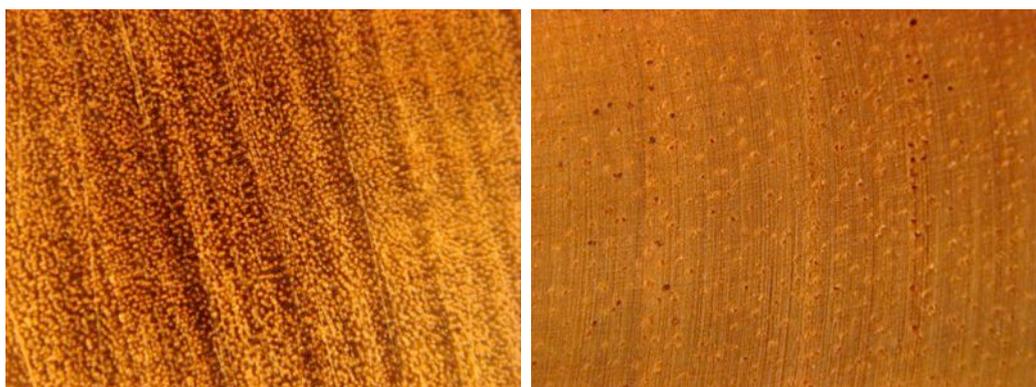
#### 2.1 Propriedades Organolépticas da Madeira

As propriedades organolépticas são aquelas que estão diretamente ligadas ao valor decorativo ou ornamental do lenho e perceptíveis pelos órgãos sensoriais: cor, odor, desenho, brilho, textura e grã, ou seja, todas as características que podem ter influência positiva ou negativa no emprego de madeiras para os fins desejados. Tais características são consideradas macroscópicas, ou seja, vistas a olho nu, ou com ajuda de uma lupa com ampliação de no máximo  $10\times$  [101, 92]. As imagens, cuja ampliação seja superior, são ditas microscópicas. A Figura 2.1 mostra essas diferenças.

Para uma boa identificação das propriedades organolépticas, deve-se assumir um protocolo de ações para a extração destas características. Uma dessas ações é o plano de corte.



(a) Imagens Microscópicas



(b) Imagens Macroscópicas

Figura 2.1: Ipê (*Handroanthus* sp - esquerda) e Cedro (*Cedrela fissilis* - direita)

Paula & Alves [92] comentam que a madeira é um material anisotrópico, ou seja, não apresenta as mesmas propriedades em todas as direções. Assim, como diferentes aspectos da estrutura celular são revelados em direções distintas, exige-se o estudo da anatomia da madeira em três diferentes planos, representados pela Figura 2.2, e a Figura 2.3 apresenta imagens desses cortes em amostras de *Pittosporum angustifolium*:

- Transversal (X): perpendicular ao eixo axial da árvore. Nesta superfície aparecem os anéis de crescimento, vasos (dependendo de seu tamanho) e raios.
- Longitudinal Radial (R): na direção axial, paralelo ao eixo maior do tronco e paralelo à direção dos raios lenhosos, e ainda perpendicular aos anéis de crescimento;
- Longitudinal Tangencial (T): na direção axial, paralelo ao eixo maior do tronco e em ângulo reto ou perpendicular aos raios lenhosos e ainda tangencial aos anéis de crescimento.

Para os anatomistas, a cor é uma propriedade de importância secundária na identificação, e sua variação se dá devido à impregnação de substâncias orgânicas nas células e nas paredes celulares. Uma mesma espécie pode sofrer variações de cor devido a questões naturais que ocorrem com a umidade, luz, posição na árvore e influência do solo no crescimento, ou ainda ao estado sanitário da árvore [81].

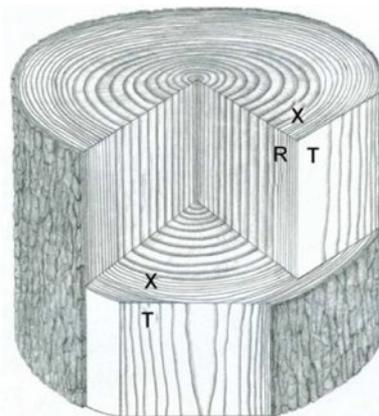


Figura 2.2: Planos de Corte [41]

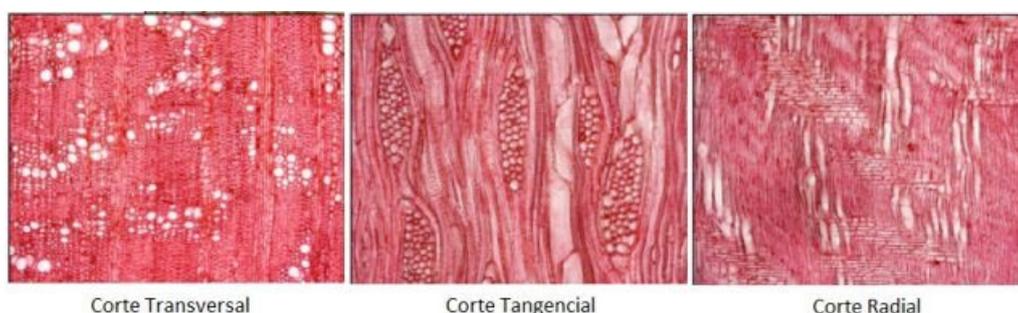


Figura 2.3: Exemplo de planos de corte de *Pittosporum angustifolium* - (escala = 125  $\mu\text{m}$ ) [10]

A textura da madeira é dada pelo conjunto de dimensões, distribuição e percentagem dos elementos estruturais que formam o lenho, sendo que em folhosas o que predomina são o diâmetro dos vasos e largura dos raios. Esta textura pode ser classificada em grossa, média e fina. Na grossa estão incluídas madeiras de vasos grandes e visíveis a olho nu, parênquima axial contrastante ou raios largos. Já na fina, aparecem as madeiras cujos elementos são de dimensões pequenas, e encontrados de forma difusa, apresentando uma superfície homogênea e uniforme [14]. Na Figura 2.4 são apresentadas amostras de texturas finas, médias e grossas, Figuras 2.4a, 2.4b e 2.4c, respectivamente <sup>1</sup>.

## 2.2 Propriedades Anatômicas da Madeira

A madeira é um conjunto heterogêneo de diferentes tipos de elementos com características próprias que desempenham funções de condução de líquidos, transformação, armazenamento e transporte de substâncias nutritivas e sustentação do vegetal [14]. Algumas estruturas são descritas a seguir:

Os **anéis de crescimento** surgem pela diferença entre a madeira formada no início do período vegetativo, normalmente, primavera, em regiões de clima temperado, e suas

<sup>1</sup>Disponível em: <http://rondoville.com.br/caracteristicas-das-madeiras>

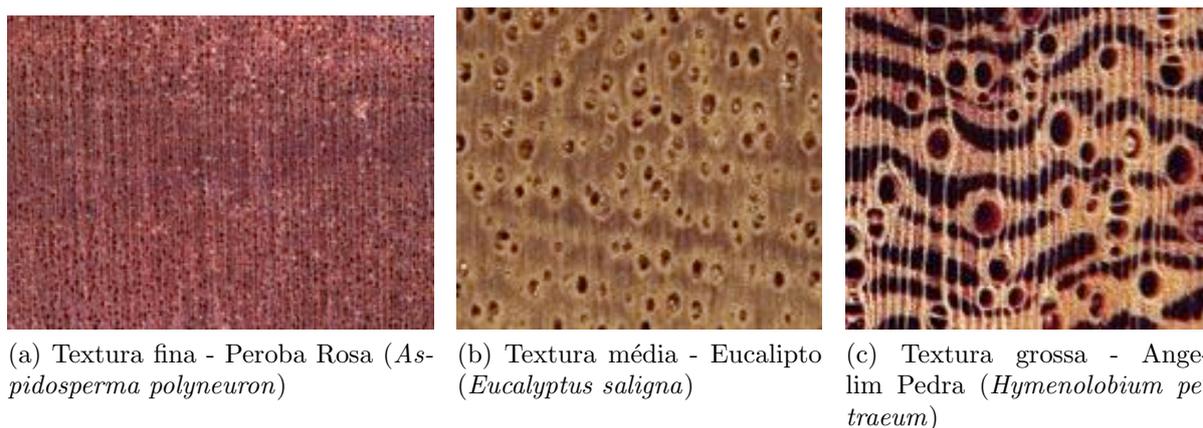


Figura 2.4: Exemplo da classificação de textura na área madeireira

células apresentam paredes finas e lumes grandes, conferido-as uma coloração clara. Já no final deste período, normalmente outono, as células vão diminuindo paulatinamente sua atividade fisiológica, tornando suas paredes gradualmente mais espessas e os lumes menores, apresentando uma tonalidade mais escura que as de início do período vegetativo [81].

O **cerne** representa a parte central de um tronco e é formado à medida que a árvore cresce; as partes internas perdem gradativamente sua atividade vital e adquirem uma coloração mais escura devido à deposição de tanino, resinas, gorduras, carboidratos e outras substâncias. Já o **alburno** representa a parte de maior atividade fisiológica da planta, uma vez que o fluxo ascendente de líquidos retirados do solo ocorre nos anéis de crescimento mais externos [14].

O **vaso** é um conjunto de células sobrepostas que forma uma estrutura tubiforme contínua, que tem a função da condução ascendente de líquidos na árvore, em geral, esse tipo de estrutura só ocorre em folhosas, sendo um forte elemento de identificação entre folhosas e coníferas. Quando esse tipo de estrutura se apresenta na seção transversal, recebe o nome de **poros** e sua forma de distribuição, tamanho e agrupamento são características que ajudam no reconhecimento da espécie [81].

O **parênquima** pode ser axial ou radial, e tem a função de armazenar materiais de reserva, como gorduras e amido, sendo de grande importância na identificação macroscópica. O parênquima radial pode ser denominado como **raio** ou parênquima transversal, e é um agrupamento de células que tem eixo longitudinal orientado perpendicularmente ao eixo da árvore [81].

Algumas dessas estruturas podem ser observadas através das Figuras 2.5 e 2.6.

O método mais comumente empregado para a classificação, tanto macro como microscópica de madeiras, é o de chaves de identificação (normalmente dicotômicas). Através delas pode-se chegar à identificação em nível de família, gênero ou até espécie. Como seu nome sugere, trabalha oferecendo duas alternativas em cada destinação e a escolha de

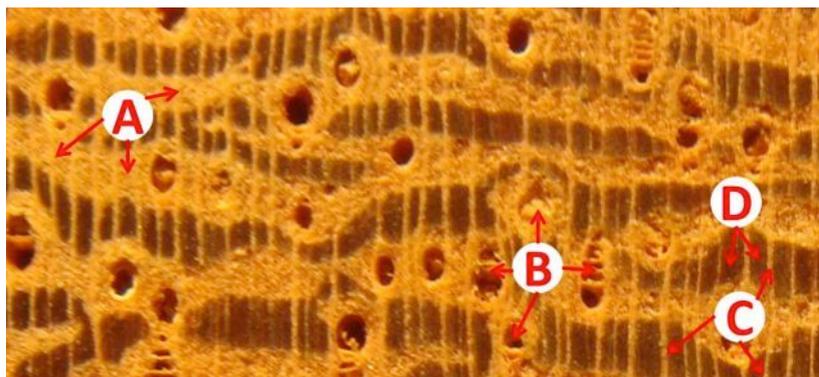


Figura 2.5: Estruturas anatômicas - Angelim (*Hymenolobium petraeum*) - sendo que A representa o parênquima, B os vasos, C os raios e D fibra

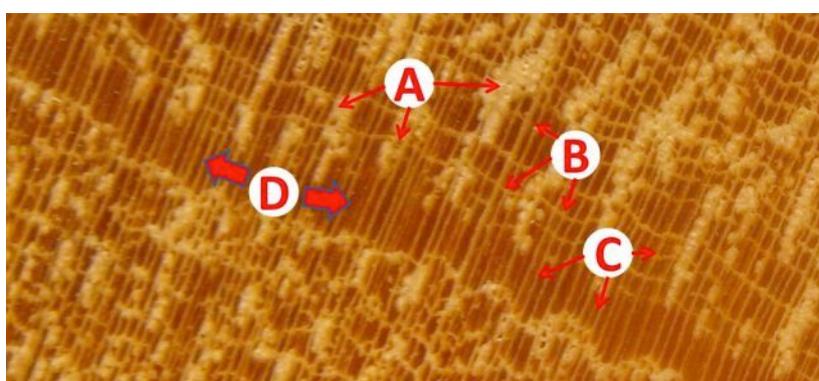


Figura 2.6: Estruturas anatômicas - Goiabão (*Planchonela pachycarpa*) - sendo que A representa os vasos, B os parênquimas (linhas), C os raios (colunas) e a faixa apontada em D representa anel de crescimento

uma das alternativas determina a etapa seguinte, até que se encontre à qual espécie determinada madeira pertence [14]. Neste processo, os anatomistas analisam as características anatômicas verificando a existência ou não de certas estruturas, elementos e suas distribuições. Porém, computacionalmente, essa análise é subjetiva, podendo variar bastante. Logo, este trabalho visa auxiliar nessa classificação por meio de uma ferramenta que permita o reconhecimento das espécies, porém não através da identificação das estruturas anatômicas da madeira, e sim, através de sua textura e cor.

### 2.3 Cor

Apesar da cor ser uma propriedade de importância secundária na identificação para anatomistas da madeira, ela é uma propriedade importante na análise de imagens realizada pelos seres humanos, seja com ou sem o auxílio do computador [94, 66].

Segundo Yu *et al* [119], a cor, comparada com outros atributos, é muito estável, insensível à rotação, escala e a outros tipos de deformação, mostrando robustez com vantagem de ser de cálculo simples.

Forsyth *et al* [34] descrevem que a representação de uma cor tem uma importância comercial muito grande, sendo que alguns produtos estão associados a cores muito próximas. Porém, é difícil haver uma uniformidade, pois a interpretação de cor para as pessoas varia dentro de uma faixa muito grande, e para que houvesse uma padronização na forma de tratar as cores, foram definidos “espaços de cores”, ou ainda, chamados de “modelos de cor” ou “formatos de cor”

O RGB (*red*, *green* e *blue*) é um dos espaços mais comuns, é de formação aditiva, utilizado em câmeras e monitores de vídeo. Este canal baseia-se na teoria de visão colorida tricromática de Young-Helmholtz, que provou que todas as cores do espectro visível poderiam ser representadas com a soma de três cores primárias, pois, o olho humano é formado por três tipos de receptores de cor, e estes respondem mais aos comprimentos de onda vermelho (R), verde (G) e azul-violeta (B). Conhecido também como cubo de cores, no qual os seus oito vértices são formados pelas três cores primárias, as secundárias (ciano, magenta, amarelo) e mais o preto e o branco [36]. A Figura 2.7a representa esse modelo.

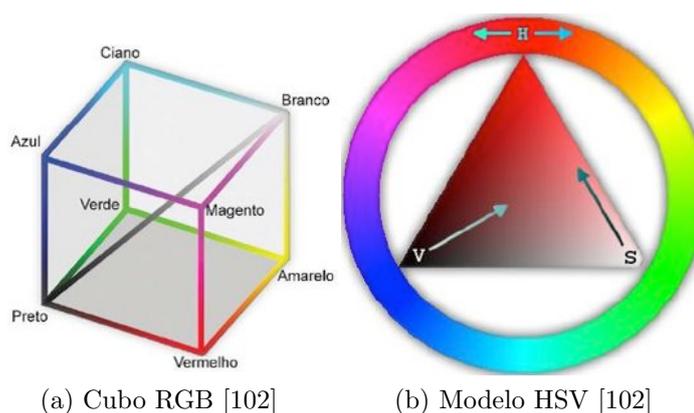


Figura 2.7: Modelos de cor RGB e HSV

Os canais de cores HSV (*Hue*, *Saturation* e *Value*), HLS (*Hue*, *Luminance* e *Saturation*) e HSI (*Hue*, *Saturation* e *Intensity*) são, normalmente, vinculados a pintores por utilizar três componentes presentes em diversas técnicas de pintura: Matiz, Saturação e Iluminação ou Intensidade ou Valor (adquirido através do brilho na imagem). Nesta “família de cores”, a matiz é angular e os outros componentes são lineares. Apesar de também não ser perceptualmente uniforme, seu uso é interessante por conter informações que são perceptíveis e discriminantes para um observador [3, 11, 107]. A Figura 2.7b representa esse modelo.

Na opinião de Yu *et al* [119], esta família se destaca dos outros modelos em análise e processamento de imagem devido a três importantes características. A primeira é que o valor (*V*) pode ser separado dos componentes de cor (matiz e saturação), segunda, que a matiz e saturação trabalham de forma equivalente com o modo pelo qual as pessoas

percebem a cor e por fim a utilização ponderada de fatias de seus componentes é bem ajustada a algoritmos de análise de imagem.

O modelo de cores XYZ é um sistema aditivo e baseia-se em cores primárias imaginárias X, Y e Z, e foi proposto em 1931 pela CIE, pressionada pelo desenvolvimento do filme fotográfico colorido, devido à inexistência de um conjunto finito de cores primárias que produzisse todas as cores visíveis possíveis. Suas cores são definidas matematicamente, e são compostas pela variação de três comprimentos de onda definidos 700 nm, 546,1 nm, 435,8 nm correspondentes a toda a percepção humana de cores [107]. Para cada um dos canais existe um limite da variação definido pelo comprimento da onda: 0~700 (X), 0~546,1 (Y) e 0~435,8 (Z). Qualquer cor pode ser definida apenas pelas quantidades dos elementos de X e Y normalizados, que são chamadas de coordenadas de cromaticidade por dependerem apenas do matiz e da saturação. A descrição completa de uma cor é dada pelas coordenadas de cromaticidade e pelo valor de um dos três estímulos originais, normalmente do Y, que contém a informação de luminância [63, 65]. Na Figura 2.8a tem-se uma representação gráfica do canal XYZ.

Os modelos de cor CIELAB e CIELUV foram definidos pela CIE (*International Commission on Illumination*), em 1976, na tentativa de aumentar a uniformidade das cores percebidas pelo sistema visual humano, sendo que o objetivo era proporcionar cores bem definidas, independente de qual dispositivo fosse ser usado. Algumas vezes são representados pelas siglas  $L \times a \times b$  e  $L \times u \times v$ , e o L indica o valor da luminosidade corrigida para uma escala perceptualmente linear, variando de branco a preto, e sendo igualmente definido em ambos os sistemas e os outros componentes (A, B ou U, V) são os elementos de cromaticidade [65]. O modelo CIELUV é um sistema aditivo, já o CIELAB é subtrativo, sendo que a luz é absorvida por colorantes, tais como tintas e pigmentos. No modelo CIELAB, o valor de  $a$  pode variar de verde a vermelho e o valor de  $b$  pode variar de azul a amarelo, analogamente à percepção das cores pelo cérebro. As Figuras 2.8b e 2.8c representam esses modelos.

## 2.4 Textura

A análise de textura tem sido usada desde os anos 60, e em geral, é descrita como sendo um conceito nebuloso, frequentemente atribuído à percepção humana, em que cada pessoa tem sua própria percepção, que não tem definição matemática e ela simplesmente existe. Alguns estudos mostram que para o reconhecimento de objetos no mundo real, o sistema visual humano depende parcialmente da percepção de consistência e diferença textural [6, 66, 83].

Segundo Parker [89], ao se observar uma imagem, é possível facilmente conectar regiões com similaridade nos tons de cinza, ou ainda, objetos coloridos, mesmo com variações de luminosidade ou sobreposição de objetos. Para buscar a definição de como descrever uma

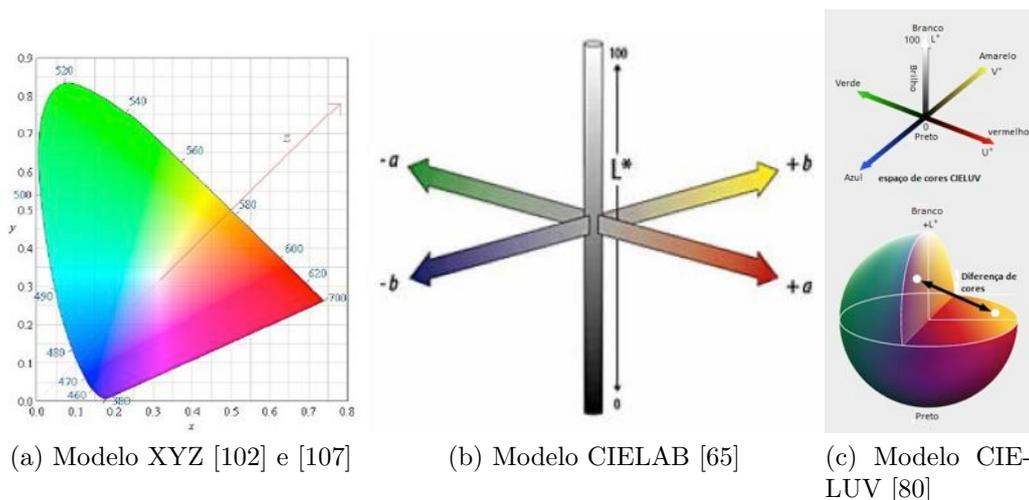


Figura 2.8: Modelos de cor XYZ, CIELAB e CIELUV

região dentro de uma imagem, a forma natural é interpretar como o sistema visual humano o faz, e ele usa a textura como sendo uma dessas formas. A textura é a característica visual mais importante para identificação de estruturas homogêneas em uma imagem, pois suas propriedades representam a superfície ou estrutura de um objeto, podendo estabelecer um relacionamento de vizinhança através de seu posicionamento entre os demais (conectividade), o agrupamento espacial (densidade) e sua regularidade (homogeneidade) [15, 94, 107, 115].

Haralick *et al* [40] descrevem que tons e texturas estão sempre presentes em uma imagem, e eventualmente, um sobrepõe o outro, ou seja, se em um pequeno pedaço da imagem houver pouca variação dos tons de cinza, o tom é dominante, e no inverso, é a textura. Nessa vertente, uma imagem pode ser considerada como um mosaico de textura e características dessa textura podem ser utilizadas para indexar os dados desta imagem. Devido a sua importância para vários tipos de imagens, a textura vem sendo uma ferramenta de grande relevância em suas análises, e com as melhorias computacionais, cada vez mais informações na forma de imagens têm sido armazenadas, gerando a necessidade de novas ferramentas de busca e recuperação. Para isso, a textura aparece como uma primitiva visual muito importante para esta busca e navegação por meio dessas coleções de imagens com características similares [39, 72].

Segundo Petrou & Sevilha [95], o estudo de textura é importante, pois pode ser um incômodo em visão computacional para a análise de formas de objetos se não for tratada, bem como pode apresentar informações valiosas para se conhecer de que material é composto algum objeto ou região. Na Figura 2.9 é apresentada uma imagem na qual a identificação automática das bordas é comprometida devido à textura.

Vários autores citam que não se tem uma definição aceita de forma global para textura [9, 18, 31, 83], porém, ela pode ser expressa como [18, 31, 36, 40, 94, 107]:

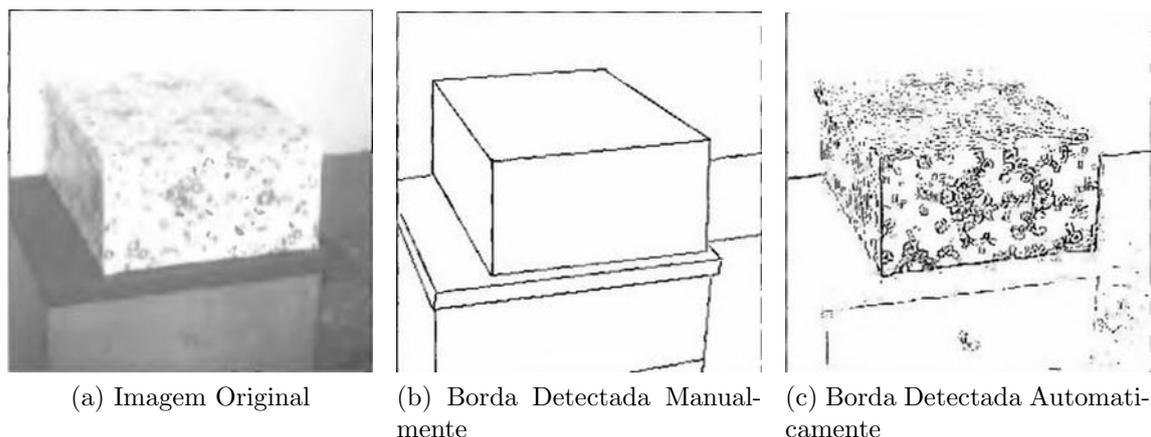


Figura 2.9: Exemplo da importância do tratamento da textura de uma imagem [95]

- “um conjunto de estruturas detalhadas, existentes nas superfícies físicas, perceptíveis ao olho humano, e que trazem grande quantidade de informações sobre a natureza da superfície”;
- “constituente de uma região macroscópica, em que sua estrutura é formada pela repetição de padrões, nos quais seus elementos ou primitivas encontram-se arranjados conforme uma regra de composição”;
- “algo que consiste de elementos mutuamente relacionados”;
- “estrutura composta por um grande número de elementos similares mais ou menos ordenados”;
- “uso de coeficientes de uniformidade, densidade, aspereza, regularidade, intensidade, dentre outras características da imagem”;
- “Se um conjunto de características estatísticas ou outras propriedades locais da imagem forem constantes, com pouca variação ou aproximadamente periódicas então está representada a textura”.

Logo, a textura é um fenômeno fácil de reconhecer e entender, porém difícil de conceituar. Apesar da falta de consenso em sua definição alguns autores concordam que a textura tem um conceito bidimensional, na qual em uma dimensão são tratadas as características da variação de intensidade de coloração entre os pixels vizinhos (primitivas de tonalidade - não homogêneas), e na outra, o relacionamento espacial entre essas primitivas, ou sua dependência (homogeneidade) [31, 9, 39, 34].

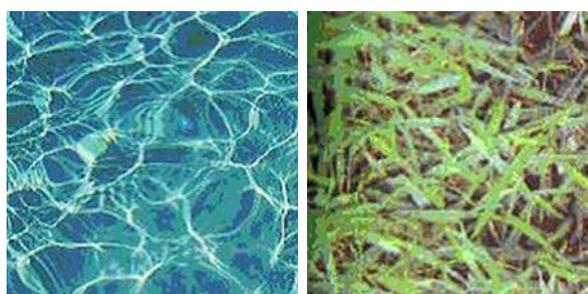
A textura não pode ser definida em um pixel, mas em uma região ou conjunto de pixels. Este conjunto descreve um padrão de variação de tons de cor (cinza) de uma região, representando a superfície de um objeto e, em geral, consiste de elementos de textura, ou ainda, primitivas de textura e a estes é dado o nome de texton [34, 107]. Segundo Liu &

Wan [37], o *texton* é um conjunto de manchas ou um padrão que emerge compartilhando uma característica comum sobre toda a imagem. O padrão do *texton* pode ser de forma precisa ou com variações, e estes elementos podem ser descritos como cor, altura, largura, orientação, entre outras; a variação como estes *textons* se relacionam deve ser suficiente para diferenciar duas texturas, sendo que a definição desses relacionamentos talvez seja a coisa mais importante para poder segmentar uma imagem por textura [75, 89].

Nixon & Aguado [83] comentam que assim como não existe uma única definição para a textura, não se tem uma única forma de descrevê-la e extraí-la. Para a descrição da textura, existem algumas abordagens, e segundo Gonzalez & Woods [36], as principais são: estatística, estrutural e espectral. Na abordagem estatística, classifica-a como suave, áspera, granular, entre outras, já a estrutural trata a imagem baseada em suas primitivas, como o paralelismo de linhas e seus espaçamentos, e as técnicas espectrais usam algumas propriedades do espectro de Fourier como detecção da periodicidade global dos picos de alta energia no espectro. Segundo Petrou & Sevilha [95], a textura pode ser regular ou irregular, demonstrado nas Figuras 2.10a e 2.10b, sendo que a maioria das texturas feitas manualmente são regulares e a maioria das naturais são irregulares. Para as regulares, a abordagem que melhor as descreve é a estrutural, e para as irregulares, as mais usadas são as estatísticas e espectrais.



(a) Texturas Regulares



(b) Texturas Irregulares

Figura 2.10: Tipos de Textura [18]

Segundo Sanchez *et al* [106], qualquer textura contém características tanto regulares quanto estatísticas, o que torna difícil usar um único método para identificá-la. Já Tomita & Tsuji [111] afirmam que não existe uma única forma para analisar qualquer textura.

## 2.4.1 Abordagem Estatística

A abordagem estatística é comumente usada para a análise de imagens naturais, pois estas possuem texturas com um certo grau de aleatoriedade e é mais facilmente modelada nessa abordagem. Na abordagem estatística, a textura é um apanhado de padrões de imagens que, com um conjunto de elementos estatísticos, pode-se descrevê-la. Esta foi uma das primeiras formas propostas para definir a qualidade da textura em uma distribuição espacial de valores em tons de cinza. Neste tipo de abordagem não se busca compreender explicitamente a estrutura hierárquica da textura, mas sim, representá-la através de propriedades estatísticas que definem a forma de distribuição e o relacionamento entre os níveis de cinza que a compõem. As várias formas de aplicar esta abordagem descrevem a textura através de grandezas, caracterizando-a em suave, áspera ou granular [36, 17, 115].

Segundo Alves & Araujo [5], a abordagem estatística pode ser dividida em duas vertentes, uma de primeira ordem, na qual se extraem atributos a partir de histogramas, e a de segunda, que é baseada no posicionamento relativo da ocorrência dos níveis de cinza. Os autores ainda destacam que a principal diferença entre as vertentes é que, tendo-se duas imagens com a mesma quantidade de níveis de cinza, mas com posicionamento diferente, na abordagem de primeira ordem tem-se um histograma idêntico, já na de segunda, os histogramas serão diferentes.

Haralick [39] propõe várias abordagens estatísticas para medir e caracterizar uma textura, dentre elas pode-se citar: funções de autocorrelação, bordas texturais, probabilidade de coocorrência espacial de níveis de cinza e comprimento da série de um nível de cinza. Já Pedrini & Schwartz [94] propõem ainda algumas outras medidas baseadas na distribuição dos níveis de cinza e no comprimento de sequência de cinza (*run length*).

Tucerian & Jain [115] citam que um grande número de técnicas de textura foram propostas e que elas não são independentes, o que pode ser visto na Figura 2.11, em que se tem o relacionamento de várias técnicas estatísticas de segunda ordem e a imagem original.

### 2.4.1.1 Medidas baseadas na distribuição de níveis de cinza

Como a forma mais simples para descrever uma imagem em níveis de cinza é o pixel, sua distribuição pode dar características como média, variância, desvio padrão, assimetria e curtose. Porém, para caracterizar o texton, geram-se relações de dependência entre as transições de dois ou mais pixels de sua vizinhança. Esse tipo de técnica tem como grande vantagem seu baixo custo computacional [94].

A média dos níveis de cinza e sua variação são conhecidas como momentos e são medidas de primeira ordem, sendo uma das abordagens mais simples para a descrição de texturas. Baseia-se em considerar  $z$  uma variável aleatória que demonstra a intensidade discreta de uma imagem e  $p(z_i)$  seu histograma. A equação 2.1 mostra o  $n$ -ésimo momento

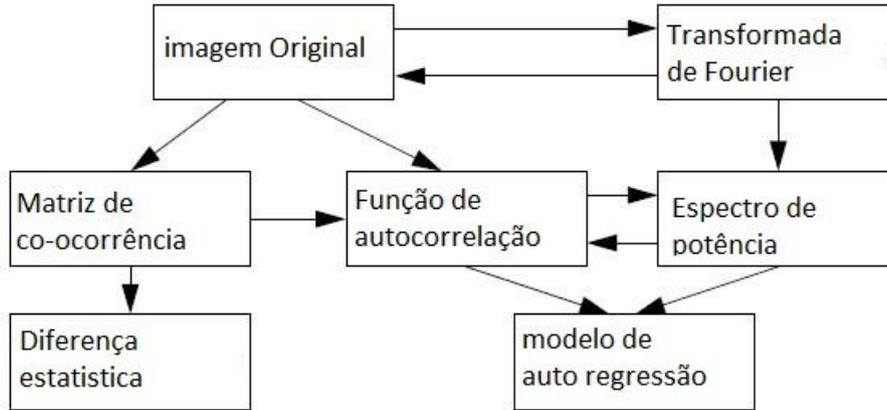


Figura 2.11: Relacionamento entre técnicas estatísticas de segunda ordem e a imagem Original [111]

de  $z$ , sendo  $L$  o número de níveis de intensidade e  $m$  é a intensidade média descrita através da equação 2.2. Segundo Gonzalez & Woods [36], o segundo momento (variância,  $\sigma^2(z)$ ) é particularmente importante para a textura, pois indica como estão distribuídas as intensidades dentro da região, seu espalhamento em torno do tom médio, ou seja, sua homogeneidade. Este momento pode definir descritores de suavidade relativa, e baseando-se na equação 2.3, pode-se obter valores próximos a zero para áreas de intensidade constante e próximos a um com grandes valores de variância [18, 36, 89].

$$\mu_n(z) = \sum_{i=1}^L (z_i - m)^n p(z_i) \quad (2.1)$$

$$m = \sum_{i=1}^L z_i p(z_i) \quad (2.2)$$

$$R = 1 - \frac{1}{1 + \sigma^2(z)} \quad (2.3)$$

O terceiro momento ( $\mu_3$ ) permite determinar uma medida de antissimetria do histograma (obliquidade - *skewness*) através da equação 2.8, e o resultado será maior que zero, caso a distribuição esteja agrupada abaixo da média, se for superior a zero, a concentração estará acima da média e tendendo a zero é aproximadamente simétrica [36].

O quarto momento ( $\mu_4$ ) calcula a medida de dispersão (curtose - equação 2.9), o que demonstra o achatamento ou planaridade da curva de distribuição. Caso este resultado seja igual a zero (mesocúrtica), então, tem-se um achatamento igual à distribuição normal, se for superior a zero (leptocúrtica), a distribuição é mais alta (afunilada) e concentrada que a normal e, no caso de ser inferior a zero (platicúrtica), a distribuição será mais achatada que a normal [36].

Uma forma de tratar estatisticamente os pixels é usar os valores de intensidade como

variáveis aleatórias. Por exemplo  $z_i$ ,  $i = 0, 1, 2, \dots, L - 1$ , para as  $L$  intensidades possíveis de uma imagem e a probabilidade da ocorrência de uma intensidade  $z_k$  é dada pela equação 2.4, em que  $n_k$  é o número de elementos na imagem com intensidade  $k$  e  $MN$  é a quantidade de pixels analisados. A partir desta probabilidade, outros importantes descritores podem ser conseguidos, como a média (descreve a intensidade média - equação 2.5), variância e desvio padrão (descrevem a dispersão dos dados em relação à média - equações 2.6 e 2.7, respectivamente), obliquidade (descreve a assimetria da distribuição em relação à média - equação 2.8), curtose (descreve o grau de *achatamento* da distribuição - equação 2.9) [36].

$$p(z_k) = \frac{n_k}{MN} \quad (2.4)$$

$$\mu = \sum_{k=0}^{L-1} z_k p(z_k) \quad (2.5)$$

$$\sigma^2 = \sum_{k=0}^{L-1} (z_k - \mu)^2 p(z_k) \quad (2.6)$$

$$\sigma = \sqrt{\sigma^2} \quad (2.7)$$

$$\nu = \left( \frac{\mu_3}{\sigma^3(z)} \right) \quad (2.8)$$

$$\kappa = \left( \frac{\mu_4}{\sigma^4(z)} \right) - 3 \quad (2.9)$$

A média dos níveis de cinza e sua variação são conhecidas como momentos e são medidas de primeira ordem, sendo uma das abordagens mais simples para a descrição de texturas. Baseia-se em considerar  $z$  uma variável aleatória que demonstra a intensidade discreta de uma imagem e  $p(z_i)$  seu histograma. A equação 2.1 mostra o  $n$ -ésimo momento de  $z$ , sendo  $L$  o número de níveis de intensidade e  $m$  é a intensidade média descrita através da equação 2.2. Segundo Gonzalez & Woods [36], o segundo momento (variância,  $\sigma^2(z)$ ) é particularmente importante para a textura, pois indica como estão distribuídas as intensidades dentro da região, seu espalhamento em torno do tom médio, ou seja, sua homogeneidade. Este momento pode definir descritores de suavidade relativa, e baseando-se na equação 2.3, pode-se obter valores próximos a zero para áreas de intensidade constante e próximos a um com grandes valores de variância [18, 36, 89].

Pedriani & Schwartz [94] ainda descrevem que outra forma para extrair medidas estatísticas são os histogramas (equação 2.10), sendo que  $h(i)$  representa a quantidade de ocorrência de um pixel de intensidade  $i$ , e  $n$  representa a quantidade de pixels na janela de

textura. E a partir do histograma, pode-se calcular a energia (equação 2.11) e a entropia (equação 2.12), sendo que  $H_g$  representa o tom de cinza máximo.

$$P(i) = \frac{h(i)}{n} \quad (2.10)$$

$$Energia = \sum_{i=0}^{H_g} (P(i))^2 \quad (2.11)$$

$$Entropia = \sum_{i=0}^{H_g} P(i) \lg(P(i)) \quad (2.12)$$

Gonzalez & Woods [36] citam que as medidas de textura calculadas com base em histogramas sofrem a limitação de não se ter informações relativas ao posicionamento dos pixels em relação a sua vizinhança, e por isso, não oferecem informações sobre a natureza repetitiva da textura. Para sanar isso, sugere que além da intensidade leve-se em consideração o seu posicionamento. Já em Conci *et al* [18] é sugerido o uso de métodos referentes a medidas de segunda ordem, que além de descreverem a distribuição, apresentam a relação espacial entre os pixels, sendo que o método mais usual é a matriz de coocorrência dos níveis de cinza (*gray level co-occurrence matrices - GLCM*) de uma imagem.

#### 2.4.1.2 Matriz de coocorrência

Segundo Nixon & Aguado [83], esta é a abordagem estatística mais famosa, sendo que a técnica consiste de experimentos estatísticos realizados sobre, como um certo nível de cinza ocorre em relação a outros níveis de cinza, gerando uma matriz, ou ainda, baseia-se na ocorrência repetida da configuração de alguns níveis de cinza na textura, sendo uma variação rápida em texturas finas, e lenta em ásperas.

Segundo Haralick [39], o primeiro a usar este método em textura foi Julesz [50], porém, alguns autores citam que o trabalho apresentado por Haralick *et al* [40] foi o precursor dessa técnica. Haralick sugeriu um conjunto de 14 características de textura que poderiam ser extraídas dessas matrizes (Tabela 2.1), e essas características podem informar a homogeneidade, a dependência linear, contraste, o número e a natureza dos perímetros presentes e a complexidade da imagem. Haralick *et al* [40] ainda citam ter conseguido uma precisão de classificação de 80 a 90%, logo, esta tem sido a técnica de textura mais usada e bem sucedida, ainda que, com variações quanto à forma como são calculadas as matrizes [18, 115].

Segundo Hammon & Strauser [38], a definição formal da GLCM encontrada sobre uma região de interesse (ROI - *Region Of Interest*) de uma imagem para uma determinada orientação é dada pela Equação 2.13, na qual  $I(m, n)$  representa a intensidade de níveis

de cinza nas coordenadas  $(m, n)$  da imagem;  $N_{a,b}$  representa o par de pixels cujos valores são  $a$  e  $b$  respectivamente;  $N$  o número total de pares na ROI;  $r_\theta$  o deslocamento radial entre os pixels e  $\theta$  a direção entre os pixels.

$$G_{a,b}(r_\theta, \theta) = \frac{N_{a,b}}{N} \approx Pr\{I(m, n) = a, I(m + r_\theta \cos\theta, n + r_\theta \sin\theta) = b\} \quad (2.13)$$

A técnica se baseia em que cada elemento da matriz  $N \times N$ , sendo que  $N$  é o nível máximo de tons de cinza, represente a frequência com que um pixel de intensidade  $i$  e outro de intensidade  $j$  ocorrem em uma imagem, desde que separados por uma distância  $d$  e um ângulo  $\theta$ , ou ainda separados por  $\Delta x$  colunas e  $\Delta y$  linhas. O tamanho da matriz é definido de acordo com a quantidade de tons de cinza presentes na imagem, logo, para que não seja comprometida a performance, é recomendável diminuir a quantidade de tons da imagem. Com a variação da distância e do ângulo podem ser obtidas diversas matrizes para se extrair informações para a análise da textura, denominados descritores [40].

Haralick *et al* [40] propõem que o ângulo  $\theta$  tenha a variação de acordo com a Figura 2.12. A informação de textura é dada pela matriz de frequência relativa  $p(i, j, d, \theta)$ , que indicará a probabilidade de ocorrer dois pixels  $(i, j)$  a uma distância  $d$  e relação angular  $\theta$  na imagem.

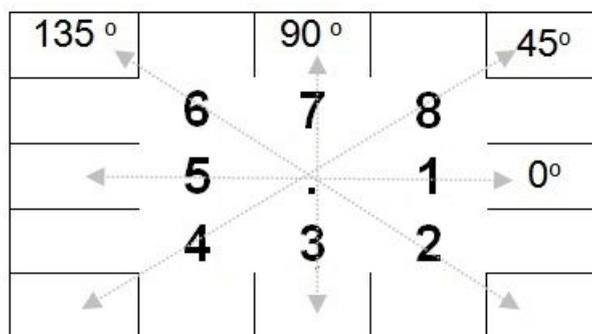


Figura 2.12: Ângulos utilizados para cálculo da matriz de coocorrência. Adaptado de [40]

As matrizes sozinhas não caracterizam as texturas, mas a comparação de alguns descritores ajuda a perceber a similaridade de duas texturas. Conci *et al* [18] descrevem que valores elevados na diagonal principal indicam predomínio de faixas na imagem com direção  $\theta$  e espessura média de múltiplos de  $d$ , e Liu & Yang [37] comentam que em uma textura grossa, a matriz tende a ter valores altos na diagonal principal e para texturas finas, tendem a ter valores espalhados.

Haralick [40] propõe 14 descritores baseados na distribuição do pixel, porém, segundo Baraldi & Pannigiani [8], apenas seis são relevantes, segundo momento angular, entropia, contraste, variância, correlação e homogeneidade.

Tabela 2.1: Descritores de Haralick [40]

<b>Característica</b>		<b>Descrição</b>	<b>Equação</b>
Probabilidade Máxima		Indica a direção mais importante da textura a ser examinada.	2.21
Entropia		Mede a informação contida em $p$ ; muitos valores nulos representam pouca informação.	2.15
Momento de diferenças de ordem $k$		Distorção da imagem. Apresenta valores pequenos se $p$ tiver valores maiores na diagonal principal.	2.22
Momento inverso de diferenças de ordem $k$		Inverso do contraste. Apresenta valores maiores se $p$ tiver valores pequenos na diagonal principal.	2.23
Energia ou uniformidade		Retorna a soma dos elementos elevados ao quadrado dentro da matriz. Varia de 0 a 1, tendendo a 1 em imagens constantes.	2.14
Variância ou contraste		Retorna uma medida do contraste entre as intensidades de um pixel analisado e do pixel vizinho. Para uma imagem constante o resultado será 0. Corresponde ao momento de ordem 2.	2.16, 2.17 e 2.18
Variância Inversa		Inverso do Contraste.	2.24
Correlação		Retorna o quão correlacionado está o pixel com seu vizinho, Varia entre -1 e 1, sendo que o 1º aparece em uma imagem completamente descorrelacionada.	2.19
Homogeneidade		Retorna um valor que representa a proximidade da distribuição dos elementos em relação a diagonal da matriz. Varia entre 0 e 1, sendo que 1 representa uma matriz diagonal.	2.20

$$energia = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (P(i, j))^2 \quad (2.14)$$

$$entropia = - \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j) \log P(i, j) \quad (2.15)$$

$$contraste = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - j)^2 P(i, j) \quad (2.16)$$

$$var_i = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - \mu_i)^2 P(i, j) \quad (2.17)$$

$$var_j = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (j - \mu_j)^2 P(i, j) \quad (2.18)$$

$$correlacao = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j) \frac{(i - \mu)(j - \mu)}{\sigma^2} \quad (2.19)$$

$$homogeneidade = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{P(i, j)}{1 + (i - j)^2} \quad (2.20)$$

$$PM = \max(P(i, j)) \quad (2.21)$$

$$momento = \sum_i \sum_j (i - j)^k p(i, j) \quad (2.22)$$

$$inverso = \sum_i \sum_j \frac{p(i, j)}{(i - j)^k} \quad (2.23)$$

$$VarianciaInversa = \sum_i \sum_j \frac{p(i, j)}{(i - j)^2}, i \neq j \quad (2.24)$$

Ito *et al* [47] propõem duas novas maneiras de mensurar as relações espaciais para a matriz de coocorrência, com o intuito de torná-la invariante à rotação. Sendo que uma das maneiras é através do cálculo das médias dos níveis de cinza sobre duas circunferências concêntricas e de raios distintos (MC), demonstrado na Figura 2.13a, e a outra, é através do cálculo das médias dos pixels sobre retas radiais em diversas orientações (MR), demonstrado na Figura 2.13b. Os autores descrevem que as médias sobre circunferências são inerentemente invariantes à rotação, o que não acontece com as linhas radiais, porém, os parâmetros estatísticos determinados a partir delas são.

Dacheng *et al* [19] descrevem uma variação da matriz de coocorrência para o espaço

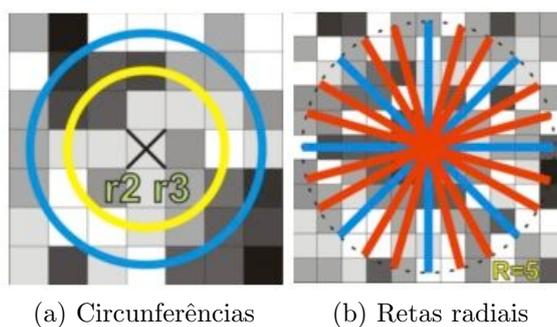


Figura 2.13: Representações das relações espaciais para a matriz de coocorrência [47]

tridimensional, permitindo descrever texturas coloridas, utilizando-se o espaço de cores HSV quantizando 8, 4 e 4 tons de cinza para os canais H, S e V, respectivamente, cujo objetivo principal é relacionar tanto os pixels vizinhos quanto descrever o relacionamento entre as bandas do HSV, gerando matrizes que resumam as transições de intensidade. Segundo os autores, para extrair atributos da matriz de coocorrência 3D, não se pode usar a distância 1 e ângulos de  $45^\circ$  graus, pois não descrevem bem a imagem, e por isso, sugerem nove direções e definiram que, cada pixel no plano H terá nove vizinhos correspondentes no plano S e mais nove no plano V (Figura 2.14).

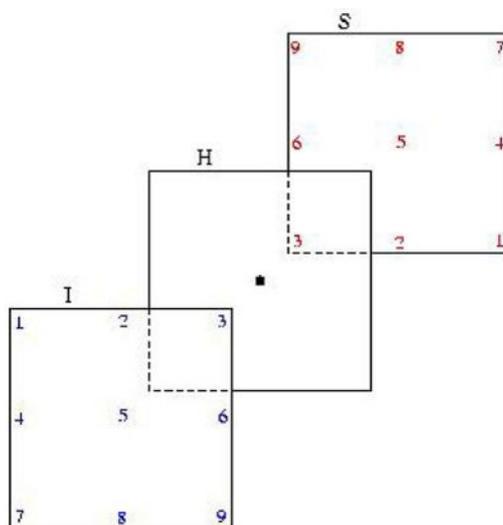


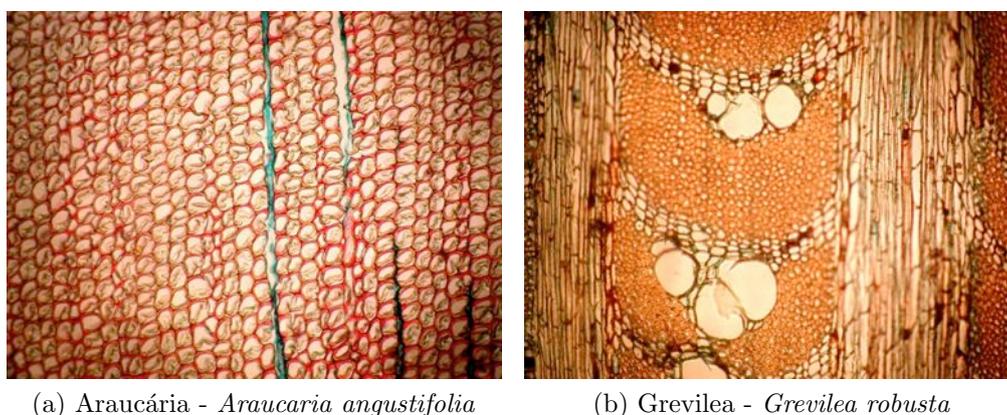
Figura 2.14: Vizinhança proposta para a matriz de coocorrência 3D [108]

Dacheng *et al* [19] adaptaram uma série de descritores e, baseados nas matrizes resultantes extraíram e compararam uma grande quantidade de características, entre elas: segundo momento angular, contraste, correlação, entropia. Obtendo resultados melhores que os de uma matriz normal.

Em Palm [88] também foi usada uma matriz de coocorrência tridimensional, porém, neste trabalho é utilizado o espaço LUV, sendo feito um relacionamento entre bandas, duas a duas e não considerando as três.

## 2.4.2 Abordagem Estrutural

Abordagens estruturais são consideradas apropriadas quando a primitiva de textura é grande o suficiente para ser individualmente segmentada e descrita. Nesse tipo de técnica, explora-se a noção da primitiva da textura, que é a estrutura geométrica básica que forma a textura, sendo que um conjunto de pixels é caracterizado pelos seus atributos, e a forma mais básica é o nível de cinza do pixel, e a mais complexa, é um conjunto conectado de pixels homogêneos [78]. Segundo Maeenpaa [66], nesta abordagem, a estrutura espacial da textura é enfatizada, sendo que um padrão local é repetido periodicamente, ou quase, sobre uma região, ou ainda, são primitivas de uma determinada forma com variação de tamanhos que se repetem. Dois exemplos podem ser observados nas Figuras 2.15a e 2.15b.



(a) Araucária - *Araucaria angustifolia*

(b) Grevilea - *Grevilea robusta*

Figura 2.15: Exemplos de fotos microscópicas de espécies florestais

A análise estrutural obtém os elementos de textura presentes na imagem, determinando seus formatos e estimando as regras de posicionamento, descrevendo como os elementos de textura são colocados em relação aos demais. A abordagem estrutural trata dos arranjos de primitivas de imagem e pode ser utilizada sempre que os elementos da textura forem claramente identificáveis.

Nesta abordagem, a ideia básica é a de que uma primitiva de textura simples possa ser usada na formação de padrões complexos de textura através de regras que limitem o número de arranjos possíveis. E uma forma simples de se mensurar a textura é extrair blocos de homogeneidade máxima e descrever a imagem em termos da estatística dos tamanhos dos blocos, podendo esta descrição ser hierárquica, ou seja, as primitivas podem ser compostas por outras primitivas. Logo, sendo descrita através de gramáticas estocásticas, nas quais as regras a serem aplicadas são escolhidas com base em uma função de densidade de probabilidade [78, 36].

A vantagem da abordagem estrutural é que ela provê uma boa descrição simbólica da imagem. Entretanto, essa característica é mais útil em tarefas de síntese do que em análise de textura.

### 2.4.2.1 Fractais

A geometria fractal e sua utilização para caracterizar texturas é uma área bastante promissora, permitindo identificar e classificar texturas com grande simplicidade e eficiência [18, 78].

Nos anos 70, Mandelbrot propôs uma maneira para descrever e tratar as estruturas irregulares e descontínuas da natureza, a geometria fractal. Sendo ela, uma ferramenta qualitativa e quantitativa capaz de lidar, eficientemente, com os dados espaciais ou temporais, descrevendo com maior precisão sua complexidade [42].

Uma importante característica das formas fractais é a sua autossimilaridade, ou seja, uma determinada forma, seja ela em grandes escalas (macroscópicas) ou em escalas menores (microscópicas), é formada por um mesmo conjunto de primitivas. Logo, qualquer forma autossimilar pode ser dividida em  $N$  elementos menores dela mesma, de tal forma que possam ser escalonadas por um fator  $s$ . Logo, um fractal, ou ainda, uma estrutura fractal, é por definição uma estrutura em que as partes que a compõem se assemelham com o todo, ou seja, existem partes similares que, estatisticamente, podem ser encontradas dentro da estrutura global. Isto indica a presença do fenômeno de escala e de um nível de tendência, o qual pode ser medido através da dimensão fractal, que é uma medida de complexidade [42, 99].

Assim, o reconhecimento de um fractal baseia-se na caracterização da autossimilaridade associada aos objetos, que é uma característica que os objetos fractais possuem, cada pequena porção sua pode ser analisada como uma réplica reduzida do todo. Existem diversos índices considerados em geometria fractal que podem quantificar as texturas ou as propriedades dos objetos fractais, tais como dimensão fractal, lacunaridade e sucolaridade [18].

A dimensão fractal é uma medida que quantifica a densidade dos fractais em um determinado espaço métrico em que são definidos e serve para compará-los; já a lacunaridade é caracterizada pela regularidade dos vazios, sendo muito importante para caracterizar as texturas, e a sucolaridade utiliza o nível de percolação ou interligação entre os vazios em diversas direções [74].

A lacunaridade e a sucolaridade são variações de métodos fractais que permitem diferenciar objetos fractais com mesma dimensão, mas com aparências diferentes [18].

### Dimensão Fractal

Segundo Backes *et al* [7], a dimensão fractal é um valor capaz de representar o nível de ocupação do espaço e a irregularidade do objeto, sendo ela a maneira mais utilizada de quantificar a complexidade de uma imagem, ou seja, o quão irregular um objeto é, ou quanto espaço este ocupa. Devido a sua eficiência em separar áreas de texturas diferentes,

ela é bastante utilizada para determinar a rugosidade da superfície, na classificação de imagens, na distinção entre tipos de paisagens, na detecção de bandas espectrais ruidosas, na determinação da escala operacional de fenômenos naturais em imagens digitais, no escalonamento aplicado às extensões espaciais em sensoriamento remoto, na análise de superfícies fraturadas, desgaste e erosão, corrosão, dentre outras [18, 42].

Segundo Melo [74], existem várias formas de se abordar a dimensão fractal, tais como: dimensão de similaridade ( $D_s$ ), dimensão de Hausdorff ( $DH$ ), dimensão *Box counting* ( $DB$ ), dimensão de informação ( $DI$ ), dimensão de correlação ( $DC$ ), dimensão *pointwise* ( $DP$ ) e dimensão da média de *pointwise* ( $DA$ ).

A  $D_s$  é uma das formas mais intuitivas para associar-se escala e autossemelhança, sendo que um objeto de  $d$  dimensões pode ser dividido em  $N$  partes iguais, sendo cada parte igual a anterior, dada uma escala de fator  $\delta = \frac{1}{N}^{\frac{1}{d}}$ , e  $N \times \delta^d$  irá reconstruir o objeto, e sendo todas as partes, a  $D_s$  será igual a 1. Logo,  $D_s$  pode ser descrito através da equação 2.25, em que  $N$  é o número de partes para reconstruir a imagem original e  $d$  é a relação entre os passos consecutivos.

$$D_s = \frac{\log N}{\log\left(\frac{1}{\delta}\right)} \quad (2.25)$$

Em Melo [74] é demonstrado, através de várias imagens, o cálculo da dimensão de similaridade e sua simplicidade, podendo aplicá-lo quando se conhece as regras de construção do objeto e todas as partes têm a mesma relação. Porém, isso só ocorre quando se tem fractais determinísticos, já objetos complexos como nuvens, árvores, folhas, entre outros, exigem outras formas de medir a dimensão fractal, como a dimensão de compasso, dimensão de caixa ou dimensão de grid.

A dimensão de Hausdorff ( $DH$ ), segundo Melo [74], é matematicamente conveniente, porém, em alguns casos, pode ser difícil de ser obtida computacionalmente.

O teorema da contagem de caixas (*Box counting Theorem*) é uma forma simples para estimar a dimensão fractal de imagens, sendo que a ideia baseia-se em cobrir a imagem com caixas de tamanho  $d$ , e a quantidade de caixas ( $N$ ) necessárias para cobri-la refere-se a  $DB$ . Segundo Falconer [30] esta é a dimensão mais usada, dada sua facilidade de uso. Para medir a dimensão deve-se colocar uma malha regular de tamanho  $d$  sobre a imagem original (Figuras 2.16a, 2.16b e 2.16c) e contar o número de caixas ocupadas, obtendo-se  $N(d)$ . Então, muda-se progressivamente o  $d$  para tamanhos menores e conta-se novamente o  $N(d)$  e na sequência, plota-se um gráfico com parâmetros  $\log(N(d))$  e  $\log\left(\frac{1}{d}\right)$  (Figura 2.16d) e a linha que representa o declive é a  $DB$ , que segundo Melo [74], é dado pela equação 2.26.

$$D_B = \frac{\log\left(\frac{N_2(\delta)}{N_1(\delta)}\right)}{\log\left(\frac{\delta_2}{\delta_1}\right)} \quad (2.26)$$

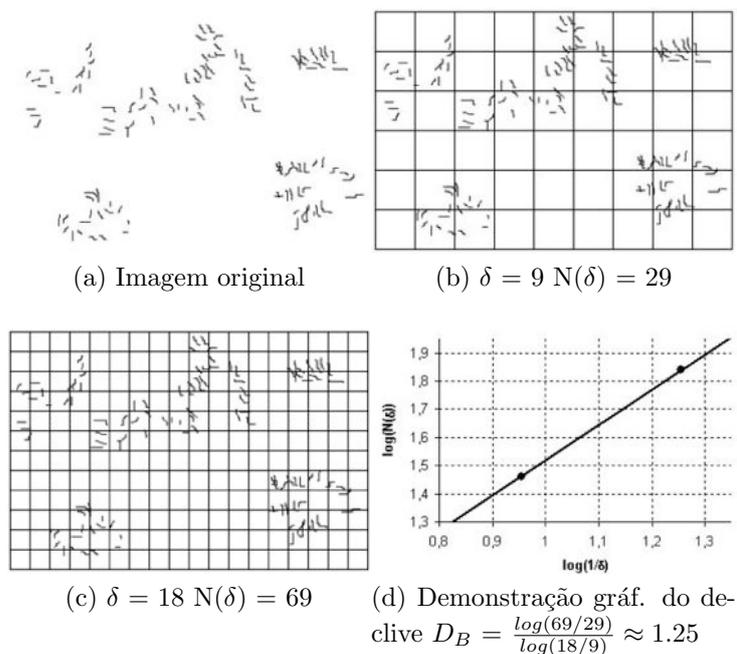


Figura 2.16: Demonstração do funcionamento da dimensão *box counting* [74]

Para imagens em tons de cinza, deve-se tratá-las como objetos 3D, e a terceira coordenada representa a intensidade do pixel. Como exemplo, os autores consideram uma imagem  $M \times M$  (Figura 2.17), dividida em grades de  $s \times s$ , e cada hipercubo é calculado o  $N(\delta)$  para, no fim, dada a equação 2.26 calcular-se o DB [18].

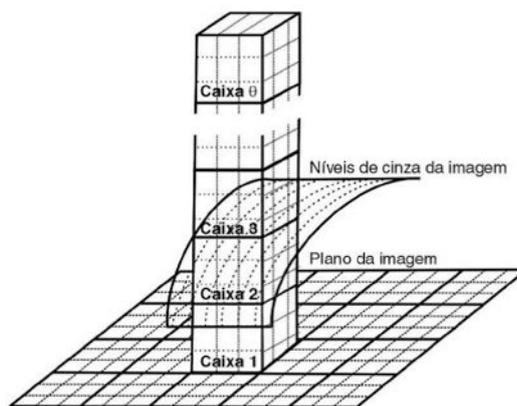


Figura 2.17: Divisões em uma imagem em tons de cinza para o cálculo da  $D_B$  [18]

Em imagens coloridas, pode-se estender esse método tratando a imagem como sendo composta por  $d$ -cubos, modelados em um espaço  $R^5$ , gerando-se divisões recursivas em partes cúbicas de tamanho  $r$ . Obtendo-se, então, um modelo de 5-cubos de lados iguais (L1, L2, L3, L4 e L5), sendo que L1 e L2 correspondem aos eixos das coordenadas  $x, y$  da matriz de pixels da imagem e L3, L4 e L5 correspondem à intensidade de cor em um canal, como por exemplo, o canal RGB [18].

Outra forma de se estimar a dimensão é denominada dimensão de informação, que

tem a idéia parecida com a  $D_B$ , porém nessa forma leva-se em conta quanto do conjunto está contido dentro de cada um, em vez de simplesmente contar os cubos. Dado pela equação 2.27, em que  $I(\delta)$  refere-se a entropia de Shannon dada pela equação 2.28 e  $P_i$  é a probabilidade de parte do conjunto ocorrer no  $i$ -ésimo cubo de tamanho  $\delta$  [74].

$$D_I = \lim_{\delta \rightarrow 0^+} \left[ \frac{I\delta}{\log(\frac{1}{\delta})} \right] \quad (2.27)$$

$$I(\delta) = - \sum_{i=1}^N P_i \log(P_i) \quad (2.28)$$

Alternativa de estimativa da dimensão fractal apontada por Melo [74] é a dimensão de correlação, que segundo o autor, requer menos tempo computacional, pois inicialmente calcula-se a soma da correlação, dada pela equação 2.29, sendo que  $\theta$  é a função de Heaviside,  $r$  é o raio de uma esfera de  $n$ -dimensões centrada em cada elemento da trajetória  $X_i$ , que representa um vetor multidimensional.

$$C_r = \frac{1}{N(N-1)} \sum_{i=1}^N \sum_{j=1; j \neq i}^N \theta(r - |X_i - X_j|) \quad (2.29)$$

Em outras palavras, Melo [74] descreve que o cálculo da soma da correlação envolve a perseguição da trajetória de referência, parando a cada ponto discreto desta trajetória, e então, contam-se o número de outros pontos do conjunto que tenham um raio  $r$ . A soma acumulativa é, então, dividida por  $N(N-1)$ , conseguindo-se, então, a soma da correlação. Dada essa soma e o raio da esfera tem-se a equação 2.30 que permite o cálculo da dimensão de correlação ( $D_c$ ).

$$D_c = C_r \alpha r_C^D \quad (2.30)$$

Segundo Melo [74], verificando-se o conjunto de dados descrito por diferentes raios da esfera, o  $D_c$  é obtido através do declive apresentado na Figura 2.18, e os eixos  $x$  e  $y$  são representados pelo  $\log(r)$  e  $\log(C_r)$ , respectivamente.

## Lacunaridade

Segundo Mandelbrot *et al* [71], as características e propriedades de um conjunto de dados fractais estão longe de ser completamente determinadas usando-se apenas sua dimensão fractal, pois alguns fractais podem ter a mesma dimensão fractal, porém, diferentes formas. Para tanto, uma propriedade chamada lacunaridade demonstra a distribuição de valas, ou buracos, na imagem.

A lacunaridade é uma medida multiescalar que descreve o complexo entrelaçamento de

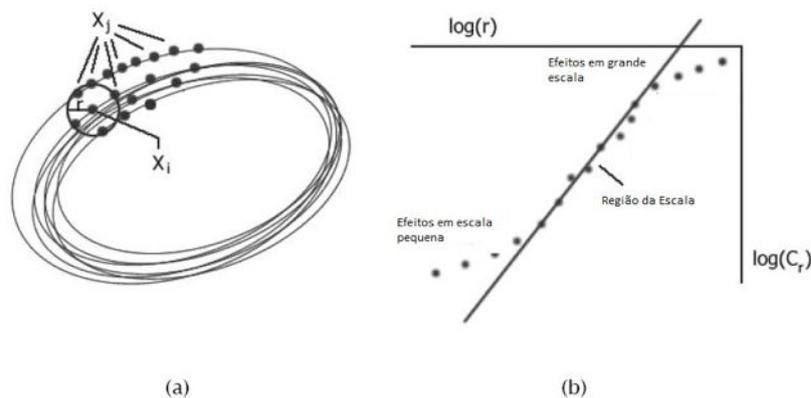


Figura 2.18: Determinação da dimensão de correlação. a) Sondagem da esfera no conjunto. b) plotagem do  $\log(r) \times \log(C_r)$  [74]

forma e a distribuição de vazios com a imagem, quantificando o desvio da forma geométrica da invariância de translação, obtendo bons resultados quando usado com imagens binárias [28].

O conceito foi estabelecido e desenvolvido, segundo Barros Filho & Sobreira [32], da necessidade científica em analisar padrões de textura multiescalar na natureza como uma possibilidade de associar padrões espaciais em vários diagnósticos relacionados.

A lacunaridade é uma característica distinta e independente da dimensão fractal, sendo considerado um complemento da dimensão de fractal para descrever a textura de uma imagem. Ela descreve como se dá a distribuição e tamanho dos vazios, de maneira geral, se um fractal tem grandes vazios, tem lacunaridade alta, caso os vazios ou buracos sejam pequenos, tem baixa lacunaridade [74].

Segundo Ivanovici & Richard [48], a lacunaridade é a entropia dos pontos de uma superfície discreta que representa uma imagem, ou ainda, ela é a “dança” da luminosidade no eixo  $z$ .

Uma textura áspera será muito lacunar (valores altos de heterogeneidade) e a baixa lacunaridade, geralmente, indica homogeneidade. A lacunaridade é uma ferramenta analítica poderosa, principalmente se associada à análise fractal, permitindo analisar densidade, agrupamento ou dispersão [32, 71].

Esta característica utiliza o nível de cinza como outra dimensão para que possa ser usado como um novo recurso no processo de reconhecimento de padrões tornando-a, assim, muito eficaz para a identificação de texturas naturais [74].

Existem vários algoritmos para calculá-la em uma imagem, porém, entre eles, os que mais se destacam são o *Gliding-Box* e o *Differential Box-Counting* [32].

O algoritmo de *Gliding-Box* (*GB*) é usado para analisar a distribuição de massa. Nele, uma caixa de tamanho  $r$  passa sobre a imagem e o número do *gliding-box* com raio  $r$  e massa  $M$  é definido como  $n(M,r)$  e a probabilidade  $Q(M,r)$  é obtida através da divisão de  $n(M,r)$  pela quantidade de caixas. A equação 2.31 descreve a forma de cálculo da

lacunaridade [77].

$$L(r) = \frac{\sum_M M^2 Q(M, r)}{[\sum_M M Q(M, r)]^2} \quad (2.31)$$

Segundo Barros Filho & Sobreira [33], este algoritmo apenas conta o fundo em imagens binárias, já em imagens em tons de cinza, ele mede a média de intensidade dos pixels através da diferença entre os valores de intensidade máxima e mínima em cada caixa de tamanho  $r$ .

O algoritmo *Differential Box-Counting (DBC)* é baseado no *Gliding-Box* e segundo Myint *et al* [77], é como se um cubo  $r \times r \times r$  fosse colocado no canto superior esquerdo de uma imagem de tamanho  $W \times W$ . Para cada *GB* de dimensões  $r \times r$ , os valores dos maiores e menores pixels são capturados e colocados em  $v$  e  $u$ , respectivamente. Com isso é calculada a altura relativa da coluna  $n_r(i, j) = v - u + 1$ , sendo que  $i$  e  $j$  são as coordenadas da imagem. Passando-se por toda a imagem é possível obter  $M_r$  dado pela equação 2.32 e este é substituído por  $M$  na equação 2.31.

$$M_r = \sum_{i,j} n_r(i, j) \quad (2.32)$$

Myint *et al* [77] descrevem duas formas de fazer a passagem do GB pela imagem; uma através da sobreposição das caixas, pelo qual o GB move-se de um pixel até a posição seguinte (Figura 2.19a), e a segunda, percorre a imagem pulando até a próxima caixa (Figura 2.19b).

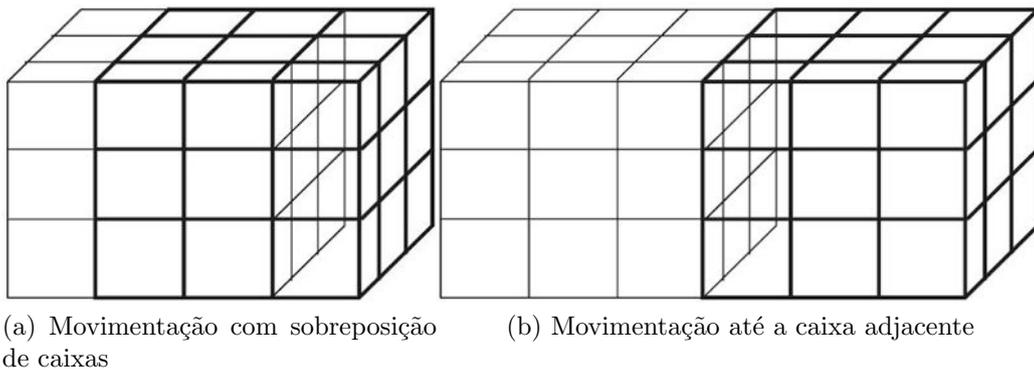


Figura 2.19: Representação das formas de movimentação do *Gliding-box* (GB) [77]

Dada uma imagem  $4 \times 4$  (Figura 2.20a) e um GB  $3 \times 3$  que passa por toda a imagem (Figura 2.20b a 2.20e), para cada posição busca-se o maior e menor valor de intensidade, por exemplo na Figura 2.20b tem-se 18 e 7. Dado um cubo  $3 \times 3 \times 3$ , a quantidade de cubos empilhados necessários para representá-los (Figura 2.21) será dado pela relação, arredondada para cima, valor de intensidade/dimensão, ou seja, a quantidade de caixas para  $u$  será  $3 \left(\frac{7}{3}\right)$  e para  $v$  será  $6 \left(\frac{18}{3}\right)$ . Logo, a altura relativa da primeira posição do GB

será  $6 - 3 + 1 = 4$  ( $v - u + 1$ ), no segundo será 7, o terceiro 4 e o último 8.

O passo seguinte é o cálculo da  $L(r)$ , que será:

$$L(r) = \frac{4 \times 4\left(\frac{1}{4}\right) + 7 \times 7\left(\frac{1}{4}\right) + 4 \times 4\left(\frac{1}{4}\right) + 8 \times 8\left(\frac{1}{4}\right)}{\left[\left(\frac{4}{4}\right) + \left(\frac{7}{4}\right) + \left(\frac{4}{4}\right) + \left(\frac{8}{4}\right)\right]^2} = \frac{36.25}{33.0625} = 1.09408$$

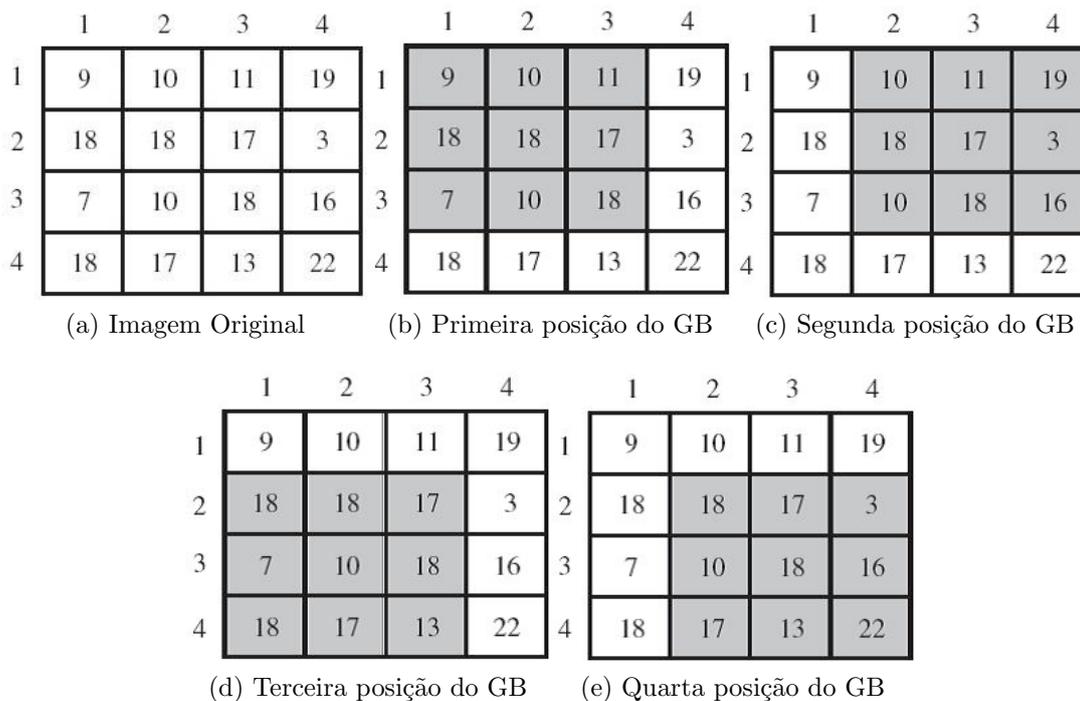


Figura 2.20: Exemplo do cálculo da lacunaridade usando o método *Gliding-box* (GB) [77]

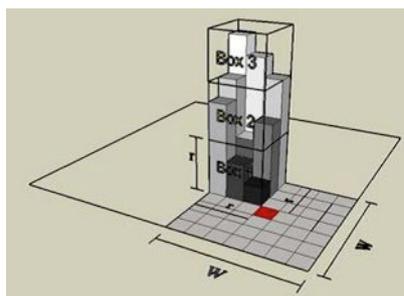


Figura 2.21: Representação dos cubos empilhados do método *Gliding-box* (GB) [77]

Ivanovici & Richard [48] propõem uma abordagem para calcular a lacunaridade através de imagens coloridas, sendo que ela caracteriza a propagação de um vetor no canal RGB e representa a medida de correlação entre as cores deste modelo. Os autores citam que enquanto em imagens em tons de cinza uma superfície discreta  $z = f(x, y)$ , sendo  $z$  a luminância em cada ponto  $(x, y)$ , em uma imagem colorida tem-se uma hipersuperfície por cada instância de  $f(x, y) = (r, g, b)$ . Portanto, na forma clássica, contava-se o número de pixels contidos em um cubo de tamanho  $d$ , nessa abordagem conta-se os pixels que estejam

a uma distância Euclidiana  $d$ , baseado no centro hipercubo  $Fc = f(xc, yc, rc, gc, bc)$ .

## Sucolaridade

Segundo Mandelbrot *et al* [71], a sucularidade é a facilidade de infiltração que um determinado líquido teria para atravessar uma imagem, ou ainda, o poder de infiltração deste líquido. Sua extração, normalmente é dada ao submeter um líquido de cima para baixo, da esquerda para a direita, da direita para a esquerda e de baixo para cima na imagem, medindo o grau de percolação deste entre os filamentos da imagem. Já a percolação, matematicamente, descreve o comportamento de agrupamentos conectados dentro de um gráfico [74].

Computacionalmente, a forma mais simples de se conseguir calculá-la é através de uma imagem binária. Para medir a sucularidade, simula-se a capacidade de percolação de um fluido na imagem, obtendo-se, dependendo das direções a serem consideradas, duas ou mais imagens. Melo [74] apresenta por meio da Figura 2.22a as possibilidades de direções como um líquido pode fluir sobre uma imagem nas quatro posições possíveis (Figura 2.22b).

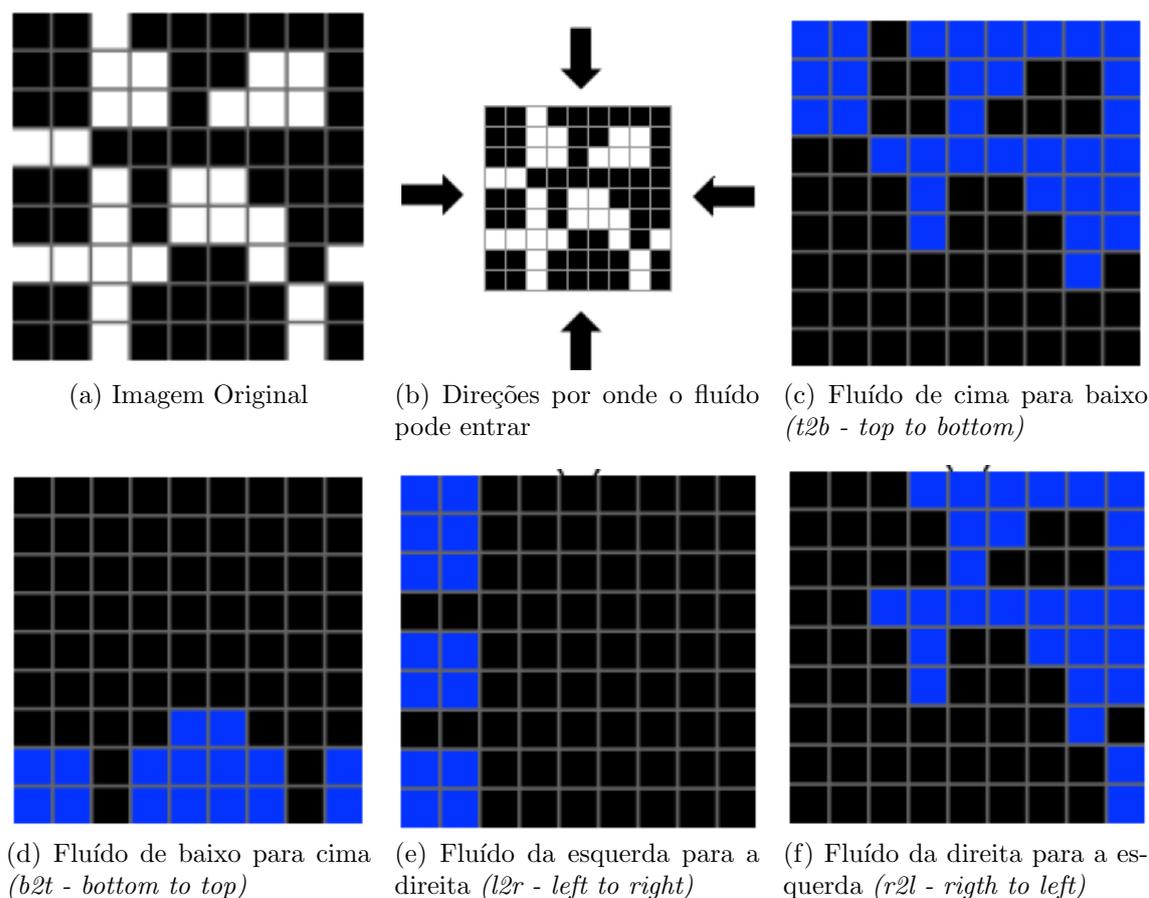
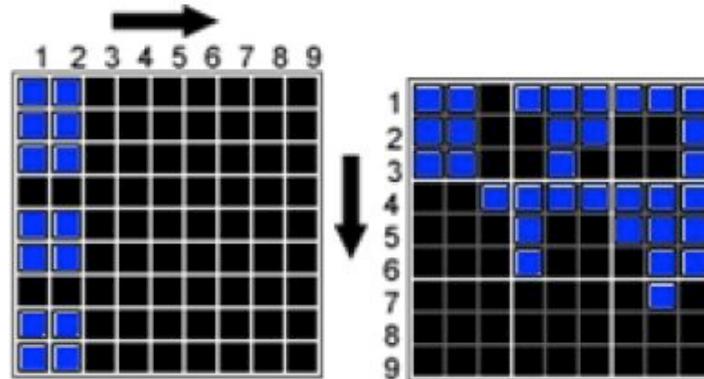


Figura 2.22: Demonstração da Sucularidade [74]

A partir das imagens conseguidas após o líquido fluir (Figuras 2.22a a 2.22f), busca-se a pressão aplicada na caixa, demonstrado nas Figuras 2.23a e 2.23b. A pressão cresce da esquerda para a direita (nos casos horizontais) e de cima para baixo (nos casos verticais).



(a) Pressão horizontal (Figura 2.22c) (b) Pressão vertical (Figura 2.22e)

Figura 2.23: Demonstração da pressão na sucolaridade [74]

Segundo Melo [74], para se calcular a sucolaridade, quatro passos devem ser seguidos:

1. A partir do topo da imagem binária, toda borda superior é considerada, se o pixel estiver vazio, significa que o fluido pode passar e inundar esta área, já se o pixel estiver ocupado, o caminho é considerado um obstáculo para o fluido. Toda área inundada, recursivamente, a partir de sua vizinhança.
2. O passo seguinte é o de dividir as áreas de enchente em caixas de mesmo tamanho ( $BS(n)$ , sendo que  $n$  é a quantidade de possíveis divisões de uma imagem em caixas), similar ao método de *Box-Counting*. Na sequência, o percentual de ocupação ( $OP$ ) é calculado para cada caixa.
3. Para cada caixa de tamanho  $k$ , soma-se a multiplicação de  $OP(BS(k))$ , e  $k$  varia de 1 a  $n$ , pela pressão  $PR(BS(k), pc)$ , e  $pc$  é a posição  $(x, y)$  do centróide da caixa na escala de pressão aplicada na caixa calculada. A pressão varia com o tamanho da caixa, pois ele é aplicado ao centróide da caixa. O centróide da caixa é dado por  $x$  (horizontalmente) e por  $y$  (verticalmente).
4. Para o cálculo da sucolaridade tem-se a equação 2.33. Segundo Melo [74], existem duas maneiras para se dividir as figuras, originadas pela pressão horizontal e vertical, em caixas de mesmo tamanho, dividindo-a por um fator  $d = 9$  (Figura 2.23a), obtendo caixas de  $1 \times 1$ , ou ainda, por um fator  $d = 3$ , obtendo-se caixas de tamanho  $3 \times 3$  (Figura 2.23b).

$$\delta(BS(k), \text{direção}) = \frac{\sum_{k=1}^n OP(BS(k))PR(BS(k), pc)}{\sum_{k=1}^n PR(BS(k), pc)} \quad (2.33)$$

Tabela 2.2: Resultados da Sucolaridade da Figuras 2.23a e 2.23b [74]

		Sucolaridade ( $\delta$ )			
$d$	$BS$	$b2t$	$t2b$	$l2r$	$r2l$
9	$1 \times 1$	0.3429	0.2387	0.0384	0.4829
3	$3 \times 3$	0.3292	0.2634	0.0576	0.4691

Através das Figuras 2.23a e 2.23b é demonstrado como se deve calcular a sucolaridade. Baseando-se que se tem caixas de  $1 \times 1$ , e dada a Figura 2.23a, nota-se que 14 caixas têm 100% de ocupação e 67 caixas tem 0%. A posição  $x$  do centróide será igual em todas as caixas da mesma coluna (percolação horizontal). O valor de  $x$  será 0.5 para as caixas na 1ª coluna e 1.5 na 2ª, nessa figura tem-se 7 caixas na primeira coluna e mais 7 na segunda. Usando-se isso no denominador da equação 2.33, tem-se  $7 \times 0.5 + 7 \times 1.5 = 14$ . O denominador será 364.5 ( $= 9 \times (0.5 + 1.5 + 2.5 + 3.5 + 4.5 + 5.5 + 6.5 + 7.5 + 8.5)$ ). Logo, a sucolaridade para caixas de  $1 \times 1$  da Figura 2.23a será dado por [74]:

$$\delta(1x1, l2r) = \frac{14}{364.5} \approx 0.0384$$

Visto que se têm caixas de  $3 \times 3$ , e dada a Figura 2.23b, tem-se sete caixas parcialmente ocupadas e duas desocupadas. Inicialmente, deve-se calcular o percentual de ocupação de cada caixa, dividindo-se a área ocupada pela área total (no caso 9 pixels). O percentual de ocupação das caixas da primeira linha de caixas será 0.67, 0.67 e 0.56 totalizando 1.9; na linha do meio, tem-se 0.11, 0.56 e 0.89, totalizando 1.56 e, na última linha, tem-se 0, 0 e 0.11, totalizando 0.11. Considerando a pressão exercida de cima para baixo, a posição do centróide  $y$  será 1.5 nas três caixas do topo, 4.5 nas caixas do meio e 7.5 nas caixas de baixo. O valor máximo de pressão possível nessa imagem será  $(1.5+1.5+1.5+4.5+4.5+4.5+7.5+7.5+7.5)=40.5$ . Por fim, aplicando-se a equação 2.33 tem-se:

$$\delta(3 \times 3, t2b) = \frac{((1.5 \times 1.90) + (4.5 \times 1.56) + (7.5 \times 0.11))}{40.5} \approx 0.2634$$

Melo [74] demonstra, através da Tabela 2.2, todos os resultados de sucolaridade da Figuras 2.23a e 2.23b.

Para uma boa classificação através de fractais, existe a necessidade da combinação das três características fractais (dimensão fractal, sucolaridade e lacunaridade). A dimensão fractal é a medida que caracteriza quanto espaço de um objeto é ocupado, esta medida não muda com escala, nem com translação ou rotação. Já a lacunaridade mede o tamanho e a frequência dos espaços vazios de uma imagem e a sucolaridade mede o grau de percolação da imagem. Algumas imagens diferentes podem ter o mesmo valor de dimensão fractal, mesmo valor de lacunaridade ou até um mesmo valor de sucolaridade, porém, nunca os

três parâmetros serão iguais em imagens diferentes [74].

### 2.4.2.2 LBP - *Local Binary Pattern*

O LBP foi inspirado em um modelo proposto em Wang & He [117], e nele uma imagem pode ser caracterizada pela sua unidade de textura, representada por oito elementos, sendo que cada um pode ter três valores possíveis (0, 1 e 2) em uma vizinhança de  $3 \times 3$ , totalizando  $3^8$  ou 6561 possibilidades de textura. A partir dessa ideia, foi proposta uma versão com apenas duas possibilidades de valores (0 e 1) na mesma vizinhança, garantindo assim  $2^8$  ou 256 possibilidades de textura [85].

Como o LBP não aborda o contraste de texturas, que é importante na discriminação de algumas texturas, ele era combinado com uma medida simples de contraste. Este método, inicialmente, trabalhava como uma matriz de convolução de tamanho fixo  $3 \times 3$  e usando o pixel central como um limiar da vizinhança de oito elementos e o código LBP era conseguido multiplicando-se os valores binarizados com os pesos do pixel correspondente, gerando o resultado final. Tal técnica pode ser observada através da Figura 2.24 [66].

pixels	Exemplo	binarizado	pesos																																				
<table style="border-collapse: collapse; width: 100%; text-align: center;"> <tr><td>P<sub>1</sub></td><td>P<sub>2</sub></td><td>P<sub>3</sub></td></tr> <tr><td>P<sub>4</sub></td><td>P<sub>0</sub></td><td>P<sub>5</sub></td></tr> <tr><td>P<sub>6</sub></td><td>P<sub>7</sub></td><td>P<sub>8</sub></td></tr> </table>	P <sub>1</sub>	P <sub>2</sub>	P <sub>3</sub>	P <sub>4</sub>	P <sub>0</sub>	P <sub>5</sub>	P <sub>6</sub>	P <sub>7</sub>	P <sub>8</sub>	<table style="border-collapse: collapse; width: 100%; text-align: center;"> <tr><td>6</td><td>5</td><td>2</td></tr> <tr><td>7</td><td>6</td><td>1</td></tr> <tr><td>9</td><td>3</td><td>7</td></tr> </table>	6	5	2	7	6	1	9	3	7	<table style="border-collapse: collapse; width: 100%; text-align: center;"> <tr><td>1</td><td>0</td><td>0</td></tr> <tr><td>1</td><td style="background-color: #cccccc;"> </td><td>0</td></tr> <tr><td>1</td><td>0</td><td>1</td></tr> </table>	1	0	0	1		0	1	0	1	<table style="border-collapse: collapse; width: 100%; text-align: center;"> <tr><td>1</td><td>0</td><td>0</td></tr> <tr><td>8</td><td style="background-color: #cccccc;"> </td><td>0</td></tr> <tr><td>32</td><td>0</td><td>128</td></tr> </table>	1	0	0	8		0	32	0	128
P <sub>1</sub>	P <sub>2</sub>	P <sub>3</sub>																																					
P <sub>4</sub>	P <sub>0</sub>	P <sub>5</sub>																																					
P <sub>6</sub>	P <sub>7</sub>	P <sub>8</sub>																																					
6	5	2																																					
7	6	1																																					
9	3	7																																					
1	0	0																																					
1		0																																					
1	0	1																																					
1	0	0																																					
8		0																																					
32	0	128																																					
<b>LBP = 1+8+32+128 = 169</b>																																							
<b>C = (6+7+9+7)/4 - (5+2+1+3)/4 = 4.5</b>																																							

Figura 2.24: Cálculo do LBP original para medição de contraste [97]

Dada uma textura  $T$  em uma vizinhança local de uma imagem em tons de cinza, composta por  $P + 1$  pixels,  $g_c$  corresponde ao valor de nível de cinza do pixel central,  $g_p$  os valores de cinza dos pixels espaçados igualmente por um círculo de raio  $R$  que compõem um conjunto circularmente simétrico dos vizinhos. As coordenadas de  $g_p$  são dadas por  $(x_c + R \cos(\frac{2\pi p}{P}), y_c - R \sin(\frac{2\pi p}{P}))$ , sendo que  $x_c$  e  $y_c$  são as coordenadas do pixel central e  $p$  a sequência dos vizinhos variando de 0 a  $P - 1$ . A Figura 2.25 demonstra três exemplos dessa vizinhança, alternando-se os valores de  $P$  e  $R$ . Os valores dos vizinhos que não atingirem perfeitamente nos pixels são estimados por interpolação bilinear [84].

Para se conseguir a invariância da escala de cinza, alguns passos devem ser seguidos; inicialmente, deve-se subtrair de cada elemento  $g_p$  o valor do pixel central  $g_c$ , sendo que é possível representar  $T$  de acordo com a Equação 2.34. A diferença de distribuição  $P$ -dimensional registra a ocorrência de diferentes padrões de textura na vizinhança de cada pixel. Segundo Ojala *et al* [84], este é um operador de textura altamente discriminante,

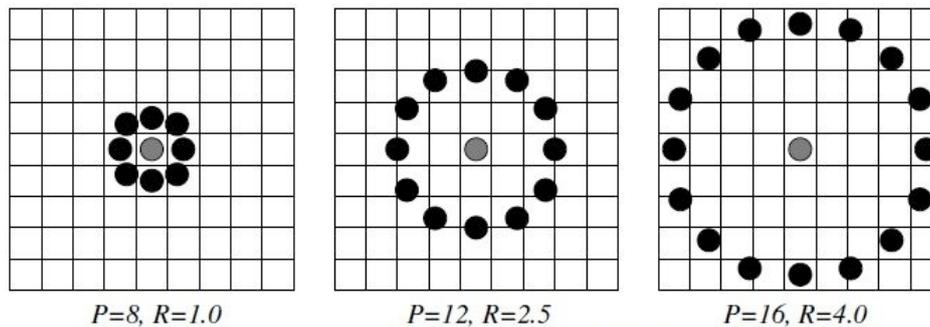


Figura 2.25: Exemplo do conjunto circularmente simétrico dos vizinhos do LBP [66]

registrando a ocorrência de vários padrões de vizinhança de cada pixel em um histograma  $P$ -dimensional. Para regiões com pouca variação ou constantes, as diferenças tendem a zero, já em bordas, o operador registra altos valores na direção do gradiente e zeros ao longo da borda e, sobre pontos, a diferença será alta em todas as direções.

No passo seguinte, para garantir a invariância da escala, somente os sinais da diferença são considerados, e cada elemento da Equação 2.34 é submetido a uma equação  $s$  (Equação 2.35) que os torna 1 se positivos e, 0 se negativos, binarizando assim, o resultado (Equação 2.36) [66].

$$T \approx t(g_0 - g_c, \dots, g_{P-1} - g_c) \quad (2.34)$$

$$s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (2.35)$$

$$T \approx t(s(g_0 - g_c), \dots, s(g_{P-1} - g_c)) \quad (2.36)$$

Na sequência é dado um peso binomial  $2^p$  a cada elemento binário conseguido por  $s$ , transformando a diferença de vizinhança em um código LBP, que representa a textura local da imagem ao redor de  $(x_c, y_c)$ , dado pela Equação 2.37.

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (2.37)$$

O nome LBP (*Local Binary Pattern*) reflete a funcionalidade do operador, pois a vizinhança local é limiarizada pelo valor do tom de cinza do pixel central em um padrão binário [84].

O LBP combina as abordagens estrutural e estatística e pode ser considerado uma abordagem unificadora, pois ao mesmo tempo explica a textura através da formação do pixel, como através de sua vizinhança local. Cada pixel é referenciado com um código de primitiva de textura que melhor se adapta com a vizinhança, permitindo detectar

primitivas como pontos, áreas planas, bordas, fins de bordas, cantos, entre outras, alguns exemplos são apresentados na Figura 2.26 [66].

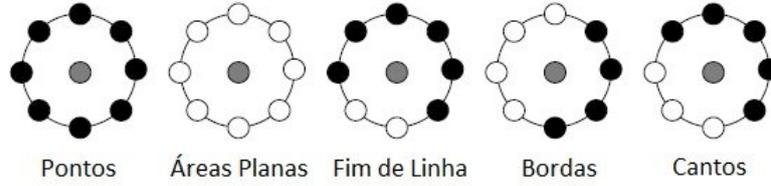


Figura 2.26: Diferentes primitivas de textura detectáveis pelo LBP [66]

Para se conseguir a invariância de rotação, por definição, alguns princípios da técnica a facilitam, como a forma circular de vizinhança do LBP, e cada pixel é considerado o centro de rotação, o que parece ser a convenção em que decorrem os operadores de rotação invariável. Porém, quando uma imagem é rotacionada, os valores de cinza de  $g_p$  estão distribuídos ao longo do perímetro centralizado em  $g_c$ , mas como a vizinhança é indexada de forma anti-horária e multiplicada pelo  $2^p$ , a rotação da imagem gera uma imagem diferente. Mas isso não se aplica quando os elementos estão representados em zeros e uns, que os mantêm constantes a todos os ângulos de rotação [84].

Para eliminar o efeito de rotação, cada código LBP deve ser rotacionado a uma posição de referência, tornando efetivamente todas as versões de rotação idênticas, e esta transformação pode ser feita usando-se a Equação 2.38. Sendo que o  $ri$  representa a “invariância de rotação” e a função  $ROR(x, i)$  (representada pela Equação 2.40) representa a mudança circular do número binário  $x$  (Equação 2.39)  $i$  vezes para direita ( $|i| < P$ ). Ou seja, o código de invariância de rotação é conseguido através da rotação circular do código original até atingir o valor mínimo [66].

$$LBP_{P,R}^{ri} = \min\{ROR(LBP_{P,R}, i) | i = 0, 1, \dots, P - 1\} \quad (2.38)$$

$$x = \sum_{k=0}^{P-1} 2^k a_k, a_k \in \{0, 1\} \quad (2.39)$$

$$ROR(x, i) = \begin{cases} \sum_{k=1}^{P-1} 2^{k-i} a_k & i > 0 \\ x & i = 0 \\ ROR(x, P + 1) & i < 0 \end{cases} \quad (2.40)$$

Em Pietikainen *et al* [96] os autores avaliaram que esta técnica nem sempre apresentava bons resultados. Em Ojala *et al* [84] foi observado que certos padrões binários locais são propriedades fundamentais de textura, sendo responsáveis por 90% dos padrões  $3 \times 3$  presentes em imagens de textura e a esses padrões chamaram “uniformes”, pois todos tem em sua estrutura circular uniforme poucas transições. Estas estruturas estão representadas

na primeira coluna da Figura 2.27, as quais funcionam como modelos de microestruturas como pontos (0), áreas planas (8) e bordas (1-7).

Para formalizar essa definição em Ojala *et al* [84] é apresentado uma forma de medir essa uniformidade ( $U(\text{padrão})$ ), que corresponde ao número de transições espaciais que ocorrem na máscara atual até se chegar ao *padrão*. Por exemplo, os padrões 00000000 e 11111111 terão  $U = 0$ , por não apresentarem transições entre seus elementos, já os outros elementos da primeira coluna da Figura 2.27 apresentam duas transições, sendo uma quando saem de 0 para 1 e outra quando saem do 1 para o 0. Todos os outros modelos apresentam,  $U \geq 4$ . Para tanto, a Equação 2.42 é aplicada na Equação 2.41 para substituir a Equação 2.38. Sendo que a referência *riu2* reflete o uso da rotação invariante uniforme com  $U$  valendo, no máximo, 2. Logo, elementos não uniformes serão agrupados com o valor de  $P + 1$  [84].

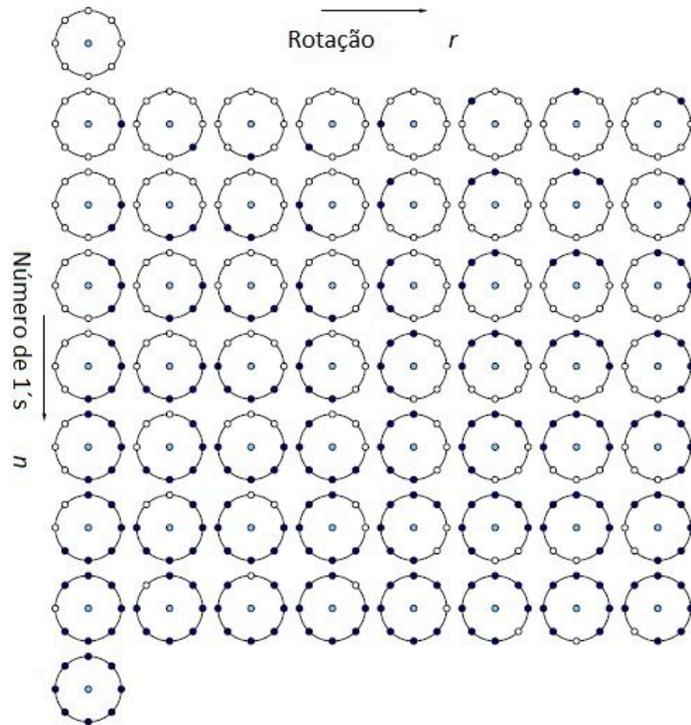


Figura 2.27: Os 58 padrões invariantes de rotação que podem ocorrer em uma vizinhança circular  $(8, R)$  [2]

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} s(g_p - g_c) & \text{Se } U(LBP_{P,R}) \leq 2 \\ P + 1 & \text{caso contrário} \end{cases} \quad (2.41)$$

$$U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (2.42)$$

O operador  $LBP_{P,R}^{riu2}$ , apesar de ser bom para medir padrões espaciais, não avalia

contraste, e para medir o contraste de uma textura local, usa-se a variância local (Equação 2.43). Sendo que  $VAR_{P,R}$  é invariante contra mudanças de tons de cinza, sendo  $LBP_{P,R}^{riu2}$  e  $VAR_{P,R}$  complementares e de sua distribuição conjunta  $\frac{LBP_{P,R}^{riu2}}{VAR_{P,R}}$  espera-se um medidor importante de invariância à rotação para textura local.

$$VAR_{P,R} = \frac{1}{P} \sum_{p=0}^{P-1} (g_p - \mu)^2, \text{ onde } \mu = \frac{1}{P} \sum_{p=0}^{P-1} g_p \quad (2.43)$$

Para a análise de textura usa-se o histograma do operador de saída do LBP e tem-se, para cada elemento do histograma, uma referência para um dos padrões uniformes, demonstrados na Figura 2.27 e mais um elemento para todos os elementos não uniformes. Para denotar um padrão LBP específico ( $U_P(n, r)$ ), em que o  $n$  corresponde ao número de bits 1 no padrão (linhas da Figura) e o  $r$  representa a rotação (colunas da Figura). Logo, caso tenham-se  $P$  vizinhos, o  $n$  terá valores de 0 a  $P + 1$ , sendo que o  $n = P + 1$ , acumulará todos os padrões não uniformes, sendo este denominado histograma *59 - bin* [2, 67]. Variações foram produzidas separando a imagem original em subimagens e para cada uma é calculado o histograma e estes são concatenados para gerar um único vetor com características locais (subimagens) e globais (imagem toda). Estas características se mostraram eficazes e rápidas em vários trabalhos [67, 105, 1].

Ainda em Ahonen *et al* [2] é proposto o uso da transformada discreta de Fourier no histograma de LBP, ao qual o autor denominou de LBP-HF, tendo esta uma natureza mais discriminante que o histograma LBP normal.

### 2.4.2.3 Local Phase Quantization - LPQ

Degradações de imagens podem limitar a análise da informação de textura, e uma classe de degradação é a desfocagem, que pode ocorrer por uma série de problemas na aquisição, e como os algoritmos que permitem retirar o borrão da imagem são computacionalmente pesados e podem introduzir novos artefatos, é desejável um algoritmo capaz de analisar a textura de forma insensível ao borramento [86].

Ojansivu & Heikkilä [86] propuseram um descritor de textura insensível ao borramento, baseado na fase quantizada da transformada discreta de Fourier, denominada LPQ (*Local Phase Quantization*). A informação da fase local de uma imagem de tamanho  $N \times N$  é dada pela STFT (*Short-Term Fourier Transform* - Equação 2.44). Sendo o filtro  $\Phi_{u_i}$  definido pela Equação 2.45, onde  $r = (m - 1)/2$  e  $u_i$  é um vetor de frequência 2D.

$$\hat{f}_{u_i}(x) = (f \times \Phi_{u_i})x \quad (2.44)$$

$$\Phi_{u_i} = e^{-j2\pi u_i^T y} | y \in \mathbb{Z}^2 | \|y\|_\infty \leq r \quad (2.45)$$

No LPQ somente quatro coeficientes complexos são considerados, que correspondem à frequência 2D  $u_1 = [a, 0]^T$ ,  $u_2 = [0, a]^T$ ,  $u_3 = [a, a]^T$  e  $u_4 = [a, -a]^T$ , em que  $a = 1/m$ . Por conveniência, o STFT (Equação 2.44) é expresso através do vetor de notação na Equação 2.46. Sendo  $w_u$  o vetor base do STFT em uma frequência  $u$  e  $f(x)$ , um vetor de tamanho  $m^2$  contendo os valores dos pixels da imagem na vizinhança ( $m \times m$ ) de  $x$ .

$$\hat{f}_{u_i}(x) = w_{u_i}^T f(x) \quad (2.46)$$

Sendo  $F = [f(x_1), f(x_2), \dots, f(x_{n^2})]$  denotado como uma matriz  $m^2 \times N^2$  que compreende a vizinhança de todos os pixels na imagem e  $w = [w_R, w_I]^T$ , em que  $w_R = Re[w_{u_1}, w_{u_2}, w_{u_3}, w_{u_4}]$  e  $w_I = Im[w_{u_1}, w_{u_2}, w_{u_3}, w_{u_4}]$ . O  $Re[\ ]$  e  $Im[\ ]$ , representam respectivamente, as partes reais e imaginárias de um número complexo e a matriz de transformação ( $8 \times N^2$ ) é dada por  $\hat{F} = wF$ .

Ojansivu & Heikkilä [86] assumem que a função  $f(x)$  de uma imagem é resultado de um processo de 1ª ordem de Markov, onde o coeficiente de correlação entre dois pixels  $x_i$  e  $x_j$  é relacionado exponencialmente com sua distância  $L^2$ . Para o vetor  $f$  é definida uma matriz de covariância  $C$  de tamanho  $m^2 \times m^2$  dada pela Equação 2.47 e a matriz de covariância dos coeficientes de Fourier podem ser obtidos por  $D = wCw^T$ . Desde que  $D$  não seja uma matriz diagonal, os coeficientes são correlatos e podem deixar de ser correlatos através de  $E = V^T \hat{F}$ , na qual  $V$  é uma matriz ortogonal derivada do valor de decomposição singular (SVD - *singular value decomposition*) de uma matriz  $D$ , que é  $D' = V^T D V$ .

$$C_{i,j} = \sigma^{\|x_i - x_j\|} \quad (2.47)$$

Os coeficientes são quantizados usando-se a Equação 2.48, em que  $e_{i,j}$  são os componentes de  $E$ ; estes elementos são transformados de binário para decimal através da Equação 2.49 e passam a representar valores inteiros de 0 a 255 e, então, através de todas as posições da imagem, é composto o vetor de 256 posições que representa o histograma LPQ.

$$q_{i,j} = \begin{cases} 1 & \text{se } e_{i,j} \geq 0, \\ 0 & \text{caso contrário} \end{cases} \quad (2.48)$$

$$b_j = \sum_{i=0}^7 q_{i,j} 2^i \quad (2.49)$$

Ainda que o foco da abordagem seja para imagens borradas, Ojansivu & Heikkilä obtiveram ótimos resultados para imagens não borradas [86].

### 2.4.2.4 Histograma da orientação da borda - *Edge Orientation Histogram - EOH*

Na busca de um algoritmo simples e rápido que funcionasse de forma robusta com mudanças de luz, Freeman & Roth [35] perceberam que a medida de orientação era pouco sensível à variação de iluminação e à translação, já que o objeto de estudo eram gestos da língua de sinais, propondo, então, o histograma de orientação.

Jain & Vailaya [49] comentam que histogramas de cor são invariantes à translação e rotação e normalizando-os, também são invariantes à escala, entretanto, eles não incorporam adjacência espacial dos pixels. Além disso, a informação de cor nem sempre está presente, sendo necessário usar forma na recuperação de imagens. Os autores descrevem que o histograma de direção de bordas não é necessariamente invariante à rotação e escala, mas, normalizando-o, resolve-se a invariância de escala. A rotação de uma imagem apenas muda as faixas do histograma e alterando sua ordem é possível resolver a orientação também.

Segundo Yang *et al* [118], para detectar as bordas, inicialmente a imagem colorida deve ser convertida para tons de cinza e, na sequência, deve-se usar o operador Sobel, tanto verticalmente como horizontalmente ( $K_x$  e  $K_y$ ), dada pela Equação 2.50. Já a força e a orientação das bordas são dadas pelas Equações 2.51 e 2.52, respectivamente. As bordas são contadas em  $K$  faixas com sua força  $S(x, y)$ .

$$G_x(x, y) = K_x * I(x, y) \quad , \quad G_y(x, y) = K_y * I(x, y) \quad (2.50)$$

$$S(x, y) = \sqrt{G_x(x, y)^2 + G_y(x, y)^2} \quad (2.51)$$

$$\theta = \arctan\left(\frac{G_y(x, y)}{G_x(x, y)}\right) \quad (2.52)$$

Levi & Weiss [61] comentam que para eliminar o ruído aplica-se um *threshold* ( $T$ ) em  $G(x, y)$ , como na Equação 2.53. Os autores dividem as bordas em  $K$  faixas e definem o valor da  $k_{esima}$  faixa como apresentado na Equação 2.54.

$$G'(x, y) = \begin{cases} G(x, y) & \text{se } G(x, y) \geq T \\ 0 & \text{outro caso} \end{cases} \quad (2.53)$$

$$\Psi_k(x, y) = \begin{cases} G'(x, y) & \text{se } \theta(x, y) \in \text{faixa}_k \\ 0 & \text{outro caso} \end{cases} \quad (2.54)$$

Na Figura 2.28 é apresentado um exemplo de um histograma da orientação de borda gerado, a partir da imagem capturada (esquerda), foram aplicados os operadores Sobel e calculada a imagem da força da borda (centro) e por fim é apresentada uma representação

polar do histograma.

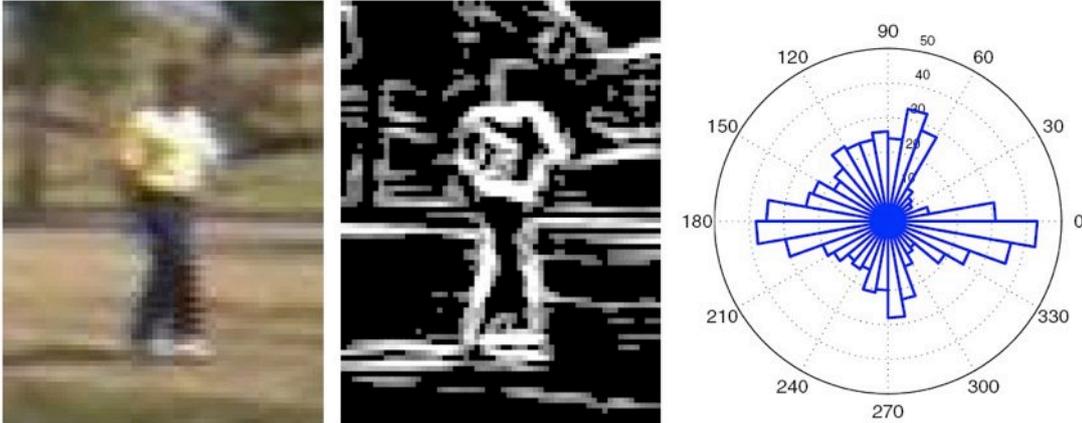


Figura 2.28: Exemplo de um histograma da orientação da borda[118]

Yang *et al* [118] comentam que o histograma pode ser construído sem calcular os ângulos da borda, substituindo-o pelas forças normalizadas horizontal ( $g_x = \frac{G_x}{S}$ ) e vertical ( $g_y = \frac{G_y}{S}$ ) como índice do histograma.

Em Vailaya *et al* [116] foi usado um detector de borda Canny e, a partir dessa imagem, foi calculado o histograma com 73 faixas, sendo 72 definidas para cada ângulo (variando-se de cinco em cinco graus) e a 73<sup>a</sup> faixa medindo a frequência dos pixels sem borda.

### 2.4.3 Abordagem Espectral

Uma fraqueza compartilhada pela maioria dos métodos de análise de textura, segundo Wouwer *et al* [26], é que a imagem é analisada em uma única escala, uma limitação que pode ser transplantada empregando-se representações multiescala. Estudos no sistema visual humano corroboram com esta abordagem, visto que o córtex visual apresenta uma grande quantidade de neurônios, alguns agrupados linearmente e outros de forma não linear, permitindo, então, que a análise da imagem seja semelhante à feita por um tipo de analisador de Fourier no domínio espacial [6, 26].

Segundo Mallat [70], a abordagem espectral permite uma invariância de escala na interpretação de uma imagem, sendo que em diferentes resoluções, os detalhes da imagem podem caracterizar diferentes estruturas físicas.

A abordagem mais básica, segundo Nixon & Aguado [83], é gerar a transformada de Fourier e agrupar os dados da transformada, de certo modo, para obter um conjunto de medidas. Depois de calculados os dados da transformada, estes devem ser normalizados pela soma dos valores quadráticos de cada componente de magnitude através da equação 2.55, garantindo invariância aos deslocamentos lineares de iluminação.

$$NFP_{u,v} = \frac{|FP_{u,v}|}{\sqrt{\sum_{(u \neq 0) \wedge (v \neq 0)} |FP_{u,v}|^2}} \quad (2.55)$$

A partir dessa normalização podem-se extrair valores espectrais, através da entropia, energia e inércia, dados pelas equações 2.56, 2.57 e 2.58, respectivamente.

$$h = \sum_{u=1}^N \sum_{v=1}^N NFP_{u,v} \log(NFP_{u,v}) \quad (2.56)$$

$$e = \sum_{u=1}^N \sum_{v=1}^N (NFP_{u,v})^2 \quad (2.57)$$

$$i = \sum_{u=1}^N \sum_{v=1}^N (u - v)^2 NFP_{u,v} \quad (2.58)$$

Pela análise de Fourier, as medidas de posição são inerentemente invariáveis, e a energia, entropia e inércia são relativamente imunes à rotação, escala e à iluminação [83].

Porém, Angelo [6] comenta que a transformada de Fourier não deixa explícitas as informações necessárias para caracterização de diferentes regiões de textura, pois traz somente frequências espaciais da imagem original sem identificar sua posição, ou seja, não diferenciando a variação na distribuição do brilho, ao longo de uma região na imagem. Logo, para se resolver o problema é necessário o uso de filtros que permitam obter um bom desempenho, tanto no domínio espacial como no de frequência, o que pode ser conseguido através de filtros como Gabor e Wavelets.

Como demonstrado por Nixon & Aguado [83], o filtro Gabor apresenta melhores resultados, em geral, por um custo computacional mais elevado do que o filtro Wavelets.

### 2.4.3.1 Filtro de Gabor

Por décadas, havia apenas duas alternativas para descrever um sinal unidimensional, um que representava o sinal em função do tempo e outro em função da frequência, através das transformadas de Fourier ou pela inversa de Fourier, dessa forma, era possível saber se uma determinada frequência acontecia, porém, não em que momento, motivando assim a ideia do filtro de Gabor, desenvolvido por Dennis Gabor, em 1946, que representa tanto o tempo quanto a frequência de um sinal. Em seu trabalho original, Gabor buscava a síntese do sinal, em como um sinal poderia ser construído através da combinação de funções elementares. Na análise do sinal, o objetivo é saber “o que está aonde”, sendo que a frequência informa o “o quê” e o tempo informa o “aonde” [52].

O filtro Gabor vem sendo utilizado com sucesso, para uso geral, em visão computacional em tarefas, tais como segmentação de imagens, reconhecimento de assinaturas, reconhecimento de faces, melhoria e identificação de impressões digitais. Isso ocorre por ter propriedades de localização espacial, seletividade de orientação e frequência espacial, que são similares aos do sistema visual humano, e a maior vantagem de se usar esse filtro é o fato dele permitir uma análise de multirresolução [6, 44, 59, 87, 83].

Várias formas de se calcular *kernels* Gabor são encontrados na literatura, sendo algumas delas descritas a seguir

Segundo Angelo [6], o trabalho desenvolvido por Gabor foi ampliado por Daugman [20] para trabalhar com duas dimensões, sendo este filtro demonstrado através da equação 2.59

$$g(x, y, \sigma_x, \sigma_y, k_x, k_y) = \exp\left\{-\frac{1}{2}\left[\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right] + (2\pi i(k_x x + k_y y))\right\} \quad (2.59)$$

Os *kernels* Gabor são seletivos à orientação e frequência, e uma família destes *kernels* é produzida através de um envelope gaussiano por meio da equação 2.60, sendo  $z = (x, y)$  uma variável no domínio espacial e  $\kappa_{\mu, \nu}$  é o vetor de frequência, que determinam a escala e orientação dos *kernels* Gabor.

Em Liu & Wan [62],  $\kappa_{\mu, \nu}$  é dado por  $\frac{\kappa_{max}}{f\nu} e^{i\phi_\mu}$  e  $\kappa_{max} = \frac{\pi}{2}$ ,  $f = \sqrt{2}$  e  $\phi_\mu = \frac{\mu\pi}{8}$ , enquanto  $\mu$  e  $\nu$  são o fator de orientação e escala respectivamente e sua variação gera diferentes retornos. Para exemplificar isso, são apresentadas através da Figura 2.29, 40 imagens com variação de  $\mu = 0, 1, \dots, 7$  e de  $\nu = 0, 1, \dots, 4$ .

$$\psi_{\mu, \nu}(z) = \frac{\|\kappa_{\mu, \nu}\|^2}{\sigma^2} e^{-\frac{\|\kappa_{\mu, \nu}\|^2}{\sigma^2}} [e^{i\kappa_{\mu, \nu} z} - e^{-\frac{\sigma^2}{2}}] \quad (2.60)$$

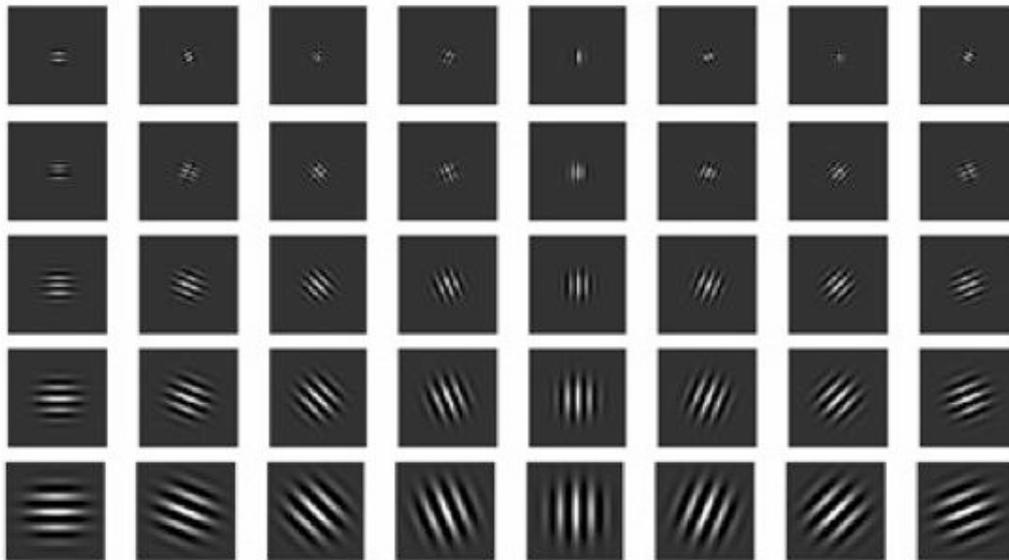


Figura 2.29: Variação dos parâmetros  $\mu = 0, 1, \dots, 7$  e  $\nu = 0, 1, \dots, 4$  [62]

Dada uma imagem  $I(z)$  a transformação Gabor de uma posição particular pode ser computada através da convolução desta com o *kernel* Gabor:

$$G_{\mu, \nu} = I(z) * \psi_{\mu, \nu}(z)$$

Já Kruizinga *et al* [56] referencia que, para trabalhar com filtros Gabor, uma imagem de entrada  $I(x, y)$  é envolta com uma função Gabor bidimensional  $g(x, y)$  (equação 2.61),

obtendo-se uma imagem  $r(x, y)$  através da equação 2.62 e para as funções de Gabor:

$$r(x, y) = \int \int I(\epsilon, \eta) g(x - \epsilon, y - \eta) d\epsilon d\eta \quad (2.61)$$

$$g_{\lambda, \theta, \varphi}(x, y) = e^{-\left(\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right)} \cos\left(2\pi \frac{x'}{\lambda} + \varphi\right)$$

sendo

$$x' = x \cos \theta + y \sin \theta, \quad y' = -x \sin \theta + y \cos \theta$$

$$\sigma = 0.56\lambda \quad e \quad \gamma = 0.5$$

O desvio padrão  $\sigma$  do fator Gaussiano determina o tamanho efetivo da vizinhança de um pixel no qual, a soma ponderada (*peso*  $\times$  *valor*) é usada; se este é muito grande, o filtro é mais robusto a ruídos, porém, perdem-se detalhes das linhas; e se for muito pequeno, não elimina ruídos, porém, é mais sensível a detalhes [21, 56]. A excentricidade Gaussiana junto com a excentricidade do *kernel* de convolução  $g$  são determinados pelo parâmetro  $\gamma$  que denota a relação de aspecto espacial. O parâmetro  $\lambda$  refere-se ao tamanho da onda e a relação  $\sigma/\lambda$  determina a largura de banda da frequência espacial dos filtros Gabor, como demonstrado na Figura 2.30. Já o ângulo  $\theta$  especifica a orientação da normal, e este terá resposta mais forte para barras, bordas e grades. O parâmetro  $\varphi$  (phi) trata da simetria da função  $g$  [56].



Figura 2.30: Exemplo da função Gabor com mesmo  $\sigma$  e diferentes tamanhos de onda [56]

Para a utilização do filtro de Gabor, é necessário o cálculo de senos e cossenos para cada elemento de uma janela espacial bidimensional, o que é computacionalmente muito caro. Para evitá-las, Oliveira [21] sugere o uso do filtro de Gabor unidimensional, dado pela equação 2.62, sendo  $x$  uma variável espacial unidimensional e decompõe esta equação em duas outras (Equações 2.63 e 2.64).

$$G(x, \sigma, f) = \frac{e^{2\pi j x f \frac{x^2}{2\sigma^2}}}{2\pi} \quad (2.62)$$

$$G_{raio}(x, \sigma) = \frac{e^{\frac{x^2}{2\sigma^2}}}{2\pi} \quad (2.63)$$

$$G_{\text{ângulo}}(x, f) = e^{2j\pi fx} \quad (2.64)$$

Segundo Oliveira [21], a partir da equação 2.63 deve-se multiplicar o vetor resultante pelo ângulo direcional para torná-la bidimensional, gerando uma matriz de dimensões  $(2n + 1) \times (2n + 1)$ . E usa-se a equação 2.64 para obter os ângulos direcionais desejados.

Já Tan [109] propõe um modelo computacional conveniente para extrair características de textura baseando-se na fisiologia e psicofísica, no qual, cada canal cortical emprega dois filtros Gabor reais para imitar um par de células corticais adjacentes simples, e o canal de saída é uma função simples e não linear das saídas dos dois filtros Gabor. Tan [109] descreve que dado um par de células adjacentes simples, um segundo par com polaridade oposta é necessário para preservar a informação.

Baseando-se em Tan [109], vários autores, como Ma & Doermann [64] e Oliveira [21], usaram o mesmo par de filtros proposto para extrair informações de textura. O modelo computacional dos filtros 2D são:

$$h_e(x, y) = g(x, y) \cdot \cos[2\pi f(x\cos\theta + y\sin\theta)] \quad (2.65)$$

$$h_o(x, y) = g(x, y) \cdot \sin[2\pi f(x\cos\theta + y\sin\theta)] \quad (2.66)$$

Em que  $h_e$  (equação 2.65) e  $h_o$  (equação 2.66) são os filtros de Gabor simétricos par e ímpar e  $g(x, y)$  é uma função gaussiana isotrópica dada pela equação 2.67.

$$g(x, y) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (2.67)$$

Para a frequência espacial das funções de Gabor, Ma & Doermann [64] adotam as equações 2.68 e 2.69. Sendo  $H_1$  dados pelas equações 2.70 e 2.71 e nelas  $f$ ,  $\theta$  e  $\sigma$  são, respectivamente, frequência espacial, orientação e constância espacial da cobertura Gabor.

$$H_e(u, v) = \frac{H_1(u, v) + H_2(u, v)}{2} \quad (2.68)$$

$$H_o(u, v) = \frac{H_1(u, v) + H_2(u, v)}{2\sqrt{-1}} \quad (2.69)$$

$$H_1(u, v) = \exp(-2\pi^2\sigma^2[(u - f\cos\theta)^2 + (v - f\sin\theta)^2]) \quad (2.70)$$

$$H_2(u, v) = \exp(-2\pi^2\sigma^2[(u + f\cos\theta)^2 + (v - f\sin\theta)^2]) \quad (2.71)$$

Devido a não ortogonalidade das ondas Gabor tem-se informações redundantes e, para que isso seja diminuído, pode-se adotar  $\sigma = \frac{1}{2\pi f}$  [64, 72].

Segundo Kruizinga *et al* [56], os resultados obtidos pelo filtro Gabor podem ser vistos diretamente como características de textura e com uma variação de três frequências espaciais e oito orientações (variação do ângulo em  $45^\circ$ ), gerando um banco de 24 filtros Gabor, pode-se ter uma cobertura da imagem; a Figura 2.31 apresenta a cobertura da imagem em ângulos de  $22,5^\circ$ . Liu & Wang [62] afirmam que os diferentes canais podem contribuir de formas diferentes para um sistema de reconhecimento, e sua combinação permite melhorias de acordo com o que se busca.

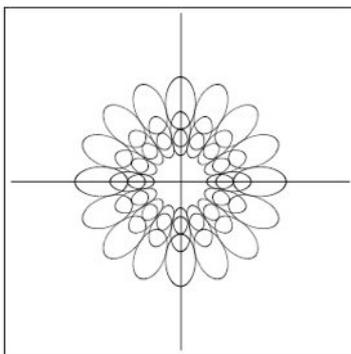


Figura 2.31: Cobertura espacial do domínio de frequência por um banco de filtros Gabor [56]

Características relacionadas ao espectro local aplicados à textura têm sido usadas tanto para classificação como para segmentação, e na maioria deles, elas são obtidas pela filtragem com um conjunto de filtros Gabor com diferentes orientações e frequências espaciais [56].

Para se ter bons resultados com Gabor é muito importante selecionar um conjunto de seus filtros e, infelizmente, para isso, gasta-se bastante tempo ajustando os parâmetros de forma empírica para aspectos globais [60].

## 2.5 Combinação de Classificadores

Um classificador tem como função mais importante atribuir um dado padrão a uma determinada classe, e cada classificador possui diferentes fronteiras de decisão, ou seja, generalizam de formas diferentes, em geral, é escolhido aquele que se apresenta de forma mais eficaz dado um conjunto de validação. Contudo, essa estratégia pode desperdiçar informações ao ignorar alguns deles, e para que isso não aconteça, a saída de cada um pode ser combinada com os restantes, permitindo uma decisão final que incorpore todas as informações, melhorando assim sua capacidade de generalização e estabilidade da classificação, já que potencializa os pontos fortes de cada um deles [51].

Para muitas aplicações, um único classificador que tenha um bom desempenho é suficiente para resolver o problema. Porém, quando se depara com problemas mais complexos, a escolha de um único classificador pode se tornar difícil, pois provavelmente limitaria

a capacidade de reconhecimento do sistema, nestes casos, a combinação é recomendada. Alguns exemplos dessa complexidade são: 1) um grande número de classes; 2) conjuntos de atributos com dimensionalidades e características diferentes; 3) dados ruidosos [51].

A combinação de classificadores tem sido usada para melhorar os resultados obtidos no reconhecimento de padrões sem que exista um aumento na complexidade, e este aumento se deve à complementariedade entre eles. Para obter essa complementariedade deve ser estabelecido um conjunto, variando-se combinadores (nível de combinação), os classificadores individuais ou especialistas (nível de classificador), os atributos (nível de características) e os subconjuntos de dados (nível de dados), como pode ser observado na Figura 2.32 [55, 103]. Vários esquemas de combinação foram propostos, como: métodos de ranking, *Borda count*, regressão logística, teoria da incerteza de *Dempster-Shafer*, *bagging*, regras fixas, entre outros [51].

Kittler *et al* [55] citam que, para aumentar a eficiência através da combinação de classificadores, pode-se adotar regras de combinação em múltiplos estágios, sendo esses sequenciais, hierárquicos, através de *clusters*, entre outros.

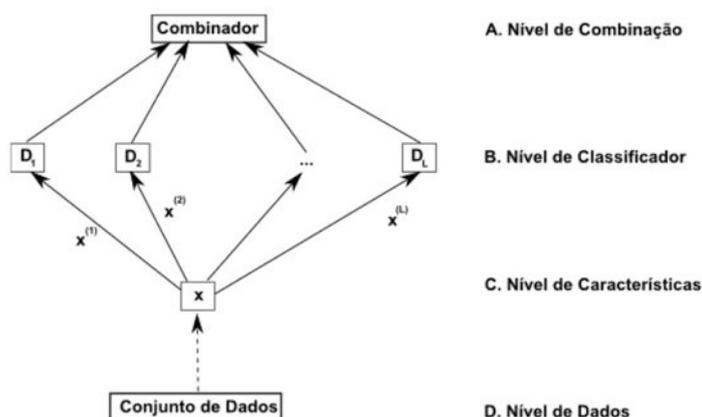


Figura 2.32: Abordagens para a construção de conjuntos em combinação de classificadores [103]

Para Salvadeo [103], um combinador de classificadores é um novo classificador que tem como entrada a resposta de  $n$  classificadores, e gera como saída, a decisão final, podendo ser de três níveis: abstração, *ranking* e medida de confiança. E os combinadores de decisão são divididos em treináveis e não treináveis (fixos). No nível de abstração, cada classificador  $D_i$  produz um rótulo de classe  $s_i \in \Omega, i = 1, \dots, L$ , sem dar informações sobre a certeza dessa predição, nem dando alternativas a essa classificação. Já no nível de *ranking*, a saída  $D_i$  é um subconjunto de  $\Omega$ , cujas alternativas são ranqueadas em ordem da plausibilidade de ser a rotulação correta, sendo bastante usado para problemas com um grande número de classes. Por fim, o nível de medida de confiança produz para cada  $D_i$  um vetor  $c$ -dimensional  $[d_{i,1}, \dots, d_{i,c}]^T$ , em que  $d_{i,j}$  representa o suporte para a hipótese de que o vetor  $x$  submetido para a classificação vem da classe  $\omega_j$  [55].

Para computar a probabilidade *a posteriori* são necessárias as medidas estatísticas, descritas em termos de funções de densidade de probabilidade conjunta  $p(x_1, \dots, x_R|\omega_k)$ , e para exprimi-la em termos de apoio à decisão dos classificadores individuais, em que cada um explora somente as informações dadas pelo seu vetor de característica  $x_i$ . Desta forma, é possível estimar a probabilidade *a posteriori*  $p(\omega_k|x_1, \dots, x_R)$ , através da Equação 2.72, no qual  $p(x_1, \dots, x_R)$  é uma medida incondicional da densidade de probabilidade conjunta. Já para conseguir a medida de distribuição condicional é apresentada a Equação 2.73 [12].

$$P(w_k|x_1, \dots, x_R) = \frac{p(x_1, \dots, x_R|w_k)P(w_k)}{p(x_1, \dots, x_R)} \quad (2.72)$$

$$P(x_1, \dots, x_R) = \sum_{j=1}^m p(x_1, \dots, x_R|w_j)P(w_j) \quad (2.73)$$

Kittler *et al* [55], após uma série de deduções, descrevem que, dado o conjunto de distribuições de probabilidade das medidas extraídas pelos classificadores tem-se uma das regras de combinação de classificadores: a Regra do Produto (Equação 2.74).

$$\begin{array}{l} \text{atribuir } Z \rightarrow w_j \text{ se} \\ p^{-(R-1)}w_j \prod_{i=1}^R P(w_j|x_i) = \max_{k=1}^m P^{-(R-1)}(w_k) \prod_{i=1}^R P(w_k|x_i) \end{array} \quad (2.74)$$

A Regra da Soma (Equação 2.75) deriva da Regra do Produto e, segundo Kittler *et al* [55], as regras de decisão mais usadas, como Máximo (Equação 2.76), Mínimo (Equação 2.77), Mediana (Equação 2.78), Voto (Equação 2.79), derivam destas duas.

$$\begin{array}{l} \text{atribuir } Z \rightarrow w_j \text{ se} \\ (1 - R)P(w_j) + \sum_{i=1}^R P(w_j|x_i) = \max_{k=1}^m \left[ (1 - R)P(w_k) + \sum_{i=1}^R P(w_k|x_i) \right] \end{array} \quad (2.75)$$

$$\begin{array}{l} \text{atribuir } Z \rightarrow w_j \text{ se} \\ (1 - R)P(w_j) + R\max_{i=1}^R P(w_j|x_i) = \max_{k=1}^m [(1 - R)P(w_k) + R\max_{i=1}^R P(w_k|x_i)] \end{array} \quad (2.76)$$

$$\begin{aligned}
 & \text{attribuir } Z \rightarrow w_j \text{ se} \\
 \min_{i=1}^R P(w_j|x_i) &= \max_{k=1}^m \min_{i=1}^R P(w_k|x_i) \tag{2.77}
 \end{aligned}$$

$$\begin{aligned}
 & \text{attribuir } Z \rightarrow w_j \text{ se} \\
 \text{med}_{i=1}^R P(w_j|x_i) &= \max_{k=1}^m \text{med}_{i=1}^R P(w_k|x_i) \tag{2.78}
 \end{aligned}$$

$$\begin{aligned}
 & \text{attribuir } Z \rightarrow w_j \text{ se} \\
 \sum_{i=1}^R \Delta_{ji} &= \max_{k=1}^m \sum_{i=1}^R \Delta_{ki} \tag{2.79}
 \end{aligned}$$

## CAPÍTULO 3

### ESTADO DA ARTE

Neste capítulo são apresentadas algumas formas computacionais de reconhecimento de espécies florestais, indo desde a análise espectral à análise de imagens. Ainda são descritos trabalhos que relatam o uso de técnicas de textura para a resolução de outros problemas. Ao final, é apresentado de forma compacta, um resumo destes trabalhos.

Além da importância científica, a identificação de espécies florestais tem uma grande importância prática, já que grandes quantidades de madeira são transportadas pelo mundo e todo vendedor/comprador de madeira bruta ou de produtos derivados está interessado em saber a qual espécie ela pertence, devido às suas propriedades específicas [46].

Alguns sistemas especialistas para reconhecimento de espécies florestais foram desenvolvidos, como em Ioannou *et al* [46], que através de chaves dicotômicas (padrão *se ... então ...*), o usuário informa algumas características ao sistema, e este informa as possibilidades de quais espécies estas características podem pertencer. Porém, nesse tipo de sistema, a interação humana é fundamental e o *software* é apenas uma ferramenta de auxílio no reconhecimento e, não necessariamente, um classificador. Para tornar o processo automático, alguns trabalhos propõem a utilização de visão computacional e textura para a solução desse tipo de problema.

A classificação de textura não é recente e tem sido empregada não só para resolver problemas de classificação ou diferenciação de texturas, mas também para reconhecer padrões como madeiras, rochas, face e texto [113]. Porém, segundo Tou *et al* [114] o reconhecimento de espécies florestais usando técnicas de visão computacional é um problema relativamente novo e mais desafiador do que simples problemas de reconhecimento de textura.

#### 3.0.1 Reconhecimento de Espécies Florestais

Yusof *et al* [122] e Tou *et al* [114] comentam que a principal dificuldade no reconhecimento de espécies florestais é que algumas espécies têm padrões muito similares entre si, e ainda, que algumas espécies têm uma variação de textura intraclasses muito grande, sendo que essa variação pode ser devido à localização, na tora, de onde foi retirada a amostra (cerne ou alburno), ou ainda, o aparecimento ou não dos anéis de crescimento.

Segundo Tarrio-Saavedra *et al* [110], o reconhecimento de espécies florestais sem interferência humana, apresentados na literatura, ocorrem de duas maneiras, ou através da análise de espectro ou de imagens.

Alguns trabalhos que descrevem análise espectral usam: espectroscopia Raman [58],

espectros de fluorescência [98], análise termogravimétrica (TG) e calorimetria diferencial exploratória (DSC) [110], infravermelho próximo (NIRS - *Near infrared spectroscopy*) [90], entre outras abordagens. E, na maioria dos casos, a identificação ocorre para diferenciar as classes gimnospermas (*softwood*) e angiospermas (*hardwood*).

Como o intuito deste trabalho é análise de imagem, os trabalhos descritos na sequência focam essa abordagem.

Em Khalid *et al* [54] os autores apresentam um sistema de reconhecimento de espécies florestais, tendo como base mais de 1.949 imagens de 20 diferentes espécies presentes na Malásia, as imagens tinham a resolução de  $768 \times 576$  pixels. As madeiras eram cortadas em cubos de  $2 \text{ cm}^2$ , fervidos para serem passados em um micrótomo, garantindo uma imagem reta o suficiente. Para a aquisição das imagens, foi utilizada uma câmera de padrão industrial e alto desempenho (JAI CV-M50), e para a iluminação, foi desenvolvida uma matriz de leds, o que possibilita uma distribuição de luz uniforme em toda a imagem.

Após a aquisição, a imagem foi submetida a um pré-processamento para realçá-la, passando por um filtro de passa alta, contraste e equalização de histograma. A esta imagem foi calculada uma matriz de coocorrência (GLCM) nas quatro direções ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ) com distância 1, retirando os atributos: segundo momento angular, contraste, correlação, entropia e momento da diferença inversa. Os 20 atributos extraídos foram aplicados na entrada de uma rede neural artificial (RNA), que gera uma camada de saída de 20 neurônios (espécies diferentes), destas, 1.753 imagens foram utilizadas para treinamento, e 196 para teste; o software pode ser ajustado para usar uma ou duas camadas ocultas, usando até um máximo de 150 neurônios em cada camada. As taxas de reconhecimento chegaram a 95% de acerto entre as 20 espécies; o autor acredita que melhores resultados podem ser conseguidos em estudos ligados a Wavelets e filtro Gabor.

Yusof *et al* [122] deram continuidade ao trabalho proposto em Khalid *et al* [54], porém, trabalhando com 30 espécies florestais e com 3.000 imagens, sendo 100 imagens de cada espécie. Destas, 300 imagens foram utilizadas para teste e 2.700 para treinamento. A partir da imagem original, foi usado um filtro homomórfico para realçar e dar uma definição mais clara das propriedades de textura. Após a imagem ser pré-processada, foi aplicado o filtro Gabor, gerando 80 imagens de saída e destas foram extraídas informações da matriz de coocorrência, gerando-se um vetor de características que, na sequência, é classificado através de uma RNA. Os dados extraídos foram média, desvio padrão, energia e entropia.

Para garantir as melhores características do filtro Gabor, foram incluídos dois módulos de decisão que têm por função selecionar o melhor filtro Gabor e o melhor tamanho de *kernel* a ser usado. Para tanto, foram feitos dois experimentos:

- O primeiro experimento buscava determinar a taxa de reconhecimento baseando-se no filtro Gabor como um multiplicador de imagens. Para cada imagem, foram geradas 80 novas imagens através do filtro de Gabor, variando-se 10 períodos de

pixel de 1 a 10 e oito valores de ângulos ( $0^\circ$ ,  $30^\circ$ ,  $45^\circ$ ,  $60^\circ$ ,  $90^\circ$ ,  $120^\circ$ ,  $135^\circ$  e  $150^\circ$ ).

- O segundo experimento buscava determinar o tamanho do *kernel* Gabor e, para tanto, foram testados os tamanhos 3, 5, 7 e 9. Pelos resultados obtidos, mostrou-se que quanto maior o *kernel* melhor são os resultados.

Segundo Yusof *et al* [122], a combinação de Gabor com GLCM gerou um reconhecimento de 95.44% na base de treinamento e 90.33% na base de testes, demonstrando a eficiência da técnica empregada.

Nasirzadeh *et al* [79] deram continuidade ao trabalho de Yusof *et al* [122], porém, usando LBP (*Local Binary Pattern*) em 3700 imagens de 37 espécies florestais. Foram comparados os métodos de  $LBP_{riu2}$  para garantir a invariância de rotação e histograma de Fourier do LBP (LBP-HF), obtendo-se como melhor resultado, 96.6% de acerto.

Em Tou *et al* [112], os autores apresentam uma série de experimentos visando extrair boas características que pudessem diferenciar as espécies florestais, através do uso de GLCM, sendo utilizada uma rede neural artificial (RNA) do tipo *Multi Layer Perceptron* (MLP) considerando-se uma camada oculta com função de ativação do tipo *softmax*. Para a realização dos experimentos foram utilizadas 360 imagens, obtidas no Centro de Inteligência Artificial e Robótica (CAIRO), e destas, foram selecionadas 50 imagens de cinco espécies diferentes.

Nos experimentos a distância usada para a GLCM, variou de 1 a 20, e para cada um dos descritores foram feitos testes nas cinco espécies, buscando características que fossem úteis na sua identificação.

Dentre as características, a energia se mostrou útil na classificação indiferente da distância, já os outros descritores tiveram valores mais próximos em pequena distância nas mesmas espécies. Os resultados mostram que a entropia com distância maior que um produz uma variação grande de valores, gerando confusão no classificador.

Foram feitos dois experimentos:

- No primeiro, a RNA usou 20 neurônios de entrada, 20 na camada oculta e saída com cinco neurônios, e como função de ativação usou tangente hiperbólica em cada camada e *softmax* na saída. Teve precisão de 72%, sendo que duas espécies obtiveram 100% de reconhecimento.
- No segundo experimento, a RNA era similar, mudando apenas o fato de ter sido retirada a energia nas quatro direções, gerando uma camada de entrada de 16 neurônios, com isso uma espécie atingiu 100%, porém, as outras decaíram, gerando uma precisão geral de 60%.

Os experimentos mostraram que, apesar da pequena base, o GLCM e MLP são técnicas eficientes para o reconhecimento de espécies florestais. Pelos dados, a orientação não

influencia os valores das imagens de mesma espécie, desde que a distância seja pequena, pois assim que aumenta a distância, as diferenças entre imagens de mesma espécie tornam-se mais óbvias. Os resultados ainda mostram que a entropia em grandes distâncias é inútil.

Dando continuidade ao trabalho proposto em Tou *et al* [112], em Tou *et al* [113] os autores tinham como objetivo reduzir o custo computacional do método da matriz de coocorrência, reduzindo sua dimensão de duas para uma. Para validar a técnica, dois experimentos foram propostos; um utilizando a base de imagens de textura Brodatz; e outro a base de espécies florestais CAIRO. No primeiro, foram extraídos 16 atributos da matriz unidimensional GLCM e da normal e foi usado o k-nn como classificador, tendo como melhor resultado 81.35% de acerto em relação a 83.01% na GLCM normal. No segundo experimento, foram utilizadas as mesmas técnicas, e como classificador foram usados o k-nn e o MLP, e cinco atributos das matrizes foram extraídos (contraste, energia, entropia, homogeneidade e correlação) da matriz normal e na unidimensional só a correlação não foi usada. Como resultado o 1D GLCM teve 72.80% de reconhecimento usando MLP e 63.60% usando k-nn, já a GLCM normal teve 56.80% para MLP e 58,40% para o k-nn.

Tou *et al* [114] propuseram um estudo comparativo de técnicas de classificação de textura para o reconhecimento de espécies florestais, dando continuidade aos trabalhos propostos em Tou *et al* [112] e Tou *et al* [113]. Os testes foram executados com imagens de seis espécies florestais da base CAIRO, tendo 100 imagens de cada espécie, destas, 90 foram utilizadas para treinamento e 10 para testes. Como classificador foi usado o k-nn. Cinco experimentos foram executados GLCM, filtros Gabor, combinação GLCM e Gabor, matriz de covariância e *verification-based recognition*. No experimento utilizando atributos GLCM e *raw GLCM*, teve-se 78.33% de acerto para *raw GLCM* e 76.67% para GLCM, para tanto foram extraídos contraste, correlação, energia, entropia e homogeneidade, nas oito direções, para garantir invariância de rotação. No experimento usando Gabor, as imagens de saída foram geradas usando três frequências diferentes e oito orientações, devido à complexidade dos atributos produzidos, o número de características foi reduzido através do SVD (*singular value decomposition*), e como taxa de acerto atingiu 73.33%. No terceiro experimento foram combinados GLCM e filtro Gabor e obteve-se 76.67% de reconhecimento. Já através dos 24 filtros de Gabor foi gerada uma matriz de covariância, obtendo 85% de acerto. No último experimento, através do uso do *verification-based recognition* usando quatro GLCM com distância 1 em oito tons de cinza, atingindo 78.33%.

Em Bremananth *et al* [13] foi desenvolvido um sistema de reconhecimento de espécies florestais que permite classificar 10 espécies da floresta indiana, nele, as imagens são redimensionadas para  $256 \times 256$  pixels, convertidas para tons de cinza, e na sequência são extraídos de uma matriz de coocorrência (energia, entropia, homogeneidade, momento de diferença inversa e segundo momento angular) nos quatro ângulos ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ). Como elemento de treinamento/classificação foi usada correlação de Pearson. Os autores relatam que obtiveram uma boa taxa de reconhecimento.

Em Yu *et al* [119] foram utilizadas 100 imagens de espécies florestais, em um sistema de recuperação de imagens, com o intuito de analisar e verificar o comportamento das espécies em relação ao canal de cores HSV e produzir uma divisão dos canais de forma não igualitária, com o intuito de descrever seus histogramas de forma mais comprimida e com uma complexidade computacional menor no casamento dos atributos. Através de observações, o canal de matriz foi dividido em seis faixas, o de saturação em três e o de valor também em três faixas.

É apresentado em Yu *et al* [120] um método integrado de recuperação de imagens de espécies florestais baseado em cor, textura e informação espacial, sendo que foram analisadas técnicas como HSV, GLCM, modelos LRE, Wavelets e algoritmos fractais. Destas, nove parâmetros são extraídos. De cor, usou-se o canal HSV, para GLCM foram extraídos contraste, segundo momento angular e a soma das variâncias. Como descritores de textura, ainda foram calculados, o LRE (*long run emphasis*) baseado em estatísticas de *run-length*, das técnicas de Wavelet foi calculada a proporção de energia da baixa frequência horizontal (EPLH - *Energy proportion of horizontal low-frequency*) e ainda foi calculada a dimensão fractal. Como base, usou-se 100 imagens de madeiras, e nestas foram feitos três experimentos. No primeiro experimento foram utilizadas somente as cores do HSV, baseados no trabalho proposto em Yu *et al* [119], e propuseram um método de divisão espacial, no qual o canal H foi dividido em nove blocos (h0 - h8), o canal S em quatro blocos (s0 - s3) e o canal V em outros quatro. Ao final, o vetor de características foi transformado em um histograma unidimensional com 164 elementos, simplificando a complexidade computacional. Em um segundo experimento foram utilizados somente os descritores de textura. Segundo os autores, o uso de descritores só de cor, ou só de textura não foram suficientes, por isso, motivou-se um terceiro experimento combinando os experimentos anteriores. Essa combinação de características tornou a recuperação de imagens mais efetiva, mais similar ao sistema visual humano.

Yu *et al* [120] citam que, para imagens naturais de madeira, a cor e a textura são as características visuais mais importantes e que apenas uma assinatura não pode construir uma ferramenta de recuperação potente, e para que seja aumentada a precisão, deve-se combinar tanto atributos de cor quanto de textura.

A quantidade de sistemas que visem efetivamente o reconhecimento de espécies florestais é pequeno, segundo Khalid *et al* [54], isso se dá devido aos seguintes fatores:

- Dificuldade na obtenção de uma base de imagens;
- Falta de técnicas comprovadas de reconhecimento de espécies florestais;
- As pesquisas atuais usam equipamentos caros;
- A falta de especialistas em classificação nos países em desenvolvimento.

No início desta proposta foram apresentados alguns trabalhos prévios, relatando os experimentos. Em De Paula *et al* [24] foi proposta a abordagem de se dividir a imagem em subimagens, para tanto, foram utilizadas 164 imagens de 14 espécies, divididas em 540 subimagens. Como descritor foram utilizados atributos de cor usando-se os canais L (Luv), S (HSV), G (RGB) e X (XYZ) em 2 faixas, calculando-se quantidade de pixels, média e mediana, totalizando um vetor com 24 atributos e, como classificador, usou-se rede neural artificial. O melhor resultado em relação às subimagens foi de 65.20% de reconhecimento.

Já em De Paula *et al* [22] uma nova base foi utilizada com 347 imagens de 11 espécies. As imagens foram divididas em 25 subimagens e delas foram extraídos atributos de cor e GLCM e os resultados individuais foram fundidos através de uma estratégia de votação para o resultado de reconhecimento final. Por meio dessa estratégia, conseguiu-se 82% de reconhecimento. Dando continuidade a este trabalho, em De Paula *et al*[23] a base de imagens foi expandida para 1270 imagens de 22 espécies, e foi avaliada a melhor forma de tratar os vetores de atributos de cor e GLCM, se deixando-os unidos (um único vetor) ou se deveriam ser tratados de forma individual, em que a melhor taxa de reconhecimento foi de 80.80% através da união dos dois vetores.

Os trabalhos sobre reconhecimento de espécies florestais podem ser sintetizados através da Tabela 3.1, na qual são apresentadas quais técnicas foram adotadas, bem como outros métodos para análise de textura.

Tabela 3.1: Síntese dos trabalhos de reconhecimento de espécies florestais apresentados

Trabalho	Ano	Método adotado	Classif.	Imag/Esp.	Melhor acerto
Tou <i>et al</i> [112]	2007	GLCM.	RNA	360/5	72,00%
Tou <i>et al</i> [113]	2008	GLCM e 1DGLCM	RNA e knn	360/5	72,80%
Tou <i>et al</i> [114]	2009	GLCM, filtros Gabor, combinação GLCM e Gabor, matriz de covariância e <i>verification-based recognition</i>	K-nn	600/6	85,00%
Khalid <i>et al</i> [54]	2008	GLCM.	RNA	1949/20	95,00%
Yusof <i>et al</i> [122]	2010	Gabor e GLCM	RNA	3000/30	90,33%
Nasirzadeh <i>et al</i> [79]	2010	LBP <sup>u2</sup> e LBP <sub>HF</sub>	RNA	3700/37	<b>96,60%</b>
Bremananth <i>et al</i> [13]	2009	GLCM	Corr.Pearson	1/10	1
De Paula <i>et al</i> [24]	2009	Cor	RNA	164/14	65,20%
De Paula <i>et al</i> [22]	2009	Cor e GLCM	RNA	347/11	82,00%
De Paula <i>et al</i> [23]	2010	Cor e GLCM	RNA	1270/22	80,80%
Yu <i>et al</i> [119]	2009	HSV	1	100/50	1
Yu <i>et al</i> [120]	2009	HSV, GLCM, modelos LRE, wavelets e algoritmos fractais.	1	100/50	1
Ioannou <i>et al</i> [46]	2009	Chave dicotômica. Processo manual	2	2	2

<sup>1</sup>Informações não disponíveis no artigo

<sup>2</sup>Não se aplica

### 3.0.2 Problemas relacionados

Alguns problemas de inspeção industrial têm algumas características parecidas com o problema do reconhecimento de espécies florestais e as técnicas utilizadas podem contribuir, pois, em geral, são de alta complexidade e necessitam de soluções em tempo real,

entre eles, pode-se citar análise de materiais como tecido, papel, madeiras, ferro, entre outros. Segundo Kumar & Pang [57] a detecção de defeitos é um dos problemas mais difíceis e intrigantes na visão computacional e que, por isso, tem recebido bastante atenção no decorrer dos anos.

Kauppinen [53] propõe um sistema para reconhecimento de defeito em tacos, e nele faz um processo em dois estágios, sendo que no primeiro busca identificar se na imagem existe algum defeito ou não, e em um segundo estágio, busca classificar qual foi o problema encontrado. Para tanto, usa como características os percentis do histograma RGB; as imagens coloridas foram adquiridas através de câmeras *line-scan*. Foram utilizadas 150 imagens para treinamento e 360 para testes e, para a detecção dos defeitos, foram obtidas 26.855 amostras retangulares de  $32 \times 32$  pixels das imagens de treinamento.

Um conjunto de 117 características de percentis foi calculado no treinamento, e um algoritmo de seleção de características foi usado para buscar o melhor conjunto para detecção de defeitos e reconhecimento. Em um primeiro momento buscou-se classificar se os tacos apresentavam algum defeito ou não, e para isso, foi conseguido 98% de acerto. As amostras que apresentavam algum defeito passavam por um novo processo que buscava reconhecer o tipo de problema, e esse processo obteve cerca de 80% de acerto.

Em Radovan *et al* [100], os autores comentam que na indústria de madeira é fundamental que se tenha uma sistema que permita perceber, reconhecer e medir tamanho e posição de defeitos. Na proposta, os autores desenvolveram um sistema de visão computacional que usa câmeras de área, inspecionando as quatro faces da madeira, detectando e classificando defeitos como nós, rachaduras, diminuição de bordas, bolsa de resina, largura, espessura, curvatura, falhas, fendas, fissuras, etc. usando imagens coloridas e monocromáticas, permitindo processamento 2D e 3D.

Nos experimentos haviam seis câmeras com lentes variando de 4-16 mm e resolução de  $768 \times 576$  pixels, capturando 50 *frames* por segundo. Para iluminação foram utilizadas duas técnicas: uma frontal, através de lâmpadas fluorescentes operando a 32 KHz para evitar cintilação, e outra através de “geração de linha de laser” (*laser-line generator*).

O método de inspeção se baseia em duas linhas de inspeção paralelas, sendo que em uma faz-se a detecção de defeitos biológicos (nós, apodrecimento e resina) e em outro, as deformações mecânicas.

Para os defeitos biológicos são adquiridas imagens em tons de cinza, e feito um *threshold* adaptativo, calculado através da análise do histograma. Para eliminar os ruídos foi usado filtro morfológico, na sequência, usou-se um algoritmo de *labeling* e, por fim, foram extraídas informações dos objetos (largura, altura, ponto central, proporção de elipse e compacidade).

Para a detecção dos defeitos mecânicos foram medidas propriedades geométricas como espessura, deformação e forma da superfície da madeira, e foram usados *range sensors* com um filtro de passa banda. A imagem é adquirida pela linha do vetor que segue o

traçado do laser e, posteriormente, tem-se um pós-processamento que gera a imagem toda, denominado de *profile extraction*. Para realçar a imagem foi feito um *threshold*.

Para a classificação em tempo real, necessita-se de velocidade e precisão e os autores escolheram uma mistura de lógica *fuzzy* e de regras de decisão. Para os experimentos foram usados dois conjuntos de dados, um com 260 exemplos, e o segundo com 160, e obteve-se acertos de 96% na detecção de rachaduras (melhor caso) e 76% nos nós vermelhos (pior caso).

Haralick [39] faz uma revisão da literatura no que se refere a formas de investigação de textura, incluindo várias abordagens estatísticas. Através de experimentos, o autor conclui que para microtexturas, as abordagens estatísticas estudadas no artigo funcionam bem, já as abordagens estruturais não são amplamente utilizadas. Já para macrotexturas, a pesquisa tem sido direcionada para o uso de primitivas de histogramas e coocorrência.

Em Alves & Araújo [5] foram aplicadas duas técnicas de análise de textura, uma utilizando histogramas de primeira ordem e outra através dos descritores baseados em matrizes de coocorrência. Para os experimentos foram utilizadas 50 imagens de tecidos biológicos para treinamento e mais 50 para testes, divididas em cinco classes. Para a classificação foi usada tanto uma rede SOM (*Self Organized Maps*) quanto uma rede MLP. Como atributos de primeira ordem foi usado um vetor de 256 elementos, representando cada um dos níveis de cinza e, como atributos de segunda ordem, foram usados oito dos descritores de Haralick (segundo momento angular, contraste, entropia, momento da diferença inversa, correlação, variância, dissimilaridade e média). Os resultados do histograma se mostraram melhores que os da matriz de coocorrência, assim como a rede SOM foi melhor que a MLP.

Tan [109] usou 14 classes de imagens de textura da base Brodatz e, a partir da imagem original, fez a equalização do histograma, e aplicou os filtros Gabor através das quatro frequências (4, 8, 16 e 32) e quatro orientações ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ), gerando como saída 16 imagens e, a partir do histograma delas, calculou média e desvio padrão, formando um vetor de atributos com 32 posições para cada imagem de entrada. Com esses atributos teve resultados próximos a 100%.

Angelo [6] trabalhou com uma imagem da base Brodatz e uma imagem real fazendo uma série de experimentos para medir a influência dos parâmetros do filtro Gabor. Dependendo do experimento, foram geradas 15, 25 e 32 imagens de saída, e destas foram calculadas a média e a matriz de covariância e, então, foi aplicado o classificador de Verossimilhança Gaussiana.

Kumar & Pang [57] usam um algoritmo baseado no filtro otimizado de Gabor, e as imagens foram divididas em quatro escalas ( $\varpi_1$ ,  $\varpi_2$ ,  $\varpi_3$  e  $\varpi_4$ ), separadas por um *octave*, e os pontos de amostra de cada uma das frequências foram rotacionados em  $45^\circ$ , ainda, foram utilizadas máscaras de convolução de pequenas dimensões ( $5 \times 5$  e  $7 \times 7$ ) e um conjunto de 16 imagens filtradas formaram o vetor de características para a detecção do

defeito. Atributos de baixa frequência da imagem adquirida foram usados para intensificar os atributos. A repetição subsequente de subamostras e a convolução com filtros passa baixa, geraram um conjunto de imagens com variação de graus de resolução (pirâmide multirresolução) e as imagens geradas por esses quatro estágios da pirâmide foram usados para normalizar as 16 imagens filtradas de Gabor, destas, foram calculados a média ( $\mu_{i,j}$ ) e desvio padrão ( $\sigma_{i,j}$ ), formando a base de localização de defeitos. Para fundir as 16 imagens em uma única imagem, usaram-se duas etapas, na primeira, quatro imagens de escala são fundidas em uma, através das regras de combinação de Bernoulli e, no segundo estágio, foi feita a média geométrica das quatro imagens de escalas adjacentes. Por fim, o *threshold* da imagem fundida produz a imagem binária dos defeitos, sendo que o valor desse limiar depende do material a ser inspecionado.

Em Backes *et al* [7] foi feita a análise de textura do parênquima paliçádico, com o objetivo de auxiliar na identificação e a delimitação de táxons. Para isso testaram técnicas tradicionais de análise de textura, como matriz de coocorrência, descritores de Fourier, de Wavelets, Gabor e a dimensão fractal de imagens histológicas foliares de espécies típicas do cerrado paulista. Dentre estes métodos, a dimensão fractal apresentou os melhores resultados, 78,44% de reconhecimento e a matriz de coocorrência obteve 77,81%, sendo que os demais descritores apresentaram resultados em torno de 63%.

Já em Deguy *et al* [27] é apresentado um novo método de análise de textura fractal usando o modelo *multi-scale fractional Brownian motion* e um novo parâmetro, denominado intermitência. Este parâmetro descreve o grau de presença de informação textural. Para validar essa abordagem, os autores trabalharam com imagens de oito tipos distintos de silagem de milho. Para cada um dos tipos, foram trabalhadas com 30 imagens e concluíram que a intermitência não só é identificável, mas também representa um parâmetro de textura significativa, dando informações diferentes a partir da dimensão fractal.

Com o intuito de identificar áreas urbanas classificando-as em pouca ou alta condição de habitabilidade, em Barros Filho & Sobreira [33], foi proposto o uso de lacunaridade. Para tanto, testou-se a técnica em imagens binarizadas e em tons de cinza, através do algoritmo *Differential Box-Counting - DBC*, e concluiu-se que o DBC aplicado em imagens em tons de cinza na discriminação de textura apresenta bons resultados.

Em Allain & Cloitre [4] os resultados mostraram que a lacunaridade é uma ferramenta para caracterizar a geometria da textura, podendo ser aplicada a qualquer escala e que o *q-ésimo* momento de escala de uma função de probabilidade permite a demonstração de autossimilaridade e uma nova forma de determinar a dimensão fractal de uma imagem.

Serafim [104] analisou o uso de assinatura fractal de texturas naturais, trabalhando com imagens em tons de cinza de papel Kraft e cortiça para verificar a ocorrência ou não de defeitos. O autor conclui que a assinatura fractal é uma característica relevante para textura, cujos modelos são de fácil implementação para resolver problemas de reconhecimento de texturas naturais. Para os experimentos com os dois tipos de textura, a

assinatura fractal demonstrou-se invariante à direção.

O objetivo do trabalho proposto por Plotze & Bruno [99] foi apresentar uma nova abordagem para análise e classificação de formas utilizando a assinatura fractal multiescala, contrapondo-se aos métodos tradicionais baseados em dimensão fractal que utilizam um único descritor para representar a complexidade de uma forma. Para tanto, uma curva da dimensão fractal multiescala foi usada como assinatura de complexidade e os descritores de Fourier são adotados como vetores de características. Para os experimentos foram utilizados órgãos foliares de espécies vegetais da Mata Atlântica e do Cerrado, com o intuito de analisar e classificar suas formas. Os resultados apresentados demonstram a eficiência dessa abordagem, no qual, através dos descritores da assinatura fractal multiescala, chegou-se a uma taxa de acerto de 96% das espécies vegetais.

Em Maenpaa *et al* [69] comenta-se que o uso de textura para a inspeção de superfície é parte importante de várias aplicações para controle de qualidade industrial, como inspeção de superfície de madeira, ferro, papel e têxtil. Na maioria, a velocidade é um aspecto crítico, logo, a extração de características e a classificação deve ser rápida. Para tanto, propõe uma abordagem através do LBP, otimização dos atributos com o algoritmo SFFS e classificação com redes SOM.

Foram feitos dois experimentos, no primeiro foram utilizadas imagens do banco Outex que contém mais de 300 texturas, e destas, foram selecionadas 24 texturas, com subimagens de  $32 \times 32$ , gerando um total de 8832 imagens com 368 exemplos por textura, que foram divididas em treinamento e teste. A classificação atingiu a média de 88,6% de acerto através do  $LBP_{8,1}$  sem interpolação e 91,1% com LBP multirresolução, com tempo de 11 ms por imagem. Já no segundo experimento foi usado, no problema de inspeção de papel, em tempo real, para verificar a performance, sendo analisados papéis em quatro classes distintas, cujas imagens são de  $756 \times 566$  em tons de cinza. Um conjunto de 1004 imagens foram divididas em treinamento e teste, atingindo-se um reconhecimento de 99,8%, usando-se um classificador 3-NN e gastando-se 11 ms por imagem, já com SOM teve-se 98,4% de acerto com 1,7 ms por imagem.

Em Niskanen *et al* [82] é feita a comparação de atributos de cor e textura na detecção de defeito em madeira serrada. Para cor, foram usados percentis e para textura LBP e como classificador foi usado SOM, através do pacote G-SOM. A inspeção da madeira foi dividida em duas partes, na primeira foram detectadas regiões com possíveis defeitos, e na segunda, foram examinados os defeitos individualmente.

Como material de teste foram utilizadas 42 tábuas e as imagens foram adquiridas com uma câmera colorida *line-scan* com resolução de 0.5 mm. As imagens foram divididas em regiões de  $40 \times 40$  pixels. Os melhores resultados foram obtidos usando percentil, somente no canal vermelho (RGB) e atributos LBP.

### 3.0.2.1 Conclusão

Neste capítulo buscou-se mostrar os trabalhos referentes ao reconhecimento de espécies florestais, bem como trabalhos que apresentavam problemas relacionados à análise textural. O esquema apresentado na Figura 3.1 busca agrupar os trabalhos apresentados em relação à técnica principal utilizada.

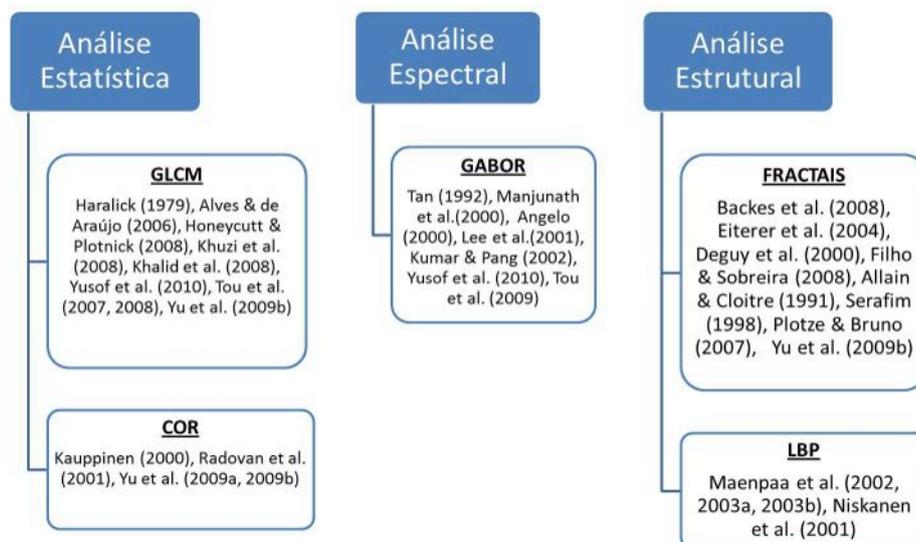


Figura 3.1: Agrupamento das técnicas utilizadas nos trabalhos descritos no estado da arte

Como o problema do reconhecimento de espécies florestais é recente, não existe um padrão para qual é a melhor forma de se tratar tal problema. Por isso estudos foram feitos, indo desde a formação de bases de imagens, definindo-se protocolos de aquisição, até como tratá-las de forma robusta em campo.

## CAPÍTULO 4

### BASES DE DADOS

Dentre os problemas de reconhecimento de espécies florestais está a falta de bases de imagens. Isto ocorre devido a fatores relacionados ao elevado custo de equipamento de aquisição, reduzido número de pesquisas na área, dificuldade na preparação de amostras, entre outros problemas [54]. Desta forma, visando viabilizar alternativas para tal, uma das contribuições desse trabalho foi a construção de duas bases de imagens macroscópicas de espécies florestais presentes no Brasil. Através delas é possível simular situações em ambiente controlado (Protocolo em Laboratório), que respaldará um segundo ambiente (Protocolo em Campo), ainda pouco explorado por trabalhos acadêmicos. 1) Protocolo em Campo - com imagens obtidas com soluções de baixo custo; 2) Protocolo em Laboratório - com imagens obtidas utilizando equipamentos de alta precisão, disponíveis em laboratório.

As imagens foram capturadas a partir de blocos de madeiras de aproximadamente  $2\text{ cm}^3$  - Figura 4.1, obtidas junto ao Laboratório de Anatomia da Madeira da UFPR (Universidade Federal do Paraná). Foram selecionadas considerando um número mínimo de 30 amostras disponíveis e o alto nível de similaridade entre espécies (selecionadas por meio da experiência de anatomistas da madeira). Para que as amostras se tornem uniformes, estas são lixadas, visando a retirada de imperfeições causadas pela serra, lascas de grande ondulações ou mesmo para melhorar o realce das estruturas anatômicas.



Figura 4.1: Exemplo de amostras de madeira

As amostras foram fotografadas no plano transversal. Devido à necessidade de identificar as amostras independentemente da orientação dos anéis de crescimento, cada amostra foi fotografada em diferentes sentidos para ambos os protocolos de coleta definidos (descritos nas seções 4.1 e 4.2).

#### 4.1 Protocolo em Campo

Tendo em vista que o reconhecimento de espécies florestais pode ser realizado em campo, com situações adversas e normalmente sem equipamentos adequados, buscou-se

desenvolver uma alternativa para este cenário, para tanto, há necessidade do uso de uma serra (para realizar o corte), lixa grossa (para eliminação de marcas de serra) e lixa fina (para realizar o realce das estruturas anatômicas).

Para a situação em campo, deve-se ainda considerar os aspectos quanto à aquisição de imagens, como a utilização de equipamentos não profissionais, ou de menor qualidade (menor custo), que os disponíveis em laboratórios. Outro ponto que pode afetar os resultados é a luminosidade inerente a ambientes não controlados. Visando mitigar esses problemas, foi proposto o protocolo para padronização da distância (entre a lente e a amostra) e iluminação. Foi construído um ambiente, como ilustrado na Figura 4.2, que proporciona a obtenção de imagens com a qualidade necessária, sendo este, um suporte equipado com duas lâmpadas halógenas para garantir a homogeneidade da luz e uma câmera fotográfica (SONY DSC T20) com o modo macro ativado. Os melhores resultados foram obtidos utilizando amostras próximas à lente ( $\approx 1$  cm) e modo autofocus, obtendo-se imagens com resolução de  $3264 \times 2448$  pixels.

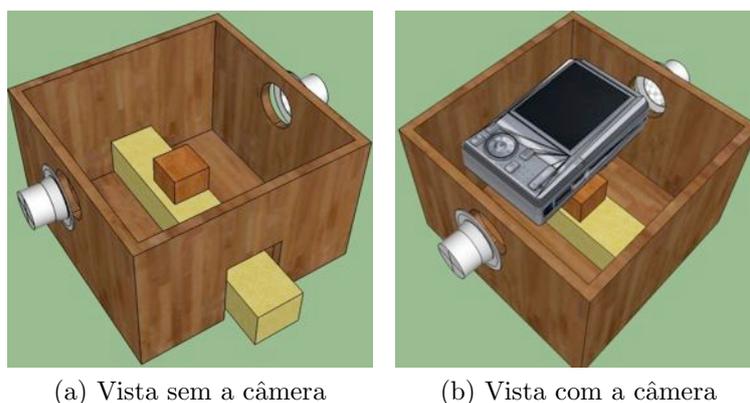


Figura 4.2: Esquema da estrutura para aquisição das imagens

Inicialmente uma base com 1270 imagens de 22 espécies florestais foi criada. Observou-se um tom amarelado nas mesmas, devido à intensidade da luminosidade gerada pelas lâmpadas halógenas [23]. Foram então testadas opções de filtros (papel de seda e papel sulfite branco com gramatura  $75 \text{ g/m}^2$ ), e lâmpadas (halógenas, led e fluorescente). Os melhores resultados, visualmente observados, foram obtidos quando utilizou-se lâmpadas halógenas com filtro de papel sulfite, que produziram uma iluminação mais homogênea com menor intensidade. Então, foi criada uma nova base, composta de 2942 imagens de 41 espécies florestais (Tabela 4.1 e Figura 4.3).

## 4.2 Protocolo em Laboratório

Seguindo um protocolo controlado para obtenção das imagens, visando a posterior comparação de resultados obtidos pelo método proposto, foi criada uma base de imagens adquiridas em laboratório (Laboratório de Anatomia da Madeira da UFPR) utilizando

Tabela 4.1: Composição da base de imagens final

Id	Nome Popular	Nome Científico	Quantidade de imagens
1	Acrocarpus	<i>Acrocarpus fraxinifolius</i>	53
2	Amapá	<i>Brosimum paraensis</i>	63
3	Andiroba	<i>Carapa guianensis</i>	43
4	Angelim Pedra	<i>Hymenolobium petraeum</i>	99
5	Araucária	<i>Araucaria angustifolia</i>	63
6	Assacu	<i>Hura crepitans</i>	41
7	Bracatinga	<i>Mimosa scabrella</i>	48
8	Cabriúva Vermelha	<i>Myroxylon balsamum</i>	75
9	Castanheira	<i>Bertolothia excelsa</i>	72
10	Cedrinho	<i>Erisma uncinatum</i>	98
11	Cedro	<i>Cedrela fissilis</i>	37
12	Cedrorana	<i>Cedrelinga catenaeformis</i>	99
13	Cinamomo	<i>Melia azedarach</i>	56
14	Cumaru	<i>Dipteryx</i> sp	67
15	Cupiuba	<i>Goupia glabra</i>	51
16	Curupixa	<i>Micropholis venulosa</i>	78
17	Eucalipto	<i>Eucalyptus</i> sp	99
18	Freijó	<i>Cordia goeldiana</i>	53
19	Goiabão	<i>Pouteria pachycarpa</i>	94
20	Grevilea	<i>Grevilea robusta</i>	86
21	Imbuia	<i>Ocotea porosa</i>	99
22	Ipê	<i>Handroanthus</i> sp	99
23	Itauba	<i>Mezilaurus itauba</i>	64
24	Jatobá	<i>Hymenaea</i> sp	82
25	Jequitibá	<i>Cariniana estrellensis</i>	55
26	Louro	<i>Laurus nobilis</i>	46
27	Machaerium	<i>Machaerium</i> sp	87
28	Massaranduba	<i>Manilkara huberi</i>	92
29	Mogno	<i>Swietenia macrophylla</i>	96
30	Louro amarelo	<i>Cordia</i> sp	51
31	Pau amarelo	<i>Euxylophora paraensis</i>	96
32	Pau marfim	<i>Balfourodendron riedelianum</i>	99
33	Peroba rosa	<i>Aspidosperma polyneuron</i>	43
34	Pinus	<i>Pinus</i> sp	79
35	Podocarpus	<i>Podocarpus lambertii</i>	62
36	Quaruba	<i>Vochysia</i> sp	59
37	Roxinho	<i>Peltogyne</i> sp	58
38	Sucupira	<i>Bowdichia</i> sp	99
39	Tatajuba	<i>Bagassa guianensis</i>	58
40	Tauari	<i>Couratari</i> sp	63
41	Virola	<i>Virola surinamensis</i>	80

um estereomicroscópio da marca Zeiss, modelo Discovery 12 (Figura 4.4). A garantia de luminosidade dá-se através de um anel iluminador de luz fria (lâmpadas halógenas



Figura 4.3: Exemplos das amostras da base de dados colhidas com o protocolo de campo

15V/150W), garantindo que estruturas extremamente finas possam ser iluminadas em suas cores naturais [45].

Em algumas situações a madeira é cortada com um micrótopo, que retira uma fatia da amostra, garantindo que esta fique plana e sem marcas de serra. Tal processo permite ter imagens com características equivalentes às usadas em outros experimentos como [54, 114, 122].

A base de imagens obtidas com o uso do estereomicroscópio (Figura 4.5) conta com 2380 imagens referentes a 40 espécies (Tabela 4.2), com resolução de  $2080 \times 1540$  pixels.

A Figura 4.6 mostra a diferença na qualidade das imagens obtidas através da abordagem de campo e a abordagem de laboratório. Na Figura 4.6a é possível observar, com qualidade, as estruturas anatômicas da madeira, já na Figura 4.6b, estas estão pouco evidenciadas, pois a amostra não está bem lixada.



Figura 4.4: Estereomicroscópio - Marca Zeiss - Modelo Discovery 12

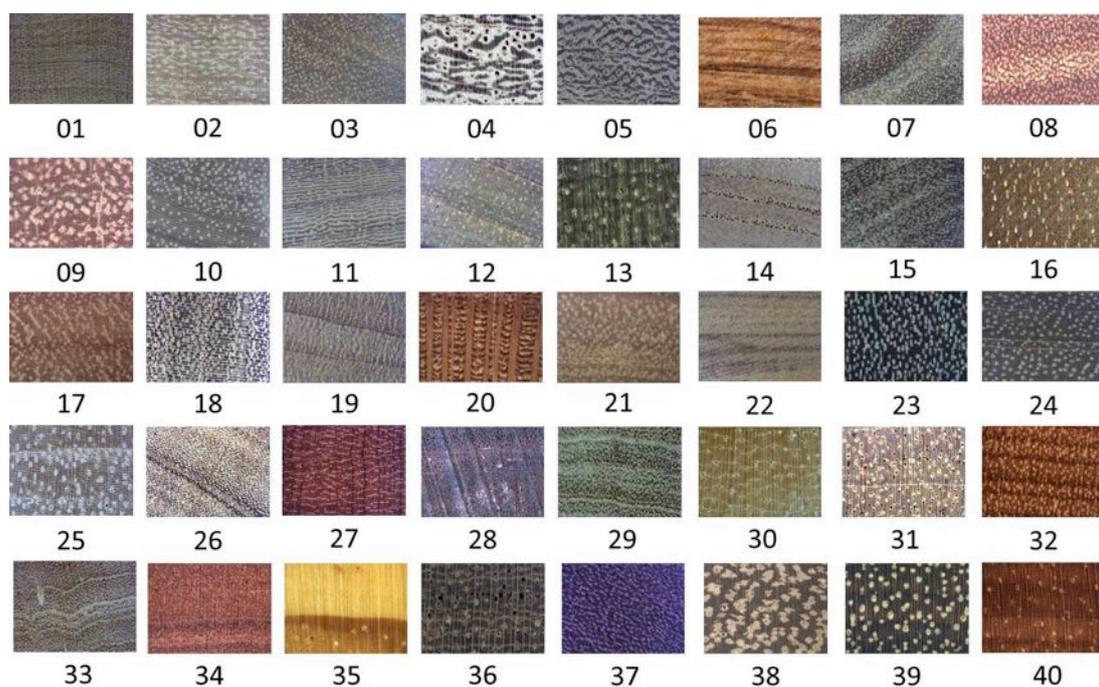


Figura 4.5: Exemplos das amostras da base de dados colhidas com o protocolo de laboratório

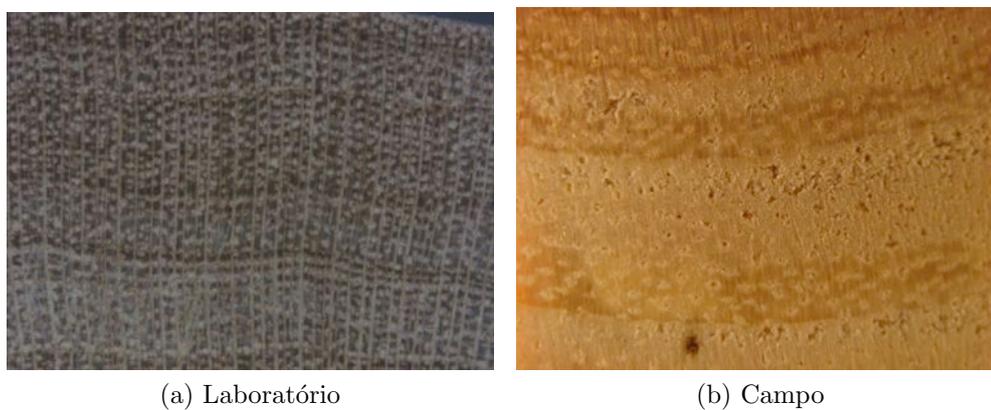


Figura 4.6: Imagens de Acrocarpus - *Acrocarpus fraxinifolius*, adquiridas através das duas abordagens

Tabela 4.2: Descrição da codificação das amostras de imagens macroscópicas do Estereomicroscópio - Marca Zeiss

Cod	Nome Popular	Nome Científico	Quantidade de imagens
01	Acrocarpus	<i>Acrocarpus fraxinifolius</i>	39
02	Amapá	<i>Brosimum paraensis</i>	45
03	Andiroba	<i>Carapa guianensis</i>	33
04	Angelin	<i>Hymenolobium</i> sp	29
05	Angelin pedra	<i>Hymenolobium petraeum</i>	52
06	Araucária	<i>Araucaria angustifolia</i>	103
07	Bracatinga	<i>Mimosa scabrella</i>	41
08	Cabreúva vermelha	<i>Myroxylon balsamum</i>	64
09	Cupiuba	<i>Goupia glabra</i>	40
10	Castanheira	<i>Bertolothia excelsa</i>	58
11	Cedrinho	<i>Erisma uncinatum</i>	83
12	Cedro	<i>Cedrela fissilis</i>	32
13	Cedrorana	<i>Cedrelinga catenaeformis</i>	171
14	Cinamomo	<i>Melia azedarach</i>	90
15	Cumaru	<i>Dipteryx</i> sp	62
16	Curupixá	<i>Micropholis venulosa</i>	82
17	Eucalipto	<i>Eucalyptus</i> sp	50
18	Freijó	<i>Cordia goeldiana</i>	56
19	Goiabão	<i>Pouteria pachycarpa</i>	52
20	Grevilea	<i>Grevilea robusta</i>	50
21	Imbuia	<i>Ocotea porosa</i>	61
22	Ipê	<i>Handroanthus</i> sp	50
23	Itauba	<i>Mezilaurus itauba</i>	87
24	Jatobá	<i>Hymenaea</i> sp	45
25	Jequitiba	<i>Cariniana estrellensis</i>	43
26	Louro	<i>Laurus nobilis</i>	40
27	Massaranduba	<i>Manilkara huberi</i>	50
28	Machaerium	<i>Machaerium</i> sp	15
29	Pau Marfim	<i>Balfourodendron riedelianum</i>	72
30	Marupá	<i>Simarouba amara</i>	33
31	Mogno	<i>Swietenia macrophylla</i>	102
32	Pau Amarelo	<i>Euxylophora paraensis</i>	86
33	Pau Cetim	<i>Aspidosperma</i> sp	68
34	Peroba rosa	<i>Aspidosperma polyneuron</i>	23
35	Pinus	<i>Pinus</i> sp	48
36	Quaruba Cedro	<i>Vochysia</i> sp	53
37	Roxinho	<i>Peltogyne</i> sp	62
38	Sucupira	<i>Bowdichia</i> sp	95
39	Tatajuba	<i>Bagassa guianensis</i>	58
40	Tauari	<i>Couratari</i> sp	57

## CAPÍTULO 5

### MÉTODO PROPOSTO

Neste estudo busca-se realizar o reconhecimento de espécies florestais usando técnicas de análise de cor e textura em imagens macroscópicas de amostras de madeira obtidas em campo, e para confrontar com as técnicas normalmente usadas, a mesma técnica será usada com amostras adquiridas pelo método tradicional (obtidas em laboratório).

Devido à similaridade entre espécies e à variedade intraespécies, este tipo de reconhecimento é mais desafiador do que a maioria dos problemas de análise de textura [114], principalmente, se as imagens a serem analisadas apresentarem problemas (naturais ou de captura). Neste sentido, nessa seção é apresentado o método proposto baseado na ideia *dividir para conquistar*.

Neste sentido, cada imagem é dividida em  $n$  subimagens de tamanho igual, com o intuito de que problemas locais não afetem o reconhecimento global da imagem. Então, inicia-se uma fase de processamento de baixo nível, no qual para cada pedaço da imagem são extraídos vetores de vários descritores texturais e de cor. Cada vetor, separadamente, é normalizado e passado a um classificador e, a partir dos vários resultados obtidos dos classificadores, é feita uma fusão para cada pedaço, tornando seu reconhecimento mais robusto, concluindo-se essa etapa de “baixo nível”. Na etapa seguinte, uma nova decisão de “alto nível” funde às avaliações individuais de cada pedaço, gerando assim, a decisão final. A Figura 5.1 ilustra esta proposta.

Esta proposta pode ser tratada de forma modular, ou seja, não necessariamente, é preciso passar por todas as etapas apresentadas. Essa modularização permite que certas etapas possam ser puladas, caso o problema a ser analisado seja menos complexo, ou ainda, permite a adição de novos descritores (camada 3), ou novas regras de fusão, tanto de baixo nível (camada 5) quanto de alto nível (camada 6).

Para avaliar os descritores, foi usado o classificador SVM que, segundo Yuan [121], é um algoritmo com alto poder de separação entre classes e tem sido usado com sucesso em vários tipos de problemas. A taxa de reconhecimento é calculada através da Equação 5.1.

$$\text{Taxa de reconhecimento} = \frac{\text{Nº de elementos reconhecidos corretamente}}{\text{Total imagens}} * 100 \quad (5.1)$$

Nas próximas seções, cada módulo do método proposto é descrito em detalhes. No capítulo 6 são apresentados experimentos em que cada módulo é testado de maneira independente, bem como experimentos com todos os módulos do sistema. O objetivo é

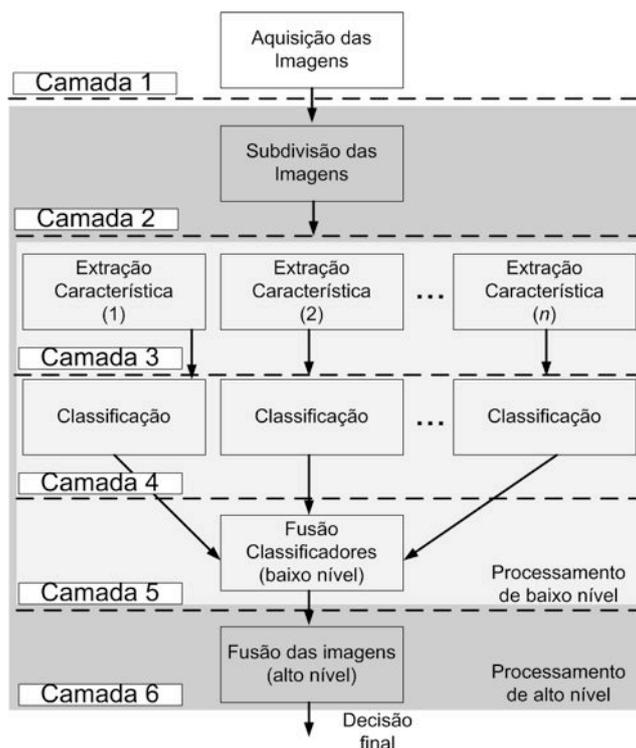
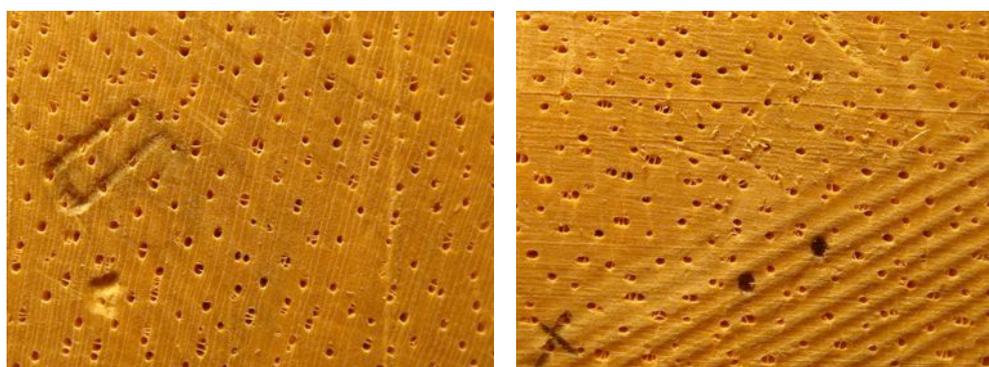


Figura 5.1: Fluxograma do Método Proposto

mostrar o impacto e a contribuição das diversas camadas do sistema proposto.

## 5.1 Subdivisão da imagem

Como as amostras adquiridas em campo não receberam um tratamento seguindo o protocolo realizado em laboratório, as imagens obtidas podem apresentar problemas relacionados ao caráter natural ou devido a problemas na preparação das amostras, tais como a diferença de cerne/alburno, transições de anéis de crescimento, marcas de serra, marcas de lixa, sinais de queimadura, imagem desfocada ou resultante de amostra mal lixada, entre outras (Figura 5.2).



(a) Marcas Externas

(b) Marcas Externas e marcas de serra

Figura 5.2: Exemplo de amostras mal preparadas (Marupá - *Simarouba amara*)

Como os problemas citados normalmente não afetam a imagem como um todo, e sim, apenas pequenas partes, visando reduzir a possível interferência no processo de classificação, propôs-se a estratégia de subdividir a imagem em  $n \times n$  partes. Para identificar qual deveria ser a melhor divisão, experimentos foram realizados variando o  $n$  em 2, 3, 5, 6, 7, 8 e 10 e estes são descritos na seção 6.3. A partir da classificação individual de cada parte da imagem, estratégias de fusão foram adotadas para definir a qual espécie corresponde uma imagem.

Na Figura 5.3, tem-se uma representação desta abordagem. No exemplo, a imagem é dividida em quatro pedaços, atributos são extraídos e seus vetores são classificados. Hipoteticamente, três pedaços indicam que a amostra pertence à espécie 1 e um pedaço à espécie 3, e através de uma fusão por votação, um classificador indica que a imagem pertence à espécie 1.

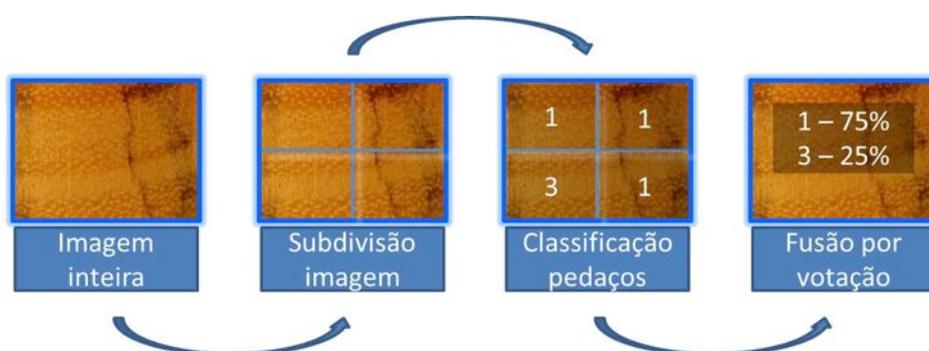


Figura 5.3: Representação da estratégia da divisão da imagem

## 5.2 Extração de características

Com o objetivo de identificar quais técnicas de análise de textura melhor se adaptam para o reconhecimento de espécies florestais, foram utilizadas as abordagens estatística, estrutural e espectral, as quais são descritas com detalhes na sequência. Na Tabela 5.1 é apresentado um resumo dos descritores, sua abordagem e o tamanho do vetor de atributos resultante.

Para a normalização dos dados destes vetores, foi usado o aplicativo *svm-scale* da biblioteca LIBSVM que transforma os dados em valores entre dois limites, máximo ( $M_i$ ) e mínimo ( $m_i$ ). Por padrão, o aplicativo assume -1 como valor mínimo e 1 para máximo. A Equação 5.2 descreve essa normalização.

$$\text{Normalização} = \frac{2(x - m_i)}{(M_i - m_i) - 1} \quad (5.2)$$

Tabela 5.1: Resumo dos descritores

Abordagem	Descritor	Tamanho
Estatística	GLCM	28
Estatística	Cor (RGB)	81
Estatística	Cor (LAB)	81
Estatística	Cor (Canais mistos)	18
Estrutural	Fractais	24
Estrutural	LBP <sub>8,1</sub>	59
Estrutural	LBP <sub>8,2</sub>	59
Estrutural	LBP <sub>16,2</sub>	243
Estrutural	LBP <sub>HF</sub>	38
Estrutural	EOH	37
Estrutural	LPQ	256
Espectral	Filtro Gabor	120

### 5.2.1 Abordagem estatística

Dos extratores estatísticos foram escolhidos a análise de cor por ser um elemento importante para diferenciar as espécies, e matriz de coocorrência por ser uma referência clássica na análise de textura.

#### 5.2.1.1 Análise de cor

Para a análise de atributos de cor, foram utilizados três vetores, sendo um obtido por meio da análise de histograma em diferentes modelos, e os demais pelo método proposto por Zhu *et al* [123], que utiliza os canais de cor RGB e Lab.

Inicialmente, buscou-se por meio da análise de frequência e distribuição dos *pixels*, identificar quais modelos de cor melhor representam uma proximidade intraclasse e uma separação extraclasse. Para isso, foram utilizadas dez amostras de cada espécie, sendo gerados seus respectivos histogramas para cada um dos canais de uma série de modelos. Após geração e avaliação dos histogramas, foram selecionados os canais L (Luv), S (HSV) e G (RGB).

Um exemplo pode ser observado na Figura 5.4, na qual através do modelo de cores RGB, foi usado o canal G para seis espécies, *Peltogyne* sp (a), *Laurus nobilis* (b), *Cedrela fissilis* (c), *Pinus* sp (d), *Manilkara huberi* (e), *Aspidosperma* sp (f), e de forma geral, os histogramas apresentam um comportamento similar intraclasse.

Para cada um dos canais escolhidos, os histogramas foram normalizados em um intervalo que vai de 0 a 255, e destes, foram definidas duas regiões de fatiamentos de cores que permitiram uma melhor representação das espécies. Dos canais L e S o fatiamento foi nas faixas de 0 a 200 e de 201 a 255, já do canal G foi de 0 a 127 e 128 a 255. Destes seis fatiamentos foram extraídas informações de média, curtose e obliquidade, gerando um vetor de 18 atributos.

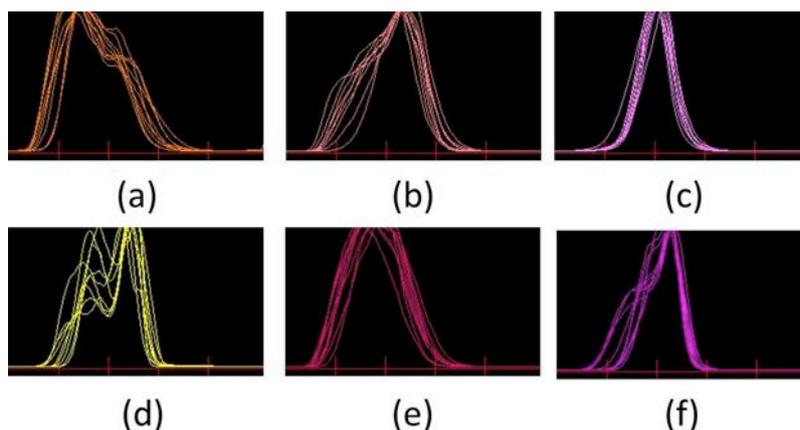


Figura 5.4: Exemplo do comportamento do histograma no modelo RGB, canal G

Outros dois vetores de cores foram usados; um, usando o modelo de cores RGB, e no outro, o Lab. Neles, cada imagem é dividida em uma grade de  $3 \times 3$  e de cada uma das nove subimagens dessa grade são extraídas média, variância e obliquidade, gerando vetores de 81 atributos, tais vetores foram propostos por Zhu *et al* [123].

### 5.2.1.2 Matriz de coocorrência - GLCM

Para a extração da GLCM, experimentos foram realizados, variando-se os canais de cor em tons de cinza, canais H e S (HSV) e canal G (RGB) e variando-se descritores, distâncias e ângulos. Os melhores resultados foram conseguidos usando-se energia, contraste, entropia, homogeneidade, probabilidade máxima, momento de 3ª ordem e correlação dos quatro ângulos ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ) e usando-se distância um, gerando um vetor de 28 atributos.

## 5.2.2 Abordagem espectral

Da abordagem espectral foi utilizado o filtro de Gabor, que tem sido utilizado com sucesso em diferentes aplicações de classificação de textura.

### 5.2.2.1 Filtros de Gabor

Para extrair os atributos de Gabor, as imagens foram transformadas para tons de cinza e experimentou-se uma série de variações dos parâmetros. Os melhores resultados foram obtidos seguindo os padrões adotados em [123], usando como padrão, um tamanho de máscara de  $64 \times 64$ , aplicando-se oito variações do fator de orientação ( $\mu = 0, 1, \dots, 7$ ) e cinco de escala ( $\nu = 0, 1, \dots, 4$ ), totalizando 40 subimagens e destas, extraiu-se média, variância e obliquidade, gerando um vetor de 120 atributos.

### 5.2.3 Abordagem estrutural

Nesta abordagem foram testados os descritores propostos pelo grupo de visão computacional da Universidade de Oulu (LPQ e LBP), que tem apresentado bons resultados em diversos trabalhos que envolvem análise de textura [2, 105, 1, 79, 76], bem como análise fractal e histograma de orientação de borda.

#### 5.2.3.1 Fractais

Para a análise fractal foi usada a dimensão fractal (*box-counting*), sucolaridade e lacunaridade (*differential box-counting*). Tais descritores foram usados nos canais L (Luv), S (HSV) e G (RGB), baseando-se na análise de histogramas descrita na seção 5.2.1.1.

Para a dimensão fractal variou-se a proporcionalidade entre 2, 3 e 5, nos três canais, gerando um vetor de nove atributos. Já a lacunaridade calculada em cada canal gerou mais três atributos. Para o cálculo da sucolaridade variou-se a percolação, como sugerido em [74], de cima para baixo, esquerda para direita, direita para esquerda e baixo para cima, por canal, totalizando mais 12 atributos. Finalmente, as três técnicas foram agrupadas gerando um único vetor de características de 24 atributos.

#### 5.2.3.2 *Local Binary Pattern - LBP*

Foram realizados testes usando-se  $LBP^{u2}$ ,  $LBP^{riu2}$  e LBP-HF, a partir das imagens em tons de cinza. Os resultados obtidos com o  $LBP^{riu2}$  não foram muito efetivos, baixa taxa de reconhecimento, e logo esta técnica foi descartada. Já a partir do histograma gerado pelo  $LBP^{u2}$  foram feitos testes variando-se a quantidade de vizinhos (8, 16 e 24) e distância (1, 2 e 3), como proposto em [68]. Devido ao alto custo computacional, dado o tamanho das imagens desta base, 24 vizinhos e distância 3 foram descartados. Seguindo-se experimento proposto em [73], foram gerados dois vetores de 59 atributos, a partir de 8 vizinhos variando-se a distância em 1 e 2. Outros dois vetores de 243 atributos foram testados, utilizando-se como parâmetros para o  $LBP^{u2}$ , 16 vizinhos e distância 2. Pelos bons resultados obtidos em [79], foram feitos testes com o LBP-HF, através do qual foi gerado um vetor de 38 atributos.

#### 5.2.3.3 *Local Phase Quantization - LPQ*

Segundo Ojansivu & Heikkilä [86] o LPQ é insensível ao borramento e, devido ao pouco tratamento nas imagens adquiridas em campo, algumas delas podem apresentar estado de borramento, neste sentido, o LPQ foi usado. Para tanto, foi utilizada a aplicação disponibilizada pelo grupo de visão computacional da Universidade de Oulu <sup>1</sup>. Como

<sup>1</sup>Disponível em: <http://www.cse.oulu.fi/CMV/Downloads/LPQMatlab>

parâmetro de entrada, foi usado o tamanho de vizinhança de  $3 \times 3$ . Como resultado, o algoritmo retorna um vetor de 256 posições, que representa o histograma gerado pelo LPQ.

### 5.2.3.4 Histograma da orientação da borda

Baseando-se em resultados obtidos em [123], buscou-se analisar este descritor. Para tanto, cada imagem foi transformada em tons de cinza e foi aplicado um detector de borda Canny. Deste resultado, foi calculado um histograma de orientação de borda usando-se 36 faixas de 10 graus cada, além de uma faixa adicional para contar os pixels sem informação de borda, gerando um vetor de 37 características.

## 5.3 Classificação

Como classificador foi usado o SVM (*Support Vector Machine*), através da biblioteca LIBSVM, desenvolvido em Chang & Lin [16]. Ele é um classificador binário por natureza, ou seja, foi projetado para discriminar padrões provenientes de duas classes. Para resolver o problema de múltiplas classes, o classificador usa uma tomada de decisão baseada em *pairwise*, ou seja, comparam-se as classes duas a duas até se chegar a uma decisão final [29]. A Figura 5.5<sup>2</sup> representa um exemplo dessa tomada de decisão, nela, a competição se dá dos níveis mais baixos até os níveis mais altos, sendo o “ganhador” aquele presente no nó da árvore.

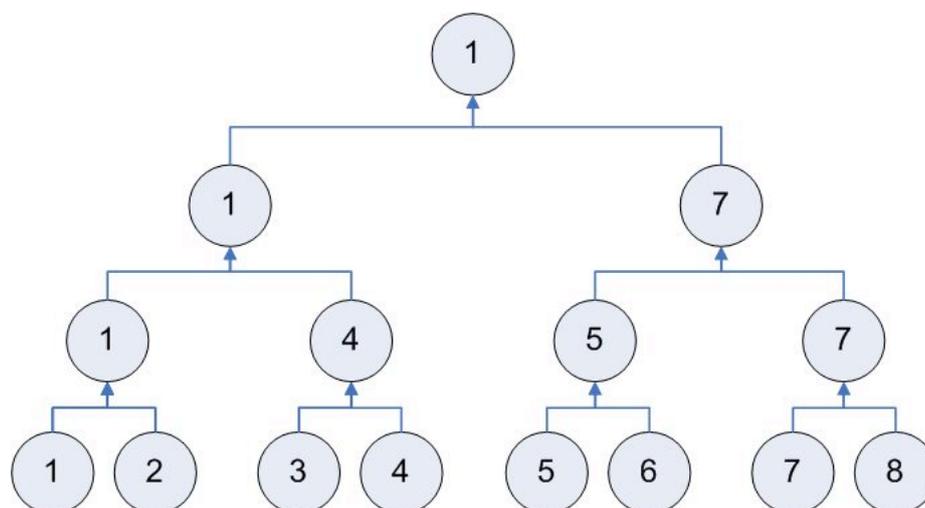


Figura 5.5: Exemplo da classificação *pairwise*

Através de uma busca gulosa, encontram-se os melhores parâmetros do classificador ( $C$  e  $\gamma$ ) que será executado para a base de testes.

<sup>2</sup>Adaptado de: <http://lesoliveira.net/wiki/tiki-index.php?page=CI851A-2012-2>

## 5.4 Fusão de classificadores - Baixo Nível (Camada 5)

Por padrão, o SVM traz os resultados de predição no nível de abstração, ou seja, produz um rótulo de classe, sem dar informações sobre a certeza dessa predição. Porém, para a estratégia proposta, o classificador foi treinado para produzir uma estimativa de probabilidade *a posteriori*, ou seja, o retorno da classificação é um vetor normalizado entre 0 e 1, que representa a hipótese de que os dados submetidos para a classificação vem da classe  $w$ .

Cada subimagem é submetida a uma série de extratores, e para cada uma se tem um resultado de classificação. Como algumas técnicas comportam-se melhor para a classificação de um tipo de espécie e pior para outra, buscou-se uma forma de complementariedade entre esses resultados. Para tanto, propõe-se a combinação destas saídas, gerando decisões mais robustas.

Os resultados de cada classificador são combinados por meio de regras de fusão sugeridos em Kittler *et al* [55].

## 5.5 Fusão das subimagens - Alto Nível (Camada 6)

Uma nova camada de fusões se faz necessária para a classificação da imagem como um todo, para se unir os seus  $n$  pedaços. Após a fusão dos classificadores de cada segmento, os resultados individuais são combinados para se ter uma decisão sobre a imagem.

A Figura 5.6 apresenta uma representação gráfica do processo de fusão (unindo a fusão de baixo nível com a de alto nível). A partir da subdivisão da imagem inteira, cada pedaço é submetido a um classificador e através da soma dos valores obtidos por cada classificador, tem-se uma nova pontuação para cada pedaço. Nessa representação hipotética de três classes e três classificadores, o primeiro quadrante teve maior pontuação para a espécie 1, fazendo-se o mesmo com todas as subimagens e, fazendo a fusão dos resultados de cada pedaço tem-se a decisão final.

Assim como na fase anterior, foram feitos testes usando como critério de fusão, a votação, soma, mediana, produto.

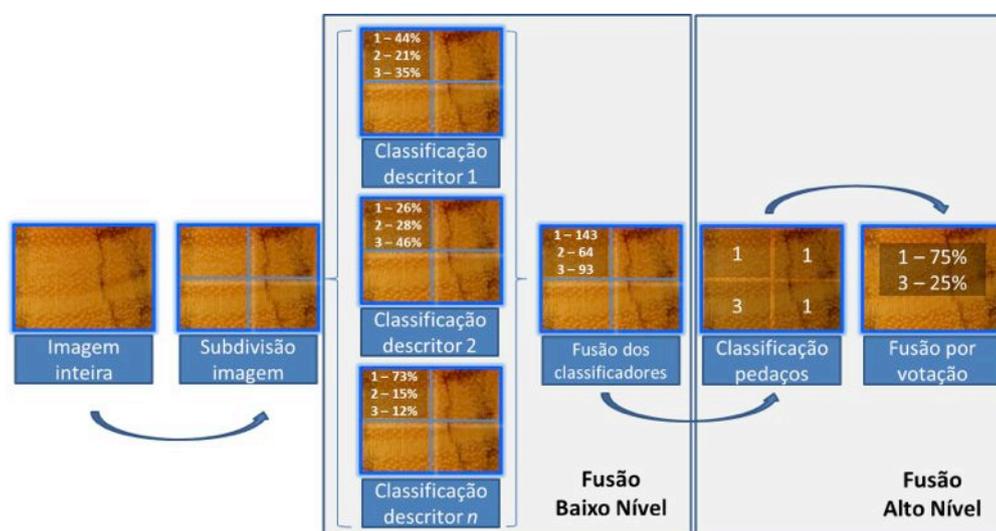


Figura 5.6: Representação da fusão por votação

## CAPÍTULO 6

### RESULTADOS EXPERIMENTAIS

Para testar o impacto da estratégia sugerida, uma série de experimentos foram realizados. Inicialmente, analisou-se a imagem como um todo, para tanto, usaram-se os descritores apresentados (Seção 5.2) e os seus resultados foram fundidos; tais experimentos estão descritos nas seções 6.1 e 6.2. Na seção 6.3 são apresentados os experimentos necessários para visualizar o impacto da variação da quantidade de pedaços usados na divisão das imagens. Já nas seções 6.4 e 6.5 são tratados os impactos da fusão dos resultados dos pedaços da imagem e da fusão dos classificadores.

Por fim, com o intuito de avaliar se a abordagem proposta atende tanto às imagens adquiridas através do protocolo de campo (seção 4.1) quanto às imagens adquiridas através do protocolo de laboratório (seção 4.2), experimentos foram realizados e estes são descritos na seção 6.6.

Como para cada espécie tem-se uma quantidade de amostras diferentes, buscou-se uma homogeneidade de amostras distribuídas em três grupos distintos (treinamento, validação e teste). Utilizou-se, para essa divisão, uma proporção de 50% para o teste, e o restante dividindo-se em 70% para o treinamento (35% do total), e 30% para a validação (15% do total).

#### 6.1 Imagem Inteira

Na primeira análise buscou-se averiguar o impacto dos descritores para as imagens inteiras. Neste experimento, a partir do fluxograma do método proposto (Figura 5.1), foram usadas as camadas 1, 3 e 4 para se chegar às decisões finais. A partir da aquisição das imagens, uma série de descritores de textura foi extraída, e individualmente, as imagens foram classificadas.

Na Tabela 6.1, são apresentadas as taxas de reconhecimento dessa análise, nela os atributos de cor LAB e RGB (79,50% e 76,40%, respectivamente) apresentam-se como os melhores descritores para imagens inteiras.

Em trabalhos prévios [22, 23], usando-se outro protocolo de captura das imagens, os melhores resultados de classificação com a matriz de co-ocorrência foram conseguidos usando-se o canal H (HSV). Como as bases foram refeitas, novos experimentos foram necessários. Para tanto, variou-se a imagem em tons de cinza, matiz e saturação (HSV) e verde (RGB). Como os melhores resultados foram obtidos usando-se tons de cinza, os demais experimentos com GLCM seguiram o mesmo padrão.

Tabela 6.1: Resultados imagens inteiras

Classificador	Taxa reconhecimento
RGB	76,40%
Lab	<b>79,50%</b>
Canais mistos	56,04%
GLCM <sub>cinza</sub>	55,97%
GLCM <sub>matiz</sub>	41,67%
GLCM <sub>saturação</sub>	39,11%
GLCM <sub>verde</sub>	51,16%
EOH	39,04%
Fractais	46,46%
LBP <sub>8,1</sub>	61,73%
LBP <sub>8,2</sub>	65,53%
LBP <sub>16,2</sub>	68,24%
LBP <sub>HF</sub>	51,31%
LPQ	61,77%
Gabor	67,97%

## 6.2 Fusão de classificadores da Imagem Inteira - Baixo Nível

Neste experimento, o objetivo foi o de usar a combinação de classificadores para escolher os descritores que melhor se comportam para o problema do reconhecimento da madeira de espécies florestais, a partir dos resultados do experimento descrito na seção 6.1, os resultados foram fundidos (camada 5 - fusão de baixo nível).

Para tanto, foram usados os doze descritores: RGB, Lab, Canais mistos, GLCM<sub>cinza</sub>, EOH, Fractais, LBP<sub>8,1</sub>, LBP<sub>8,2</sub>, LBP<sub>16,2</sub>, LBP<sub>HF</sub>, LPQ e Filtros Gabor.

A Figura 6.1, demonstra a ideia desse experimento, a partir da imagem inteira, os resultados de cada classificador são combinados através de regras de fusão gerando-se, então, uma decisão final.

Para identificar quais dos doze descritores formavam o melhor conjunto para combinação, usou-se uma estratégia de *força bruta*, gerando um total de 4096 combinações possíveis. Já para definir as regras de fusão experimentos foram realizados usando-se regras de votação, soma, mediana e produto, sendo que os dois primeiros apresentaram os melhores resultados.

A Tabela 6.2 apresenta as cinco melhores combinações ordenadas pela regra da soma (ordem decrescente), já a Tabela 6.3, pela regra de votação. A regra de soma foi, na média geral, 7,11 pp (pontos percentuais) melhor que a regra da votação.

Comparando-se as melhores taxas de reconhecimento da classificação de um único descritor (79,50% - Lab) e a combinação deles (91,57%), tem-se 12,07 pp a mais para a combinação, o que respalda Kittler *et al* [55], que citam que a combinação de classificadores melhora os resultados obtidos no reconhecimento de padrões, e este aumento se deve

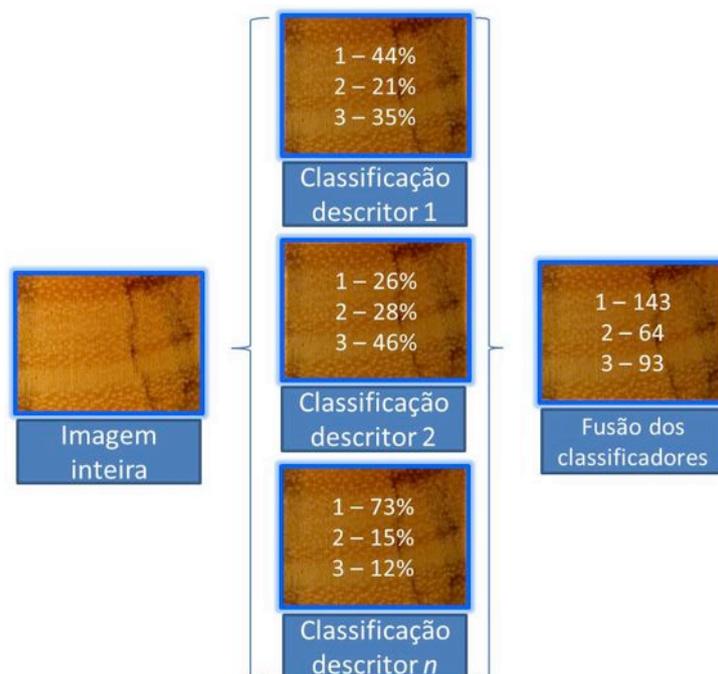


Figura 6.1: Representação da estratégia da fusão da imagem inteira

Tabela 6.2: Resultados fusão inteira, ordenado usando-se soma

Descritores	Soma	Votação
GLCM, Gabor, Fractais, Lab, RGB, LBP <sub>16,2</sub> e LBP <sub>8,2</sub>	<b>91,57%</b>	83,75%
GLCM, Gabor, Fractais, Canais Mistos, Lab, LBP <sub>16,2</sub> e LBP <sub>8,2</sub>	91,50%	82,74%
GLCM, Gabor, Fractais, Lab, LBP <sub>16,2</sub>	91,30%	83,82%
GLCM, Gabor, Fractais, Lab, LBP <sub>16,2</sub> e LBP <sub>8,2</sub>	91,30%	83,88%
Gabor, Fractais, Lab e LBP <sub>8,2</sub>	91,30%	84,02%

Tabela 6.3: Resultados fusão inteira, ordenado usando-se votação

Descritores	Soma	Votação
Gabor, Lab, LBP <sub>16,2</sub> e LBP <sub>8,2</sub>	89,68%	<b>85,43%</b>
Gabor, Lab, LBP <sub>16,2</sub> , LBP <sub>8,2</sub> e LBP <sub>8,1</sub>	88,60%	<b>85,43%</b>
Gabor, Lab e LBP <sub>16,2</sub>	90,76%	85,23%
Gabor, Lab, LBP <sub>16,2</sub> e LBP <sub>8,1</sub>	89,89%	85,23%
Gabor, Lab, RGB, LBP <sub>16,2</sub> , LBP <sub>8,2</sub> e LBP <sub>8,1</sub>	89,89%	85,17%

à complementariedade entre eles.

### 6.3 Divisão das imagens - Método *dividir para conquistar*

Após alguns experimentos, observou-se que a divisão das imagens em  $n$  pedaços melhorava as taxas de reconhecimento, pois, com isso, é possível isolar em partes da imagem problemas locais. Para definir qual deveria ser o valor de  $n$ , foi definido um protocolo de testes, variando-se a divisão da imagem em  $2 \times 2$  ( $1631 \times 1223$  pixels),  $3 \times 3$  ( $1087 \times$

815 pixels),  $5 \times 5$  ( $652 \times 489$  pixels),  $6 \times 6$  ( $543 \times 407$  pixels),  $7 \times 7$  ( $465 \times 348$  pixels),  $8 \times 8$  ( $407 \times 305$  pixels) e  $10 \times 10$  ( $325 \times 243$  pixels).

Destes segmentos de imagem, foi selecionado um descritor de cada abordagem textural (RGB - estatístico, LBP - estrutural e Filtros Gabor - espectral); cada pedaço, independente do todo, foi treinado e classificado (camadas 1, 2, 3 e 4), e os resultados são apresentados na Tabela 6.4. Para uma melhor análise destes resultados, é apresentada a Figura 6.2, nela é possível visualizar que a cor, por ser um descritor invariante à rotação, escala e deformações, é relativamente estável. Já os descritores estruturais e espectrais, perdem desempenho conforme o  $n$  aumenta.

Tabela 6.4: Avaliação da variação da quantidade de pedaços ( $n$ )

Descritor	4 ped.	9 ped.	25 ped.	36 ped.	49 ped.	64 ped.	100 ped.
<b>RGB</b>	72,98%	71,99%	70,18%	70,13%	68,70%	69,73%	69,32%
<b>Gabor</b>	<b>76,64%</b>	76,59%	69,42%	65,53%	61,60%	57,82%	53,01%
<b>LBP<sub>8,1</sub></b>	67,01%	64,33%	60,71%	56,68%	54,88%	53,54%	50,99%

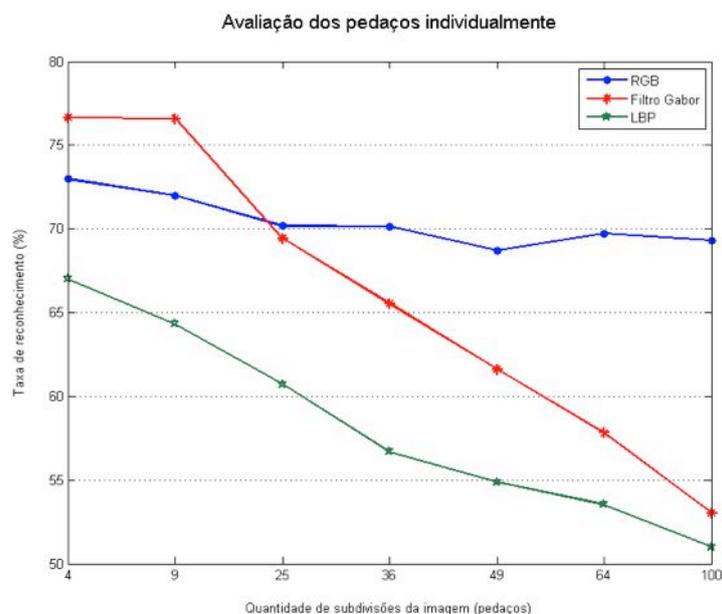


Figura 6.2: Impacto da variação da quantidade de subimagens

Obteve-se como melhor taxa de reconhecimento 76,64% (Filtro Gabor), dividindo-se a imagem em 4 pedaços, porém, essa análise leva em consideração somente o pedaço, sem analisar a imagem completa, logo, para isso, foram feitos testes fundindo-se os resultados de cada pedaço, para formar a imagem inteira (Figura 5.3), fechando assim, o ciclo do processamento de baixo nível (Camadas 1 a 5).

Na Tabela 6.5 são apresentados os resultados da fusão por votação, percebe-se que comparando a taxa de reconhecimento da imagem inteira e da fusão, em todas os casos a fusão foi melhor, variando de 2,70 pp a 21,88 pp. O melhor percentual de acerto se deu com o uso de cor (RGB), com 100 pedaços (90,69% de acerto).

Tabela 6.5: Avaliação da variação da quantidade de pedaços ( $n$ ) - Fusão por votação

Descritor	Inteira	4 ped.	9 ped.	25 ped.	36 ped.	49 ped.	64 ped.	100 ped.
<b>RGB</b>	76,40%	79,10%	84,69%	86,72%	88,60%	88,00%	89,54%	<b>90,69%</b>
<b>Gabor</b>	67,97%	82,67%	88,47%	86,92%	87,05%	85,17%	84,01%	83,48%
<b>LBP<sub>8,1</sub></b>	61,73%	74,11%	79,16%	82,81%	83,61%	82,54%	82,73%	82,67%

Avaliando-se o gráfico da Figura 6.3, percebe-se que quanto menor a imagem, a cor apresenta melhores resultados, porém, os outros descritores passam a ter uma queda de desempenho, a partir dos 9 pedaços do filtro Gabor e dos 36 pedaços do LBP. Isso ocorre pelo fato de as imagens começarem a perder as propriedades globais de textura, sendo ressaltadas somente as propriedades locais.

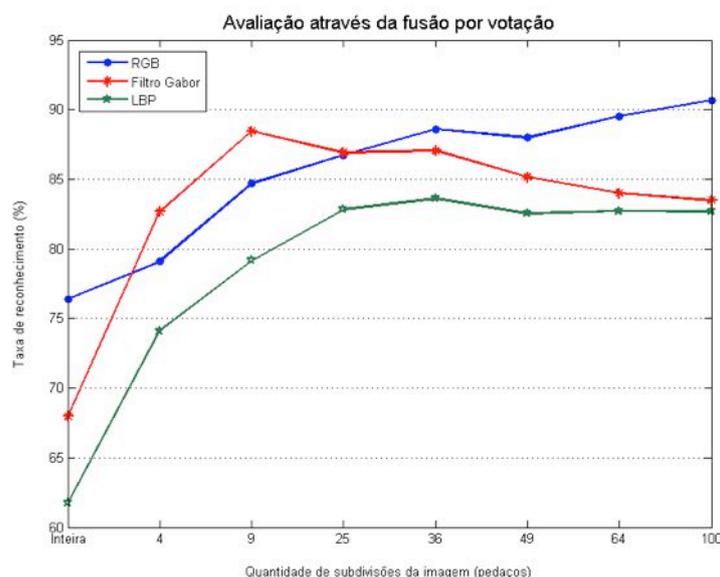


Figura 6.3: Efeito da variação da quantidade de subimagens - Fusão votação

Já na Tabela 6.6 são apresentados os resultados da fusão por soma, que foram em média 0,91 pp melhor que a fusão por votação, sendo pior somente em duas análises (36 pedaços Gabor e LBP). A melhor taxa de reconhecimento deu-se, ainda, na análise de cor com 100 pedaços (91,23 %).

Tabela 6.6: Avaliação da variação da quantidade de pedaços - Fusão por soma

Descritor	Inteira	4 ped.	9 ped.	25 ped.	36 ped.	49 ped.	64 ped.	100 ped.
<b>RGB</b>	76,40%	81,79%	86,31%	87,53%	88,74%	88,87%	90,35%	<b>91,23%</b>
<b>Gabor</b>	67,97%	85,97%	89,28%	87,66%	86,45%	85,37%	84,55%	84,69%
<b>LBP<sub>8,1</sub></b>	61,73%	76,20%	80,18%	83,68%	82,87%	83,68%	83,06%	83,48%

Para analisar o protocolo completo (Figura 5.6 - fusões de baixo e alto nível), após a classificação de cada pedaço foi feita a fusão dos classificadores (fusão de baixo nível) e a fusão dos pedaços (alto nível). Nas Tabelas 6.7 e 6.8 são apresentadas as combinações dos classificadores usando-se as regras de votação e soma, respectivamente.

Tabela 6.7: Combinação de classificadores - Regra da votação

Classificadores	4 ped.	9 ped.	25 ped.	36 ped.	49 ped.	64 ped.	100 ped.
<b>RGB e Gabor</b>	89,68%	93,53%	94,40%	94,47%	93,80%	94,06%	93,53%
<b>RGB, Gabor e LBP</b>	91,64%	93,46%	<b>94,54%</b>	94,13%	94,47%	93,45%	93,19%
<b>RGB e LBP</b>	86,45%	90,36%	92,38%	92,25%	92,85%	92,98%	93,39%
<b>Gabor e LBP</b>	87,19%	89,68%	89,62%	88,87%	87,46%	87,52%	86,78%

Tabela 6.8: Combinação de classificadores - Regra da soma

Classificadores	4 ped.	9 ped.	25 ped.	36 ped.	49 ped.	64 ped.	100 ped.
<b>RGB e Gabor</b>	92,38%	94,27%	95,01%	<b>95,41%</b>	94,47%	94,53%	93,93%
<b>RGB, Gabor e LBP</b>	93,46%	94,20%	94,81%	94,54%	94,54%	93,99%	94,00%
<b>RGB e LBP</b>	88,87%	91,30%	93,39%	92,99%	93,59%	93,52%	93,39%
<b>Gabor e LBP</b>	88,81%	90,76%	90,02%	89,08%	88,33%	88,06%	87,26%

Analisando-se as duas tabelas, observa-se que as melhores taxas foram conseguidas com a fusão de todos os classificadores (94,54% - 25 pedaços na regra da votação) e com RGB e Filtro Gabor (95,41% - 36 pedaços na regra da soma). Na média, as taxas de reconhecimento obtidas com a regra de fusão por soma foram 0,81 pp superiores ao da fusão por votação. Além disso, observa-se que, fundindo-se os classificadores, tem-se 4,18 pp a mais na taxa de classificação, comparando-se ao melhor resultado dos classificadores individuais (fusão por soma - 100 pedaços)

## 6.4 Divisão das imagens e Fusão dos pedaços

Usando como referência os resultados do experimento descrito na seção anterior, a quantidade de divisões que obtiveram as melhores taxas de reconhecimento foram as de 25 pedaços ( $5 \times 5$ ) e 36 pedaços ( $6 \times 6$ ) e, a partir delas, foram feitos novos experimentos com o intuito de testar os doze descritores desta proposta.

Para tanto, a partir das subimagens (camada 2) foram extraídos seus atributos, gerando-se os vetores de características (camada 3). Estes foram classificados (camada 4) e os resultados desta classificação são apresentados na Tabela 6.9. Os resultados da classificação individual dos 25 pedaços é em média 3,41 pp melhor que os apresentados da subdivisão com 36 pedaços, sendo a única exceção o classificador “Canais mistos”, nele, a divisão  $\frac{1}{36}$  da imagem total foi mais eficiente. Porém, esses resultados não têm uma importância tão grande, visto que tratam somente das avaliações de segmentos de imagem e não da imagem total.

Para se ter o reconhecimento da imagem como um todo, os resultados dos segmentos da imagem foram fundidos (fusão de baixo nível) por meio das regras de votação e soma (camada 5) e os resultados destas fusões são apresentados nas Tabelas 6.10 e 6.11, respectivamente.

Através destas tabelas, pode-se observar que o comportamento apresentado na Figura

Tabela 6.9: Classificação das subimagens - 25 e 36 pedaços

Descritor	25 ped.	36 ped.
<b>RGB</b>	<b>70,18%</b>	<b>70,13%</b>
<b>Lab</b>	68,69%	67,75%
<b>Canais Mistos</b>	52,74%	53,11%
<b>GLCM</b>	58,72%	57,86%
<b>EOH</b>	50,86%	33,81%
<b>Fractais</b>	34,23%	31,80%
<b>LBP<sub>8,1</sub></b>	60,71%	56,68%
<b>LBP<sub>8,2</sub></b>	64,15%	61,01%
<b>LBP<sub>16,2</sub></b>	67,79%	64,77%
<b>LBP<sub>HF</sub></b>	45,15%	42,75%
<b>LPQ</b>	60,67%	57,18%
<b>Gabor</b>	69,42%	65,53%

Tabela 6.10: Fusão por Votação dos classificadores das subimagens - 25 e 36 pedaços

Descritor	25 ped.	36 ped.
<b>RGB</b>	86,72%	<b>88,60%</b>
<b>Lab</b>	86,72%	86,85%
<b>Canais Mistos</b>	74,65%	77,01%
<b>GLCM</b>	82,60%	82,87%
<b>EOH</b>	78,29%	58,26%
<b>Fractais</b>	58,33%	58,19%
<b>LBP<sub>8,1</sub></b>	82,81%	82,87%
<b>LBP<sub>8,2</sub></b>	82,87%	83,28%
<b>LBP<sub>16,2</sub></b>	85,70%	85,03%
<b>LBP<sub>HF</sub></b>	73,84%	72,76%
<b>LPQ</b>	81,59%	79,50%
<b>Gabor</b>	<b>86,92%</b>	86,45%

Tabela 6.11: Fusão por Soma dos classificadores das subimagens - 25 e 36 pedaços

Descritor	25 ped.	36 ped.
<b>RGB</b>	87,53%	<b>88,74%</b>
<b>Lab</b>	86,78%	87,26%
<b>Canais Mistos</b>	75,93%	77,82%
<b>GLCM</b>	83,41%	83,68%
<b>EOH</b>	80,85%	61,77%
<b>Fractais</b>	62,58%	62,44%
<b>LBP<sub>8,1</sub></b>	83,68%	83,34%
<b>LBP<sub>8,2</sub></b>	83,28%	83,61%
<b>LBP<sub>16,2</sub></b>	85,84%	85,97%
<b>LBP<sub>HF</sub></b>	75,05%	74,78%
<b>LPQ</b>	81,19%	80,24%
<b>Gabor</b>	<b>87,66%</b>	87,05%

6.3 se mantêm, mesmo com a adição de novos descritores. Os atributos de cor passam a ter melhores taxas de reconhecimento quando a imagem é dividida em mais pedaços (em média 0,96 pp na fusão por soma e 1,16 pp na fusão por votação), e para os outros descritores essa taxa tendem a diminuir (em média 2,62 pp na fusão e 3,00 pp na votação). O descritor que apresentou uma taxa de reconhecimento mais significativa (a favor dos 25 pedaços) entre as duas comparações foi o Histograma de Borda (EOH) que obteve 19,08 pp a mais na fusão por soma, e 20,03 pp na fusão por votação.

A melhor taxa de reconhecimento com descritores individuais foi de 88,74% (RGB - 36 pedaços) na fusão por soma e 88,60% (RGB - 36 pedaços) na fusão por votação. Ainda através destes experimentos, é possível observar que a fusão por soma é, em média, 1,06 pp melhor, levando-se em conta a separação de 25 pedaços e, 1,25 pp, para a separação de 36 pedaços. Sendo a única exceção o LPQ (25 pedaços) que obteve melhores taxas através da fusão por soma, corroborando com os resultados obtidos no experimento apresentado na seção 6.3.

## 6.5 Divisão das imagens, Fusão dos pedaços e fusão dos classificadores - Proposta Completa

Tendo os resultados na fusão de baixo nível (seção 6.4), partiu-se para a fusão dos classificadores (alto nível). Para isso, foi feita uma combinação de todos contra todos, gerando um total de 4096 possibilidades de combinações, para cada uma das divisões de imagens (25 e 36 pedaços).

Avaliando-se a divisão de  $5 \times 5$ , as cinco melhores taxas de reconhecimento de cada tipo de fusão são apresentadas nas Tabelas 6.12 (fusão por votação) e 6.13 (fusão por soma). Através destes resultados, percebe-se que a regra de soma é superior em média, apenas 0,31 pp.

Tabela 6.12: Combinação classificadores - Fusão por Votação - 25 pedaços

Descritores	Votação
GLCM, Gabor, EOH e RGB	<b>95,62%</b>
Gabor, EOH, RGB e LBP <sub>8,2</sub>	95,28%
Gabor, Fractais, EOH, RGB e LBP <sub>8,2</sub>	95,28%
Gabor, EOH, RGB e LBP <sub>16,2</sub>	95,21%
Gabor, Fractais, Canais Mistos, LAB e LBP <sub>8,2</sub>	95,21%

Avaliando-se a divisão de  $6 \times 6$ , as cinco melhores taxas de reconhecimento de cada tipo de fusão são apresentadas nas Tabelas 6.14 (fusão por votação) e 6.15 (fusão por soma). Através destes resultados, percebe-se que a regra de soma é superior em média, apenas 0,26 pp.

Sobre os resultados, observa-se a alta complementariedade dos descritores de textura dos três tipos (estatísticos, espectrais e estruturais), como o Filtro Gabor, RGB / LAB,

Tabela 6.13: Combinação classificadores - Fusão por Soma - 25 pedaços

Descritores	Soma
Gabor, EOH, RGB e LBP <sub>16,2</sub>	<b>95,82%</b>
Gabor, EOH, RGB e LBP <sub>8,2</sub>	95,68%
GLCM, Gabor, EOH, RGB e LBP <sub>8,2</sub>	95,62%
GLCM, Gabor, Canais Mistos, RGB e LBP <sub>8,2</sub>	95,55%
GLCM, Gabor, Fractais e RGB	95,48%

Tabela 6.14: Combinação classificadores - Fusão por Votação - 36 pedaços

Descritores	Votação
Gabor, Fractais e RGB	<b>95,21%</b>
Gabor, Fractais, LAB, RGB e LBP <sub>8,2</sub>	95,14%
Gabor, Canais Mistos, LAB, RGB, LBP <sub>16,2</sub> e LBP <sub>8,1</sub>	95,14%
LBP <sub>HF</sub> , Gabor, LAB, RGB e LBP <sub>8,2</sub>	95,08%
Gabor, EOH, LAB, RGB e LBP <sub>16,2</sub>	95,08%

Tabela 6.15: Combinação classificadores - Fusão por Soma - 36 pedaços

Descritores	Soma
Gabor, Canais Mistos, RGB e LBP <sub>16,2</sub>	<b>95,48%</b>
Gabor, Fractais, LAB, RGB e LBP <sub>16,2</sub>	95,41%
Gabor e RGB	95,41%
Gabor, LAB, RGB e LBP <sub>16,2</sub>	95,35%
Gabor, Fractais, EOH, LAB, RGB e LBP <sub>16,2</sub>	95,28%

Fractais / EOH e LBP<sub>8,2</sub> e LBP<sub>16,2</sub>, presentes em praticamente todos os melhores resultados.

Quando comparados os experimentos realizados com 25 e 36 pedaços, observa-se que, em média, as taxas de reconhecimento com 25 pedaços é 0,22 pp melhor. Porém, levando-se em consideração o custo computacional, o terceiro melhor resultado, usando-se a regra de soma com 36 pedaços, obteve-se 95,41 % de reconhecimento, usando-se dois descritores, o que representa somente 0,41 pp a menos que o melhor resultado (95,82 % - fusão por soma - 25 pedaços), que efetivamente representa, apenas  $\approx 6$  imagens.

## 6.6 Comparações usando-se o protocolo de campo e de laboratório

Dados os bons resultados das seções anteriores, o intuito dessa série de experimentos foi o de avaliar o protocolo para bases de imagens mais robustas, ou seja, imagens de melhor qualidade. Com esse intuito, para avaliar a abordagem proposta, tanto para as imagens adquiridas por meio do protocolo de campo (seção 4.1), quanto do protocolo de laboratório (seção 4.2), buscou-se uniformizar as bases. Para tanto, só foram usadas imagens de espécies presentes nas duas bases. Em relação à quantidade de imagens de cada espécie, foi selecionada, entre as duas bases, aquela que continha o menor número de

registros. Ao final, as bases ficaram compostas por 1949 imagens de 36 espécies, a Tabela 6.16 apresenta suas composições.

Tabela 6.16: Composição da união das duas bases

Nome popular	Nome Científico	Quantidade de Imagens
Acrocarpus	<i>Acrocarpus fraxinifolius</i>	39
Amapá	<i>Brosimum paraensis</i>	45
Andiroba	<i>Carapa guianensis</i>	33
Angelim Pedra	<i>Hymenolobium petraeum</i>	52
Araucária	<i>Araucaria angustifolia</i>	63
Bracatinga	<i>Mimosa scabrella</i>	41
Cabriuva Vermelha	<i>Myroxylon balsamum</i>	64
Castanheira	<i>Bertolothia excelsa</i>	58
Cedrinho	<i>Erismia uncinatum</i>	83
Cedro	<i>Cedrela fissilis</i>	32
Cedrorana	<i>Cedrelinga catenaeformis</i>	69
Cinamomo	<i>Melia azedarach</i>	51
Cumarú	<i>Dipteryx</i> sp	32
Cupiuba	<i>Goupia glabra</i>	40
Curupixa	<i>Micropholis venulosa</i>	78
Eucalipto	<i>Eucalyptus</i> sp	50
Freijó	<i>Cordia goeldiana</i>	53
Goiabão	<i>Pouteria pachycarpa</i>	52
Grevilea	<i>Grevilea robusta</i>	50
Imbuia	<i>Ocotea porosa</i>	46
Ipê	<i>Tabebuia</i> sp	50
Itauba	<i>Mezilaurus itauba</i>	64
Jatobá	<i>Hymenaea</i> sp	45
Jequetiba	<i>Cariniana estrellensis</i>	43
Louro	<i>Laurus nobilis</i>	40
Massaranduba	<i>Manilkara huberi</i>	49
Mogno	<i>Swietenia macrophylla</i>	78
Pau amarelo	<i>Euxylophora paraensis</i>	86
Pau marfim	<i>Balfourodendron riedelianum</i>	72
Peroba rosa	<i>Aspidosperma polyneuron</i>	23
Pinus	<i>Pinus</i> sp	48
Quaruba	<i>Vochysia</i> sp	52
Rouxinho	<i>Peltogyne</i> sp	58
Sucupira	<i>Bowdichia</i> sp	95
Tatajuba	<i>Bagassa guianensis</i>	58
Tauari	<i>Couratari</i> sp	57

De cada uma das bases foram analisadas as imagens inteiras, sendo extraídos atributos de cor (RGB, Lab e Canais mistos), GLCM<sub>cinza</sub>, EOH, Fractais, LBP<sub>8,1</sub>, LBP<sub>8,2</sub>, LBP<sub>16,2</sub>, LBP<sub>HF</sub> e Filtros Gabor. Na Tabela 6.17 são apresentados os resultados individuais de cada descritor para cada uma das bases. Nota-se que, quando as amostras estão bem preparadas (protocolo de laboratório), geram resultados melhores, em média, tem-se um ganho de 23,91 pp nas taxas de reconhecimento. Analisando-se essas diferenças é possível

perceber as limitações do protocolo de campo em função do equipamento de baixo custo e à pouca preparação das amostras.

Tabela 6.17: Taxas de reconhecimento individuais dos descritores para as duas bases

<b>Classificador</b>	<b>Laboratório</b>	<b>Campo</b>
RGB	93,79%	77,39%
Lab	<b>94,91%</b>	<b>80,55%</b>
Canais mistos	82,18%	56,42%
GLCM cinza	85,74%	52,44%
EOH	79,33%	37,78%
Fractais	69,45%	50,92%
LBP8,1	86,98%	59,00%
LBP8,2	84,64%	65,72%
LBP16,2	87,79%	68,36%
LBP <sub>HF</sub>	79,23%	53,26%
Gabor	91,85%	71,08%

Utilizando a combinação dos classificadores por soma e por votação nas imagens inteiras obtidas em laboratório, conseguiu-se como melhor taxa de reconhecimento, 98,47%, como pode ser observado na Tabela 6.18, que apresenta as cinco melhores taxas de reconhecimento, ordenadas pela regra da soma.

Tabela 6.18: Combinação classificadores - Imagem inteira - Protocolo laboratório

<b>Descritores</b>	<b>Soma</b>	<b>Votação</b>
Gabor, Fractais, Lab e RGB	<b>98,47%</b>	95,62%
Gabor, Fractais, Lab e LBP <sub>16,2</sub>	98,47%	95,52%
Gabor, Fractais, EOH, Canais Mistos, Lab, RGB e LBP <sub>16,2</sub>	98,37%	95,11%
Gabor, Fractais, Canais Mistos, Lab e RGB	98,37%	95,52%
Gabor, Fractais, Canais Mistos, Lab e LBP <sub>8,1</sub>	98,37%	94,60%

Já utilizando a combinação dos classificadores por soma e por votação nas imagens inteiras das imagens de campo, conseguiu-se como melhor taxa de reconhecimento, 92,16%, como pode ser observado na Tabela 6.19, que apresenta as cinco melhores taxas de reconhecimento, ordenadas pela regra da soma.

Tabela 6.19: Combinação classificadores - Imagem inteira - Protocolo campo

<b>Descritores</b>	<b>Soma</b>	<b>Votação</b>
Gabor, Fractais, EOH, Canais Mistos, Lab, LBP <sub>16,2</sub> e LBP <sub>8,2</sub>	<b>92,16%</b>	83,71%
Gabor, Fractais, Canais Mistos, Lab, LBP <sub>16,2</sub> e LBP <sub>8,2</sub>	92,06%	83,91%
Gabor, Fractais, EOH, Canais Mistos, Lab, LBP <sub>16,2</sub> e LBP <sub>8,1</sub>	91,65%	83,40%
LBP <sub>HF</sub> , Gabor, Fractais, Canais Mistos, Lab, RGB, LBP <sub>16,2</sub> e LBP <sub>8,2</sub>	91,55%	83,40%
LBP <sub>HF</sub> , Gabor, Fractais, Canais Mistos, Lab e LBP <sub>8,2</sub>	91,55%	83,30%

Comparando-se as duas bases, obteve-se uma taxa de reconhecimento de 6,31 pp melhor com o protocolo de laboratório.

Na etapa seguinte, para seguir o protocolo completo desta proposta, os resultados dos descritores foram fundidos usando-se as regras de soma e votação, como descrito nos experimentos da seção 6.4. Porém, só foi usada a divisão de 25 pedaços, devido ao fato desta ter apresentado os melhores resultados.

Os resultados obtidos na fusão por votação e soma, usando-se o protocolo de campo, são apresentados nas Tabelas 6.20, e 6.21, respectivamente.

Tabela 6.20: Combinação classificadores - Fusão por Votação - 25 pedaços - Protocolo de Campo

Descritores	Votação
GLCM, Gabor, Fractais, Canais Mistos e RGB	<b>95,93%</b>
GLCM, Gabor, Fractais, EOH, Canais Mistos, LAB e RGB	95,82%
Gabor, Fractais, EOH, Canais Mistos, LAB, RGB e LBP <sub>8,2</sub>	95,82%
GLCM, Gabor, Fractais e RGB	95,82%
GLCM, Gabor, Canais Mistos e RGB	95,72%

Tabela 6.21: Combinação classificadores - Fusão por Soma - 25 pedaços - Protocolo de Campo

Descritores	Soma
GLCM, Gabor, Fractais, Canais Mistos e RGB	<b>95,93%</b>
GLCM, Gabor, LAB, RGB e LBP <sub>8,1</sub>	<b>95,93%</b>
GLCM, Gabor, Fractais, EOH, Canais Mistos e RGB	<b>95,93%</b>
GLCM, Gabor, Fractais, EOH, LAB, RGB e LBP <sub>16,2</sub>	<b>95,93%</b>
GLCM, Gabor, Fractais, LAB, RGB e LBP <sub>8,1</sub>	<b>95,93%</b>

O melhor resultado de cada experimento é igual (95,93% de taxa de reconhecimento), ou seja, das 982 imagens de teste, somente 40 foram classificadas de forma equivocada. Esta taxa foi conseguida com a mesma formação de classificadores (GLCM, Gabor, Fractais, Canais Mistos e RGB) para as duas regras de fusão. Na Figura 6.4 é apresentada a matriz de confusão para esta combinação, onde a espécie 14 (Cumaru - *Dipteryx* sp) obteve as maiores taxas de confusões (5 erros), sendo quatro deles em relação à espécie 17 (Eucalipto - *Eucalyptus* sp). Já a espécie 12 (Cedrorana - *Cedrelinga catenaeformis*) recebeu a maior quantidade de erros (9 erros).

A Figura 6.5 apresenta uma imagem de Eucalipto e três das quatro imagens de Cumaru que foram classificadas como Eucalipto, em que se pode perceber a similaridade entre as amostras.

O mesmo foi feito usando-se o protocolo de laboratório e os resultados obtidos na fusão por votação e soma são apresentados nas Tabelas 6.22 e 6.23, respectivamente.

Os cinco melhores resultados das duas regras de fusão obtiveram o mesmo resultado, 99,49% de reconhecimento, ou seja, das 982 imagens de teste, somente cinco foram classificadas de forma equivocada. Na Figura 6.6 é apresentada a matriz de confusão para estas combinações.

	1	2	3	4	5	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	28	29	31	32	33	34	36	37	38	39	40	Erros	
1	20																																					0
2		23																																				0
3			15				1			1																												2
4				24										1																					1			2
5					32																																	0
7						21																																0
8							32																															0
9								28			1																											1
10									42																													0
11										14	1																	1										2
12											35																											0
13												26																										0
14											1	11		4																								5
15											1				18												1											2
16																39																						0
17				1			1									21														1			1				4	
18																	27																					0
19	2							1																														3
20																																						0
21																																						0
22							1																															1
23																																						0
24											1																											2
25																																						0
26																																						0
28											1																											1
29								1	1	1	2																											4
31							1																															4
32																																						1
33																																						1
34	1																																					2
36											1																											1
37																																						0
38																																						1
39																																						0
40															1																							1

Figura 6.4: Matriz de Confusão da Combinação classificadores - Fusão por Soma - 25 pedaços - Protocolo de Campo



(a) Eucalipto - *Eucalyptus* sp



(b) Cumaru - *Dipteryx* sp



(c) Cumaru - *Dipteryx* sp



(d) Cumaru - *Dipteryx* sp

Figura 6.5: Exemplo de imagem de Eucalipto (a) e três imagens de Cumaru (b-d) classificadas como eucalipto

Na Figura 6.7 são apresentadas as amostras confundidas (a, c, e, g e h) e uma amostra das espécies que geraram a confusão (b, d, f e i). Percebe-se que as amostras são relativamente parecidas (estruturalmente), mas que o principal fator de confusão são as

Tabela 6.22: Combinação classificadores - Fusão por Votação - 25 pedaços - Protocolo de Laboratório

Descritores	Votação
GLCM, Fractais, Canais Mistos, Lab, RGB e LBP <sub>16,2</sub>	<b>99,49%</b>
GLCM, Fractais, Canais Mistos, Lab, RGB e LBP <sub>8,2</sub>	<b>99,49%</b>
Gabor, Fractais, Canais Mistos, Lab, RGB e LBP <sub>8,2</sub>	<b>99,49%</b>
GLCM, Gabor, Fractais, Canais Mistos, LAB, RGB e LBP <sub>8,2</sub>	<b>99,49%</b>
Gabor, Fractais, EOH, Canais Mistos, Lab, RGB e LBP <sub>8,2</sub>	<b>99,49%</b>

Tabela 6.23: Combinação classificadores - Fusão por Soma - 25 pedaços - Protocolo de Laboratório

Descritores	Soma
GLCM, Fractais, Canais Mistos, Lab, RGB e LBP <sub>16,2</sub>	<b>99,49%</b>
GLCM, Fractais, Canais Mistos, Lab, RGB e LBP <sub>8,2</sub>	<b>99,49%</b>
GLCM, Gabor, Fractais, Canais Mistos, Lab, RGB	<b>99,49%</b>
GLCM, Gabor, Fractais, Canais Mistos, Lab, RGB e LBP <sub>8,2</sub>	<b>99,49%</b>
Gabor, Fractais, EOH, Canais Mistos, Lab, RGB e LBP <sub>8,2</sub>	<b>99,49%</b>

	1	2	3	4	5	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	28	29	31	32	33	34	36	37	38	39	40	Erros
1	20																																				0
2		23																																			0
3			17																																		0
4				26																																	0
5					32																																0
7						21																															0
8							32																														0
9								29																													0
10									42																												0
11										16																											0
12											35																										0
13												26																									0
14													15																								1
15														20																							0
16															39																						0
17																25																					0
18																	27																				0
19																		25																			1
20																			25																		0
21																				23																	0
22																					25																0
23																						32															0
24																							23														0
25																								21													1
26																									20												0
28																										25											0
29																											39										0
31																												43									0
32																													36								0
33																														12							0
34																															24						0
36																																26					0
37																																	29				0
38																																		48			0
39																																			29		0
40																																				27	2

Figura 6.6: Matriz de Confusão da Combinação classificadores - Fusão por Soma e Votação - 25 pedaços - Protocolo de Laboratório

cores, pois estas são muito próximas.

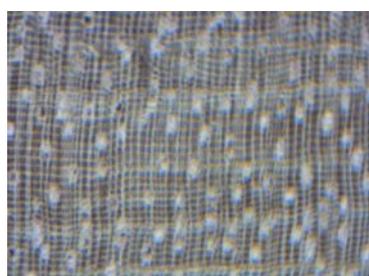
(a) Cumaru - *Dipteryx* sp(b) Jatobá - *Hymenaea* sp(c) Goiabão - *Pouteria pachycarpa*(d) Amapá - *Brosimum paraensis*(e) Jequetibá - *Cariniana estrellensis*(f) Cedrinho - *Erisma uncinatum*(g) Tauari - *Couratari* sp(h) Tauari - *Couratari* sp(i) Araucária - *Araucaria angustifolia*

Figura 6.7: Imagens que geraram confusão - Protocolo de Laboratório

## CAPÍTULO 7

### CONCLUSÃO

Um dos objetivos deste trabalho foi o de construir uma base de imagens macroscópicas de espécies florestais e que esta possa servir para auxiliar outros trabalhos de pesquisa na área. Para tanto, foram construídas duas bases, disponíveis em <http://web.inf.ufpr.br/vri/forest-species-database>.

A primeira foi adquirida através de equipamento disponível no Laboratório de Anatomia da Madeira da UFPR (estereomicroscópio), cujo objetivo foi o de ter uma base de referência (controle) que se aproximasse a outros trabalhos relatados na literatura, para tanto, obteve-se 2380 imagens referentes a 40 espécies. Tal base é melhor descrita na seção 4.2.

A segunda base (foco deste trabalho) foi o de permitir que o reconhecimento fosse efetuado em campo, ou seja, as imagens foram adquiridas baseando-se em uma solução de baixo custo e baixa complexidade para a preparação das amostras. Para tanto, foi construída uma estrutura e proposto um protocolo que permitisse a aquisição das imagens em campo. Esta base é composta de 2942 imagens de 41 espécies florestais, e é melhor descrita na seção 4.1.

Já em relação ao estudo de técnicas computacionais que viessem a auxiliar nesta tarefa, buscou-se uma série de descritores de textura, usando-se as abordagens estatísticas, estruturais e espectrais. A partir de uma série de experimentos, chegou-se a 12 descritores que obtiveram resultados satisfatórios, e sobre estes, experimentos individualizados foram realizados e alguns destes são descritos no capítulo 6.

A partir das imagens adquiridas e das técnicas de extração de seus atributos, definiu-se uma proposta de *dividir para conquistar*, através da qual, problemas pontuais gerados na aquisição ou naturais, não interferissem na identificação total da imagem. Para tanto, a imagem foi dividida em subimagens, os atributos foram extraídos e classificados. Os resultados individuais de cada descritor de textura, obtidos pelo classificador são fundidos através de duas camadas de fusão (alto e baixo nível) para, então, chegar-se à decisão final. Tal protocolo mostrou-se robusto para a base de imagens de campo (41 espécies), chegando-se a uma taxa de 95,82% de reconhecimento. Aplicando-se o mesmo protocolo na base de imagens adquiridas em laboratório, que serviu como controle, seguindo padrões similares aos experimentos apresentados na literatura, a taxa de reconhecimento foi de 99,49%, ou seja, houve somente cinco imagens classificadas de forma errada, em um total de 982 usadas como teste. A partir desses resultados, pode-se afirmar que o protocolo proposto funciona com diferentes sistemas de aquisição.

Desta forma conclui-se que a aplicação atendeu a todos os objetivos propostos, podendo ser uma referência a trabalhos futuros.

## 7.1 Trabalhos Futuros

Com a experiência adquirida neste trabalho, sugere-se algumas novas atividades que permitiriam sua complementação:

- **Bases de imagens:** acrescentar novas imagens às espécies já existentes, o que aumentaria o nível de reconhecimento desta proposta, bem como aumentar o número de espécies contempladas, permitindo uma maior diversidade ao sistema.
- **Extração de características:** estudar novas técnicas a serem agregadas à solução proposta, bem como testar novas configurações de parâmetros a algumas das técnicas escolhidas.
- **Fusão de classificadores:** buscar novas técnicas de fusão de classificadores, utilizando, por exemplo, técnicas de seleção dinâmica de classificadores.
- **Seleção de atributos:** apesar dos bons resultados, algumas das técnicas de extração de características geram muitos atributos e a seleção destes pode gerar melhores resultados com menor custo computacional.
- **Dissimilaridade:** amostras de novas espécies florestais têm sido conseguidas, permitindo assim, aumentar gradativamente a base de imagens. O uso de uma abordagem baseada em dissimilaridade pode vir a ser utilizada para garantir a escalabilidade do sistema.

## BIBLIOGRAFIA

- [1] Timo Ahonen, Abdenour Hadid, e Matti Pietikainen. Face recognition with local binary patterns. *Proceedings ECCV*, páginas 469–481, 2004.
- [2] Timo Ahonen, Jiri Matas, Chu He, e Matti Pietikainen. Rotation invariant image description with local binary pattern histogram fourier features. *Image Analysis*, páginas 61–70, 2009.
- [3] Hazem Al-Otum, Walid Shahab, e Smadi Mamoon. Colour image compression using a modified angular vector quantization algorithm. *Journal of Electrical Engineering*, 57:61–70, 2006.
- [4] C. Allain e M. Cloitre. Characterizing the lacunarity of random and deterministic fractal sets. *Physical Review A (Atomic, Molecular, and Optical Physics)*, páginas 3552–3558, 1991.
- [5] Wonder Alexandre Luz Alves e Sidnei Alves de Araújo. Avaliação da utilização de dois diferentes modelos de redes neurais na classificação de imagens com base em características texturais. *Exacta*, v. 4, n. 1:77–86, 2006.
- [6] Neide Pizzolato Angelo. Aplicação de filtros de gabor no processo de classificação de imagens digitais com base em atributos de textura. Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul, 2000.
- [7] Andre R. Backes, Jarbas J. M. Sá Junior, Odemir M. Bruno, e Rosana M. Kolb. Identificação de táxons de plantas por análise de textura do parênquima paliçádico. *4o Workshop de Visão Computacional*, páginas 57–62, 2008.
- [8] A. Baraldi e F. Pannigiani. An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. *IEEE Transactions on Geoscience and Remote Sensing*, 33:293–304, 1995.
- [9] X. L. Bardera. *Texture recognition under varying imaging geometries*. Tese de Doutorado, Departament of electronics, computer science and automatic control. Universitat de Girona, Girona, 2003.
- [10] Jennifer Anne Barker. *A prototype interactive 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. The University of Adelaide. Australia, 2005.

- [11] Túlio Cleber Bender. Classificação e recuperação de imagens por cor utilizando técnicas de inteligência artificial. Dissertação de Mestrado, Dissertação em Computação Aplicada. Universidade do Vale dos Sinos, São Leopoldo. RS, 2003.
- [12] D. Bertolini, Luiz S. Oliveira, Edson J. R. Justino, e Robert Sabourin. Reducing forgeries in writer-independent off-line signature verification through ensemble of classifiers. *Pattern Recognition*, 43(1):387–396, 2010.
- [13] R. Bremananth, B. Nithya, e R. Saipriya. Wood species recognition system. *International Journal of Computer Systems Science and Engineering*, 4 : 1:54 – 60, 2009.
- [14] Luiza Maria Burger e Hans Georg Richter. *Anatomia da Madeira*. Nobel, 1991.
- [15] Cesar A. B. Castañon. Recuperação de imagens por conteúdo através de análise multiresolução por wavelets. Dissertação de Mestrado, Dissertação de Ciências de Computação e Matemática Computacional. ICMC-USP, São Carlos - SP, 2003.
- [16] Chih Chung Chang e Chih Jen Lin. *LIBSVM - a library for support vector machine*, 2001. Disponível em <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [17] Y. Q. Chen, M. S. Nixon, e D. W. Thomas. Statistical geometrical features for texture classification. *Pattern Recognition*, 8:537–552, 1995.
- [18] Aura Conci, Eduardo Azevedo, e Fabiana R. Leta. *Computação Grafica. Teoria e Pratica. Volume 2*. Elsevier, Rio de Janeiro, 2008.
- [19] T. Dacheng, L. Xuelong, Y. Yuan, Y. Nenghai, L. Zhengkai, e T. Xiau-Ou. A set of novel textural features based on 3d cooccurrence matrix for content based image retrieval. *Proceedings of the Fifth International Conference on Information Fusion*, páginas 1403–1407, 2002.
- [20] John G. Daugman. Complete discrete 2d gabor transforms by neural networks for image analysis and compression. *IEEE Transactions on acoustics, speech, and signal processing*, 36:1169 – 1179, 1988.
- [21] Sanderson Lincoln Gonzaga de Oliveira. Desenvolvimento de um algoritmo baseado no filtro de gabor para identificação de impressões digitais. Dissertação de Mestrado, Universidade do Estado do Rio de Janeiro, 2004.
- [22] Pedro Luiz de Paula Filho, Alceu Brito Jr, e Luiz Soares Oliveira. A database for forest species recognition. *Procs of the XXII Brazilian Symposium on Computer Graphics and Image Processing*, páginas 1–2, 2009.

- [23] Pedro Luiz de Paula Filho, Alceu Brito Jr, Luiz Soares Oliveira, e R. Sabourin. Forest species recognition using color based features. *20th International Conference on Pattern Recognition (ICPR2010)*, páginas 4178–4181, 2010.
- [24] Pedro Luiz de Paula Filho, Douglas Rodrigo Roiek, Angelo Marcelo Tuset, e Luiz Eduardo S. Oliveira. Análise de cor para o reconhecimento de espécies florestais. *8th Brazilian Conference on Dynamics, Control and Applications. Dincon 09*, páginas 1 – 6, 2009.
- [25] IPT Instituto de Pesquisas Tecnológicas do estado de São Paulo. *Madeiras: material para o Design*. Secretaria da Ciência, Tecnologia e Desenvolvimento Econômico do estado de São Paulo, 1997.
- [26] G. Van de Wouwer, P. Scheunders, e D. Van Dyck. Statistical texture characterization from discrete wavelet representations. *IEEE Transactions on Image Processing*, 8:592–598, 1999.
- [27] Sébastien Deguy, Christophe Debain, e Albert Benassi. Classification of texture images using multi scale statistical estimators of fractal parameters. *British Machine Vision Conference*, páginas 192–201, 2000.
- [28] G. Dougherty e G. M. Henebry. Fractal signature and lacunarity in the measurement of the texture of trabecular bone in clinical ct images. *Medical Engineering & Physics* 23, páginas 369–80, 2001.
- [29] Kai-Bo Duan e S. Sathya Keerthi. Which is the best multiclass svm method? an empirical study. *Proceedings of the Sixth International Workshop on Multiple Classifier Systems*, páginas 278 – 285, 2005.
- [30] Kenneth Falconer. *Fractal Geometry: Mathematical Foundations and Applications. 2nd Edition*. Wiley, 2003.
- [31] E. Q. Filgueiras. Síntese de texturas utilizando modelos estatísticos espaciais. Dissertação de Mestrado, Dissertação de Mestrado em Computação Aplicada. INPE, São José dos Campos. SP, 2000.
- [32] M. N. Barros Filho e F. J. A. Sobreira. Assessing texture pattern in slums across scales: an unsupervised approach. *Centre for Advanced Spatial Analysis. University College London*, páginas 1–12, 2005.
- [33] M. N. Barros Filho e F. J. A. Sobreira. Accuracy of lacunarity algorithms in texture classification of high spatial resolution images from urban areas. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, páginas 417–422, 2008.

- [34] David A. Forsyth e Jean Ponce. *Computer Vision: A modern Approach*. Prentice Hall, 2003.
- [35] William T. Freeman e Michal Roth. Orientation histograms for hand gesture recognition. *IEEE Intl. Wkshp. on Automatic Face and Gesture Recognition*, páginas 1–9, 1995.
- [36] Rafael C. Gonzalez e Richard C. Woods. *Processamento Digital de Imagens - 3a Edição*. Pearson prentice Hall, 2010.
- [37] Guang hai Liu e Jing yu Yang. Image retrieval based on the texton co-occurrence matrix. *Pattern Recognition*, páginas 3521–3527, 2008.
- [38] Ricky K. Hammon e Mark A. Strauser. Improvements to the gray-level co-occurrence matrix [glcm] based trackability metric. *Proceedings of the Ground Target Modeling and Validation Conference*, páginas 5–8, 2002.
- [39] R. M. Haralick. Statistical and structural approaches to texture. *Proceedings of IEEE, Vol. 67, No. 5*, 67:786–804, 1979.
- [40] R. M. Haralick, K. Shanmugam, e I. Dinstein. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics.*, 6:610–621, 1973.
- [41] R. B. Hoadley. *Identifying wood: accurate results with simple tools*. Taunton Press, 1990.
- [42] M. C. Hott, V. P. Soares, C. A. A. S. Ribeiro, e J. J. Griffith. Análise fractal de textura usando um operador de hurst em uma imagem tm/landsat-5. *Anais XII Simpósio Brasileiro de Sensoriamento Remoto*, páginas 4089–4093, 2005.
- [43] Dana E. Ilea e Paul F. Whelan. Image segmentation based on the integration of colour texture descriptors - a review. *Pattern Recognition*, páginas 2479–2501, 2011.
- [44] Jarmo Ilonen, Joni Kristian Kamarainen, e Heikki Kalviainen. Efficient computation of gabor features. Relatório técnico, Lappeenranta University of Technology, 2005.
- [45] Carl Zeiss International. *Profile SteREO Discovery V12*, Acesso em 2012. Disponível em [http://www.zeiss.com/4125681F004E2140/EmbedTitelIntern/DiscoveryStereo\\_OverviewProfile/\\$File/Discovery\\_Stereo\\_Overview\\_Profile.pdf](http://www.zeiss.com/4125681F004E2140/EmbedTitelIntern/DiscoveryStereo_OverviewProfile/$File/Discovery_Stereo_Overview_Profile.pdf).
- [46] Konsatntinos Ioannou, Dimitirios Birbilis, e Panagiotis Lefakis. A pilot prototype decision support system for recognition of greek forest species. *Operational Research*, 9:141–152, 2009.

- [47] Rodrigo Hajime Ito, Hae Yong Kim, e Walter Jaimes Salcedo. Classificação de texturas invariante a rotação usando matriz de co-ocorrência. *8th International Information and Telecommunication Technologies Symposium*, páginas 1–6, 2009.
- [48] M. Ivanovici e N. Richard. The lacunarity of colour fractal images. *ICIP - IEEE International Conference on Image Processing*, páginas 453–456, 2009.
- [49] Anil K. Jain e Aditya Vailaya. Image retrieval using color and shape. *Pattern Recognition*, 29:1233–1244, 1996.
- [50] B. Julesz. Visual pattern discrimination. *IRE Transactions on Information Theory*, 8:84–92, 1962.
- [51] Moacir Pereira Ponti Junior. Combinação de múltiplos classificadores para identificação de materiais em imagens ruidosas. Dissertação de Mestrado, Universidade Federal de São Carlos. Programa de Pós Graduação em Ciência da Computação., 2004.
- [52] Joni Kristian Kamarainen. *Feature extraction using gabor filters*. Tese de Doutorado, Lappeenranta University of Technology, 2003.
- [53] Hannu Kauppinen. A two stage defect recognition method for parquet slab grading. *Proceedings 15th International Conference on Pattern Recognition. ICPR 2000.*, 4:803–806, 2000.
- [54] Marzuki Khalid, E. Lew Yi Lee, Rubiyah Yusof, e Miniappan Nadaraj. Design of an intelligent wood species recognition system. *IJSSST*, 9:9–19, 2008.
- [55] Josef Kittler, Mohamad Hatef, Robert P.W. Duin, e Jiri Matas. On combining classifiers. *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 20. No. 3:226–239, 1998.
- [56] P. Kruizinga, N. Petkov, e S. E. Grigorescu. Comparison of texture features based on gabor filters. *Proceedings of the 10th International Conference on Image Analysis and Processing*, 11:1160–1167, 1999.
- [57] Ajay Kumar e Grantham Pang. Defect detection in textured materials using gabor filters. *IEEE Transactions on Industry Applications*, 38:425–440, 2002.
- [58] 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*, Vol. 55 - 8:960 – 966, 2001.
- [59] C. J. Lee e S. D. Wang. Fingerprint feature extraction using gabor filters. *Electronic Letters*, 35:288–290, 1999.

- [60] Chih Jen Lee, Sheng De Wang, e Kuo Ping Wu. Fingerprint recognition using principal gabor basis function. *Proceedings of 2001 International Symposium on Intelligent Multimedia, video and Speech Processing*, páginas 393–396, 2001.
- [61] K. Levi e Y. Weiss. Learning object detection from a small number of examples. the importance of good features. *Computer Vision and Pattern Recognition, 2004. CVPR 2004. Proceedings of the 2004 IEEE Computer Society Conference on*, volume 2, páginas II–53 – II–60 Vol.2, june. 2 july de 2004.
- [62] WeiFeng Liu e ZengFu Wan. Facial expression recognition based on fusion of multiple gabor features. *18th International Conference on Pattern Recognition*, páginas 536–539, 2006.
- [63] Rastislav Lukac e Konstantinos N. Plataniotis. *Color image processing: methods and applications*. CRC Press, 2007.
- [64] Huanfeng Ma e David Doermann. Gabor filter based multi-class classifier for scanned document images. *Proceedings of the Seventh International Conference on Document Analysis and Recognition*, páginas 968–972, 2003.
- [65] Alvaro M. L. Machado. *Extração Automática de Contornos de Edificações Utilizando Imagem Gerada por Câmara Digital de Pequeno Formato e Dados LIDAR*. Tese de Doutorado, Programa de Pós-Graduação em Ciências Geodésicas - Universidade Federal do Paraná, Curitiba - PR, 2006.
- [66] Topi Maenpaa. The local binary pattern approach to texture analysis. extensions and applications. Dissertação de Mestrado, Department of Electrical and Information Engineering, University of Oulu, 2003.
- [67] Topi Maenpaa, Timo Ojala, Matti Pietikainen, e Maricor Soriano. Robust texture classification by subsets of local binary patterns. *Proc. 15th International Conference on Pattern Recognition*, páginas 935–938, 2000.
- [68] Topi Maenpaa, Matti PietikGnen, e Jaakko Viertola. Separating color and pattern information for color texture discrimination. *Object recognition supported by user interaction for service robots*, páginas 668–671, 2002.
- [69] Topi Maenpaa, Markus Turtinen, e Matti Pietikainen. Real-time surface inspection by texture. *Real Time Imaging*, 9:289–296, 2003.
- [70] S. G. Mallat. A theory for multiresolution signal decomposition: The wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, II:674–693, 1989.

- [71] Benoit B. Mandelbrot, Romualdo Satorras, e Erik M. Rauch. *The geometry of Critical Ising Clusters: Cap Independence and Global Structure*. Yale University, 1996.
- [72] B. S. Manjunath, P. Newsam, S. Wu, e H. D. Shin. A texture descriptor for browsing and similarity retrieval. *Signal Processing: Image Communication*, 16:33–43, 2000.
- [73] J. Martins, L. S. Oliveira, S. Nisgoski, e R. Sabourin. A database for automatic classification of forest species. *Machine Vision and Applications*, páginas 1–12, 2012.
- [74] R. H. C. Melo. Using fractal characteristics such as fractal dimension, lacunarity and succolarity to characterize texture patterns on images. Dissertação de Mestrado, Dissertação do programa de pós graduação em Computação Universidade Federal Fluminense, Rio de Janeiro - RJ, 2007.
- [75] Majid Mirmehdi e Maria Petrou. Segmentation of color textures. *IEEE Transactions on pattern analysis and machine intelligence*, 22:142–159, 2000.
- [76] M. Musci, R. Q. Feitosa, M. L. F. Velloso, T. Novack, e G. A. O. P. Da Costa. Uma avaliação de descritores de textura baseados em códigos binários locais para classificação de imagens de sensoriamento remoto. *Boletim de Ciências Geodésicas*, Vol. 17, No 4:549 – 570, 2011.
- [77] S. W. Myint, V. Mesev, e N. Lam. Urban textural analysis from remote sensor data: Lacunarity measurements based on the differential box counting method. *Geographical Analysis*, páginas 371–390, 2006.
- [78] J. P. R. Nascimento. Análise e classificação de imagens baseadas em características de textura utilizando matrizes de coocorrência. Dissertação de Mestrado, Dissertação do programa de pós-graduação em Informática Universidade Federal do Paraná, Curitiba - PR, 2003.
- [79] M. Nasirzadeh, A. Arab Khazael, e Marzuki bin Khalid. Woods recognition system based on local binary pattern. *International Conference on Computational Intelligence, Communication Systems and Networks*, 2010.
- [80] Nikon. The story of light and people. the concept of seeing, 2009. [www.nikon.com/about/feelnikon/light/chap03/img/sec01pic05.jpg](http://www.nikon.com/about/feelnikon/light/chap03/img/sec01pic05.jpg).
- [81] Silvana Nisgoski. Identificação e caracterização anatômica macroscópica das principais espécies utilizadas para laminação na região de curitiba pr. Dissertação de Mestrado, Pós-graduação em Engenharia Florestal do setor de Ciências Agrárias da Universidade Federal do Paraná, 1999.

- [82] Matti Niskanen, Olli Silvén, e Hannu Kauppinen. Color and texture based wood inspection with non supervised clustering. *Proceedings of The 12th Scandinavian Conference on Image Analysis. SCIA2001*, páginas 336 . 342, 2001.
- [83] M. Nixon e A. Aguado. *Feature Extraction and Image Processing. Second Edition*. Elsevier, 2008.
- [84] T. Ojala, M. Pietikainen, e T. Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24:971–987, 2002.
- [85] Timo Ojala, Matti Pietikainen, e David Hardwood. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, 29:51–59, 1996.
- [86] Ville Ojansivu e Janne Heikkilä. Blur insensitive texture classification using local phase quantization. *ICISP*, páginas 236–243, 2008.
- [87] S. L. G. Oliveira, Flavio Viola, e Aura Conci. Filtro adaptativo para melhoria de imagens de impressões digitais utilizando o filtro de gabor e campos direcionais. *4o Congresso Temático de Dinâmica Controle e Aplicações DINCON*, 4:1057–1066, 2005.
- [88] Christoph Palm. Color texture classification by integrative co-occurrence matrices. *Pattern Recognition*, 37:965–976, 2003.
- [89] J. R. Parker. *Algorithms for Image Processing and Computer Vision*. John Wiley & Sons Inc, 1997.
- [90] T. C. M. Pastore, J. W. B. Braga, V. T. R. Coradin, W. L. E. Magalhaes, E. Y. A. Okino, J. A. A. Camargos, G. I. B. de Muniz, O. A. Bressan, e F. Davrieux. Near infrared spectroscopy (nirs) as a potential tool for monitoring trade of similar woods: Discrimination of true mahogany, cedar, andiroba, and curupixa. *Holzforschung*, 65:73 – 80, 2011.
- [91] José E. Paula. Caracterização anatômica de madeiras nativas do cerrado com vistas à produção de energia. *Revista Cerne*, 5:26–40, 1999.
- [92] José E. Paula e José L. H. Alves. *Madeiras Nativas. Anatomia, dendrologia, dendrometria, produção e uso*. Fundação Mokiti Okada, Brasilia - DF, 1997.
- [93] José E. Paula, F. G. Silva Junior, e A. P. P. Silva. Caracterização anatômica de madeiras nativas de matas ciliares do centro-oeste brasileiro. *Scientia Forestalis, IPEF*, 58:73–89, 2000.

- [94] Hélio Pedrini e William R. Schwartz. *Análise de Imagens Digitais. Princípios, Algoritmos e Aplicações*. Thomson, São Paulo. SP, 2008.
- [95] Maria Petrou e Pedro G. Sevilha. *Image Processing Dealing with Texture*. John Wiley & Sons, 2006.
- [96] M. Pietikainen, T. Ojala, e Z. Xu. Rotation-invariant texture classification using feature distributions. *Pattern Recognition*, 33:43–52, 2000.
- [97] Matti Pietikäinen e Timo Ojala. Nonparametric texture analysis with complementary spatial operators. *Proc. Workshop on Texture Analysis in Machine Vision*, 40:3–18, 1999.
- [98] V. Piuri e F. Scotti. Design of an automatic wood types classification system by using fluorescence spectra. *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, 40(3):358–366, may de 2010.
- [99] R. O. Plotze e O. M. Bruno. Análise de formas e reconhecimento de padrões por meio da assinatura fractal multiescala. *INFOCOMP. Journal of Computer Science*, 6:91–100, 2007.
- [100] Stojanovic Radovan, Papadopoulos George, Mitropoulos Panagiotis, Georgoudakis Manos, Alcock Robert, e Djurovic Igor. An approach for automated inspection of wood boards. *Proceedings 2001 International Conference on Image Processing*, páginas 798–801, 2001.
- [101] Hans Georg Richter e Luiza Maria Burger. *Anatomia da madeira*, 1974. Departamento de Engenharia e Tecnologia Rural - Setor de Ciências Agrárias - Universidade Federal do Paraná.
- [102] John C. Russ. *The Image Processing Handbook. Fifth Edition*. Taylor and Francis Group, 2007.
- [103] Denis Henrique Pinheiro Salvadeo. *Combinação de múltiplos classificadores para reconhecimento de face humana*. Tese de Doutorado, Universidade Federal de São Carlos. Centro de Ciências Exatas e de Tecnologia. Programa de pós-graduação em Ciência da Computação, 2009.
- [104] Antonio F. Lima Serafim. Fractal signatures for complex natural textures recognition. *Proceedings of the 24th Annual Conference of the IEEE Industrial Electronics Society*, páginas 1252–1257, 1998.
- [105] Caifeng Shan, Shaogang Gong, e Peter W. McOwan. Facial expression recognition based on local binary patterns: A comprehensive study. *Image and Vision Computing*, 27:803–816, 2009.

- [106] R. E. Sánchez-Yáñez, E. V. Kurmyshev, e F. J. Cuevas. A framework for texture classification using the coordinated clusters representation. *Pattern Recognition Letters*, 24:21–31, 2003.
- [107] M. Sonka, V. Hlavac, e R. Boyle. *Image Processing, Analysis, and Machine Vision. Third Edition*. Thomson Learning, 2008.
- [108] T. Stein. Avaliação de descritores de textura para segmentação de imagens. Dissertação de Mestrado, Dissertação do programa de pós graduação em Informática Universidade Federal do Paraná, Curitiba PR, 2005.
- [109] T. N. Tan. Texture feature extraction via visual cortical channel modelling. *Pattern Recognition*, III:607–610, 1992.
- [110] J. Tarrío-Saavedra, S. Naya, M. F. Fernandez, J. L. Beceiro, e R. Artiaga. Functional nonparametric classification of wood species from thermal data. *Journal of Thermal Analysis and Calorimetry*, páginas 87 – 100, 2011.
- [111] Fumiaki Tomita e Saburo Tsuji. *Computer analysis of visual textures*. Kluwer Academic Publishers, 1990.
- [112] J. Y. Tou, P. Y. Lau, e Y. H. Tay. Computer vision-based wood recognition system. *Proceedings of International Workshop on Advanced Image Technology (IWAIT 2007)*, páginas 197–202, 2007.
- [113] J. Y. Tou, P. Y. Lau, e Y. H. Tay. One-dimensional grey-level co-occurrence matrices for texture classification. *Proceedings International Symposium on Information Technology 2008 (ITSIM 2008)*, 3:1592–1597, 2008.
- [114] Jing Yi Tou, Yong Haur Tay, e Phooi Yee Lau. A comparative study for texture classification techniques on wood species recognition problem. *Fifth International Conference on Natural Computation*, páginas 8–12, 2009.
- [115] Mihran Tuceryan e Anil K. Jain. *Texture Analysis*. In: C. H. Chen and L. F. Pau and P. S. P. WANG. *The Handbook of Pattern Recognition and Computer Vision (2nd Edition)*. World Scientific Publishing Co., 1998.
- [116] A. Vailaya, A. Jain, e Hong Jiang Zhang. On image classification: city vs. landscape. *Content-Based Access of Image and Video Libraries, 1998. Proceedings. IEEE Workshop on*, páginas 3 –8, jun de 1998.
- [117] Li Wang e Dong-Chen He. Texture classification using texture spectrum. *Pattern Recognition*, 23:905–910, 1990.

- [118] Changjiang Yang, R. Duraiswami, e L. Davis. Fast multiple object tracking via a hierarchical particle filter. *Computer Vision, 2005. ICCV 2005. Tenth IEEE International Conference on*, volume 1, páginas 212–219 Vol. 1, oct. de 2005.
- [119] Haipeng Yu, Jun Cao, Yixing Liu, e Wei Luo. Non equal spacing division of hsv components for wood image retrieval. *2nd International Congress on Image and Signal Processing*, 6:1–3, 2009.
- [120] Haipeng Yu, Jun Cao, Wei Luo, e Yixing Liu. Image retrieval of wood species by color, texture, and spatial information. *International Conference on Information and Automation*, páginas 1116–1119, 2009.
- [121] Xiaojing Yuan. Svm - based texture classification and application to early melanoma detection. *Proceedings of the 28th IEEE EMBS Annual International Conference*, páginas 4775 – 4778, 2006.
- [122] Rubiyah Yusof, Nenny Ruthfalydia Rosli, e Marzuki Khalid. Using gabor filters as image multiplier for tropical wood species recognition system. *12th International Conference on Computer Modelling and Simulation*, páginas 284–289, 2010.
- [123] Jianke Zhu, Steven C.H. Hoi, Michael R. Lyu, e Shuicheng Yan. Near duplicate keyframe retrieval by nonrigid image matching. *ACM Multimedia 2008*, páginas 41 – 50, 2008.