Identificação de espécies vegetais por meio
da análise de textura foliar

Dalcimar Casanova

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito: 18 de agosto de 2008

Assinatura: _____

Identificação de espécies vegetais por meio da análise de textura foliar

Dalcimar Casanova

Orientador: *Prof. Dr. Odemir Martinez Bruno*

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação - ICMC/USP, como parte dos requisitos para obtenção do título de Mestre em Ciências de Computação e Matemática Computacional.

**USP - São Carlos
Agosto/2008**

Agradecimentos

A Deus, pela oportunidade oferecida, permitindo a realização de um sonho.

Aos meus pais Darci e Acioní, que mesmo à distância, me apóiam e me encorajaram em todos os momentos.

A minha amada namorada Larissa, pela felicidade a mim proporcionada, pela compreensão, carinho e companhia oferecida durante o tempo em que me mantive distante.

Ao meu orientador Prof. Dr. Odemir Martinez Bruno, pela confiança depositada em mim, orientação e amizade.

Aos amigos que fiz no convívio diário da universidade, em especial: Marco, André, Jarbas, João, Marcio e Cláudio.

Ao Roberto e aos amigos do ciclismo, que me proporcionaram viagens, diversão e experiências únicas.

Aos professores e funcionários do ICMC - USP e a todos que, direta ou indiretamente, colaboraram comigo.

À FAPESP pelo apoio financeiro.

Resumo

A biodiversidade das espécies existentes no riquíssimo reino vegetal, tornam os modelos tradicionais de taxonomia uma tarefa muito complexa e morosa, na qual o processo de classificação é tradicionalmente realizado manualmente. As dificuldades presentes nesse processo implicam na existência de poucas pesquisas de classificação vegetal utilizando métodos matemáticos e computacionais. Desta forma, visando contribuir com as técnicas de taxonomia já desenvolvidas, este estudo objetiva desenvolver e testar uma metodologia computacional de identificação de espécies vegetais por meio da análise da textura foliar. Motivado pelo projeto TreeVis, este trabalho realiza uma revisão dos métodos utilizados para análise de textura em imagens digitais (foco concentrado em extração de características e classificação), investigando a aplicabilidade de métodos tradicionais como matrizes de coocorrência, técnicas estado da arte como Gabor wavelets e também de novos e promissoras técnicas de análise de textura, como a dimensão fractal volumétrica. No contexto de classificação investiga-se métodos para reconhecimento de padrões lineares com base em análise de dados multivariados, não lineares com base na teoria das Redes Neurais Artificiais e métodos simples para combinação de diferentes classificadores (comitê de máquinas). Apesar da alta similaridade entre classes e similaridade intraclasses não adequada, os resultados alcançados mostraram-se excelentes. A melhor estratégia de classificação, utilizando comitê de máquinas com descritores de Gabor wavelets/cor e dimensão fractal volumétrica/cor, obteve uma probabilidade de acerto global de 96.32% nas 40 classes estudadas. Esse resultado demonstra como os métodos computacionais de análise de imagens, em especial análise de textura, podem contribuir facilitando e agilizando a tarefa de identificação de espécies vegetais.

Palavras chaves: Visão Computacional, Análise de Textura, Taxonomia, Identificação Vegetal, Folha, Reconhecimento de Padrões.

Abstract

Biodiversity of species existing in the plant kingdom make the use of traditional models of taxonomy, a process of classification traditionally performed manually, a very complex and time-consuming task. Most of difficulties in that process result from the existence of few researches on plant classification using mathematical and computational methods. In this way, to contribute with the taxonomy techniques already developed, this study aims to develop and test a computational method for identifying plant species by leaf texture analysis. Motivated by the TreeVis project, this work is a comprehensive revision of texture analysis methods used in digital images (focus concentrated in features extraction and classification). This study investigates the applicability of traditional methods such as co-occurrence matrix, state of the art techniques as Gabor wavelets, and new and promising texture analysis methods, such as volumetric fractal dimension. In classification context is investigated methods of pattern recognition based on multivariate data analysis, artificial neural networks and committee machines. Although leaf classes present high similarity between classes and not appropriate similarity intraclasses, the results obtained are excellent. The best strategy for classification, using committee machines with descriptors of Gabor wavelets/color and volumetric fractal dimension/color, yielded a high probability of success, 96.32% in 40 classes studied. This result demonstrates how computational methods of images analysis, in particular texture analysis, can contribute and make more easier and faster the task of identifying plant species.

Keywordd: Computer Vision, Texture Analysis, Taxonomy, Vegetal Identification, Leaf, Pattern Recognition.

Sumário

Resumo	ii
Abstract	iii
1 Introdução	1
1.1 Justificativa e Motivação	1
1.2 Objetivos	2
1.3 Organização	2
2 Análise de Vegetais e o Projeto TreeVis	3
2.1 Análise de Vegetais	3
2.2 Projeto TreeVis	5
2.2.1 Textura no TreeVis	6
3 Análise de Imagens	8
3.1 Introdução a Análise e Processamento de Imagens	8
3.2 Segmentação de Imagens	9
3.2.1 Limiarização	10
3.2.2 Morfologia Matemática	11
3.3 Análise Textura	14
3.3.1 Técnicas para Extração de Características	16
4 Reconhecimento de Padrões	37
4.1 Análise Discriminante	37
4.1.1 Análise Discriminante Linear	38
4.2 Redes Neurais	40
4.2.1 Perceptron Multicamadas	40
4.3 Comitê de Máquinas	43
4.3.1 Geração de Componentes	43
4.3.2 Métodos de Combinação	45
4.4 Análise de Componentes Principais	46
4.5 Validação Cruzada	47
4.5.1 <i>Holdout</i>	48
4.5.2 <i>K-fold</i>	48
4.5.3 <i>Leave-one-Out</i>	48

4.6	Teste de Grubb's	48
5	Sistema de Visão	50
5.1	Aquisição	51
5.2	Pré-Processamento	52
5.2.1	Segmentação	52
5.2.2	Extração Janelas Texturais	53
5.2.3	Descarte de Janelas Texturais	53
5.2.4	Descarte de Amostras	55
5.3	Extração de Características	57
5.3.1	Características de Primeira Ordem	59
5.3.2	Coocorrência	59
5.3.3	Fourier	60
5.3.4	Gabor Wavelets	61
5.3.5	Fractais	63
5.3.6	Momentos de Cromaticidade	64
5.3.7	Descritores de Cor Baseados na Estrutura Espacial	65
5.3.8	Descritores de Cor Baseados na Estrutura Espacial por Análise de DF	66
5.4	Classificação	67
5.4.1	Avaliação da Qualidade da Função Discriminante Obtida	68
5.4.2	Classificação Utilizando Redução de Dimensionalidade dos Dados	71
5.4.3	Classificação por Comitê de Máquinas	72
5.4.4	Classificação por Redes Neurais	73
6	Experimentos e Resultados	74
6.1	Base de Imagens	74
6.2	Análise e Discussão dos Resultados	78
6.2.1	Avaliação da Qualidade dos Métodos de Análise de Textura	79
6.2.2	Considerações Gerais	93
6.2.3	Avaliação dos Classificadores	96
7	Conclusão	102
7.1	Conclusão	102
7.1.1	Principais Contribuições	103
7.1.2	Trabalhos Futuros	104
	Anexo	105

Lista de Figuras

2.1	Ambiente de trabalho do projeto TreeVis [77].	6
2.2	Diagrama de blocos apresentando os módulos que compõem o sistema TreeVis e suas respectivas conexões [34].	7
3.1	Erosão, abertura, dilatação e fechamento. O elemento estruturante é o pequeno círculo presente em várias posições em (b) [39].	12
3.2	A função e constitui-se pela soma das quatro funções $e = a + b + c + d$. Fourier formulou no início do século XVIII a teoria de que qualquer função que se repita periodicamente pode ser representada como uma soma de senos e/ou cossenos de frequências diferentes [39].	20
3.3	(a) parte real de um filtro de Gabor no domínio do espaço e (b) parte real de um filtro de Gabor no domínio de Fourier.	24
3.4	Conjunto de filtros de Gabor wavelets no domínio da frequência gerados pela metodologia de Manjunath and Ma [66]. Os parâmetros utilizados foram $U_h = 0.3$, $U_l = 0.05$, $K = 6$ and $S = 4$	26
3.5	Divisão de uma imagem pelo método Box-counting. As caixas em tom cinza são as que possuem uma porção do contorno em análise. Adaptado de [4]. . . .	28
3.6	A direita gráfico log-log gerado pelo método de Minkowski. A esquerda gráfico da dimensão MultiEscala. Adaptado de [81].	29
3.7	Superfície gerada pela modelagem volumétrica de uma imagem em tons de cinza [7].	29
3.8	Diferença entre as superfícies geradas da imagem original (a) em escala de cinza (b) e com seus componentes RGB (c).	30
3.9	Processo de dilatação de um modelo S para vários valores de r , apresentando fraca interação entre as bandas de cores.	31
3.10	Processo de dilatação de um modelo S para vários valores de r , apresentando forte interação entre as bandas de cores.	31
3.11	Comparação entre as DF estimadas pelo modelo multiespectral e pelo modelo em escalas de cinza)	32
3.12	(a) DF para uma imagem com baixa iluminação e (b) DF para a mesma imagem com alta iluminação.	32
3.13	Um exemplo de: (a) diagrama de cromaticidade e (b) sua distribuição bidimensional (e.g. histograma). Adaptado de [74].	34
4.1	Grafo arquitetural de uma MLP com duas camadas ocultas. Adaptado de [44]. .	41

4.2	Ilustração do fluxo do sinal nas duas fases de aprendizado da MLP (forward e backward). Adaptado de [44]	42
5.1	Etapas envolvidas no sistema de análise e identificação de espécies vegetais por meio da análise de textura foliar.	50
5.2	(a) imagem original (b) resultado após limiarização automática de Otsu e (c) resultado após aplicação do filtro morfológico F com elemento estruturante circular.	53
5.3	Exemplo de extração das Janelas texturais de uma amostra.	54
5.4	Separação das cinco janelas mais representativas ($w' = 5$) dentre o conjunto de 30 janelas ($w = 30$) extraídas da amostra em análise. Conforme Figura 5.3. . .	56
5.5	Amostra considerada discordante da classe C11 conforme teste de Grubb's. . .	58
5.6	Categorização dos métodos de análise de textura em grupos e abordagens . . .	58
5.7	Processo de extração das características de primeira ordem.	59
5.8	Processo de extração das características de segunda ordem.	60
5.9	Processo de extração das características de Fourier (componentes radiais) . . .	61
5.10	Processo de extração das características de Fourier (componentes radiais/angulares).	61
5.11	Processo de extração das características por filtros de Gabor wavelets.	62
5.12	Processo de extração das características por DF de Bouligand-Minkowski volumétrica [7].	64
5.13	Processo de extração das características por DF de Bouligand-Minkowski volumétrica multiespectral.	65
5.14	Processo de extração das características derivadas dos momentos de cromaticidade.	65
5.15	Processo de extração dos descritores de cor baseados na estrutura espacial. . . .	66
5.16	Processo de extração dos descritores de cor baseados na estrutura espacial por análise de DF Bouligand-Minkowski volumétrica.	67
5.17	Etapas envolvidas no processo de avaliação dos métodos e dos classificadores .	68
6.1	40 classes utilizadas nos experimentos.	75
6.2	Um exemplo de textura apresentado por cada uma das 40 espécimes que compõe a base de dados.	76
6.3	Cinco exemplos de textura da classe/espécime C01.	77
6.4	Cinco exemplos de textura da classe/espécime C02.	77
6.5	Cinco exemplos de textura da classe/espécime C20.	77
6.6	Cinco exemplos de textura da classe/espécime C22.	77
6.7	Cinco exemplos de textura da classe/espécime C32.	77
6.8	Acima: texturas consideradas normais de diversas amostras da classe C17. Abaixo: texturas designadas como outliers através do teste de Grubb's com nível de significância $\alpha = 0.025$	79
6.9	Variância total explicada para os 10 primeiros principais componentes. Método de Gabor wavelets/cor.	97
6.10	Variância total explicada para os 10 primeiros principais componentes. Método de DF volumétrica/cor.	97

Lista de Tabelas

6.1	Número de outliers encontrados em cada classe respectivamente	79
6.2	Sumário da classificação usando LDA sobre descritores de primeira ordem (Base 1 com 7620 janelas texturais / Base 2 com 762 amostras)	80
6.3	Matriz de confusão, com respectivos erros de omissão e comissão, utilizando características de primeira ordem (base com 762 amostras).	80
6.4	Sumário da classificação usando LDA sobre descritores de coocorrência.	81
6.5	Matriz de confusão, com respectivos erros de omissão e comissão, utilizando características de coocorrência (base com 762 amostras).	82
6.6	Sumário da classificação usando LDA sobre descritores de Fourier por análise de componentes radiais.	82
6.7	Matriz de confusão, com respectivos erros de omissão e comissão, utilizando descritores de Fourier por análise de componentes radiais.	83
6.8	Sumário da classificação usando LDA sobre descritores de Fourier por análise de componentes radiais/angulares.	83
6.9	Matriz de confusão, com respectivos erros de omissão e comissão, utilizando descritores de Fourier por análise de componentes radiais/angulares.	84
6.10	Sumário da classificação usando LDA sobre filtro de Gabor wavelets.	85
6.11	Sumário da classificação usando LDA sobre descritores de Gabor wavelets.	86
6.12	Matriz de confusão, com respectivos erros de omissão e comissão, utilizando filtros de Gabor wavelets.	86
6.13	Sumário da classificação usando LDA sobre descritores de DF Bouligand-Minkowski volumétrica para diversos raios.	87
6.14	Sumário da classificação usando LDA sobre descritores de DF Bouligand-Minkowski volumétrica.	87
6.15	Matriz de confusão, com respectivos erros de omissão e comissão, utilizando descritores de DF Bouligand-Minkowski volumétrica.	88
6.16	Sumário da classificação usando LDA sobre descritores de DF Bouligand-Minkowski volumétrica multiespectral para diversos raios.	89
6.17	Sumário da classificação usando LDA sobre descritores de DF Bouligand-Minkowski volumétrica multiespectral.	89
6.18	Matriz de confusão, com respectivos erros de omissão e comissão, utilizando descritores de DF Bouligand-Minkowski multiespectral.	90
6.19	Sumário da classificação usando LDA sobre descritores de cor baseados na estrutura espacial.	91

6.20	Matriz de confusão, com respectivos erros de omissão e comissão, utilizando descritores de cor baseados na estrutura espacial.	91
6.21	Sumário da classificação usando LDA sobre descritores de cor baseados na estrutura espacial por análise de DF.	92
6.22	Matriz de confusão, com respectivos erros de omissão e comissão, utilizando descritores de cor baseados na estrutura espacial por análise de DF.	93
6.23	Comparação resultados diversas técnicas	94
6.24	Classes que apresentam maior e menor erro de omissão para cada método de análise de textura.	95
6.25	Resultados de classificação via PCA+LDA. Das 48 componentes principais utilizadas 45 são referentes ao método Gabor wavelets/cor e 3 do método DF volumétrica/cor.	96
6.26	Matriz de confusão, com respectivos erros de omissão e comissão, para classificação via PCA+LDA, utilizando as componentes principais dos métodos de Gabor wavelets/cor e DF volumétrica/cor.	98
6.27	Resultados utilizando comitê de máquinas com descritores de Gabor wavelets/cor e DF volumétrica/cor em cada componente.	99
6.28	Matriz de confusão, com respectivos erros de omissão e comissão, para classificação via comitê de máquinas, utilizando os descritores de Gabor wavelets/cor e DF volumétrica cor.	99
6.29	Resultados utilizando rede neural artificial com descritores de Gabor wavelets/cor e DF volumétrica/cor.	100
6.30	Matriz de confusão, com respectivos erros de omissão e comissão, para classificação via RNA, utilizando as componentes principais dos métodos de Gabor wavelets/cor e DF volumétrica/cor.	100
7.1	Valores críticos para o escore Z com n graus de liberdade $\times$ nível α de significância	105

Introdução

1.1 Justificativa e Motivação

A Taxonomia Vegetal é a ciência responsável pela síntese, organização, classificação e nomenclatura das espécies de plantas. Essencial ao conhecimento da biodiversidade e ao inventário da flora brasileira, fornece também subsídios para outras áreas da Botânica (fisiologia vegetal, citologia, paleobotânica, etc.) e áreas do conhecimento afins (ciências agrárias, ecologia, etc.), além de embasar programas de conservação. Neste contexto, os herbários vegetais são ferramentas imprescindíveis no trabalho dos taxonomistas na identificação de espécies arbóreas. Estes grandes bancos de dados naturais têm por objetivo concentrar todas as espécies coletadas na natureza, bem como suas características, em um único local, como forma de facilitar a análise e pesquisa. Contudo, apesar da existência dos herbários e da alta tecnologia hoje existente, todo o trabalho de identificação e caracterização continua sendo realizado manualmente [105]. Este processo taxonômico, tradicionalmente realizado sobre ramos férteis, flores e frutos, acarreta em aferições não tão precisas, pois podem conter erros causados pela manipulação humana, além de não contemplar todas as possíveis informações contidas nas amostras, como por exemplo características de textura foliar. Neste âmbito o uso de métodos de visão artificial e modelos matemáticos está permitindo o desenvolvimento de técnicas de aferição e extração de informações de forma automatizada da folha, contribuindo para uma análise mais criteriosa da morfologia, anatomia e até mesmo da fisiologia do vegetal. Em contrapartida, o estudo dos atributos visuais das folhas é um problema complexo e auxilia no aprimoramento dos métodos matemáticos utilizados nos problemas de visão computacional.

1.2 Objetivos

Visando contribuir com as técnicas de taxonomia já desenvolvidas, este estudo objetiva desenvolver e testar uma metodologia para identificação de espécies vegetais por meio da análise de textura foliar. Essa abordagem foi adotada em virtude de haver pouquíssimos trabalhos na literatura sobre classificação vegetal por folhas utilizando técnicas de visão computacional ([60, 81, 102, 108]) e, dentro desse reduzido conjunto, nenhum faz uso do atributo textura para identificação.

1.3 Organização

No Capítulo 2 (Análise de Vegetais e o Projeto TreeVis) é apresentada uma visão geral sobre o processo taxonomia vegetal, sua importância, principais conceitos e dificuldades que envolvem este processo. Também é realizada uma breve descrição do sistema TreeVis. Esse sistema visa o estudo e desenvolvimento de técnicas de visão computacional, empregadas na identificação de espécies vegetais.

No Capítulo 3 (Análise de Imagens) é realizada uma revisão bibliográfica do conjunto de técnicas de análise de imagem e extração de características utilizadas no projeto. Os principais tópicos abordados são referentes à segmentação de imagens e análise de textura.

O Capítulo 4 (Reconhecimento de Padrões) descreve os métodos de análise de dados multivariados e de classificação utilizados no projeto.

O Capítulo 5 (Sistema de Visão) apresenta as etapas envolvidas no sistema de análise e identificação de vegetais, bem como as técnicas e configurações adotadas em cada uma delas.

No Capítulo 6 (Experimentos e Resultados) são apresentados os diversos experimentos realizados visando a identificação das espécies. Neste capítulo é avaliado a qualidade dos métodos de extração de características empregados bem como os classificadores utilizados.

Por fim, no Capítulo 7 (Conclusões), são discutidas as conclusões obtidas através dos resultados experimentais, bem como novos trabalhos que poderão ser desenvolvidos dando continuidade a este projeto. Além disso, são relatadas as principais contribuições advindas com o desenvolvimento deste projeto.

Análise de Vegetais e o Projeto TreeVis

Na primeira seção deste capítulo é apresentada uma introdução sobre análise de vegetais, sua importância, principais conceitos e as dificuldades que envolvem este processo. Logo após, na segunda seção, é apresentado o projeto TreeVis abordando seus fundamentos, descrição do sistema e os resultados já alcançados. Esse sistema tem como objetivo o estudo e desenvolvimento de técnicas de visão computacional, empregadas na análise de vegetais. Sua proposta não é substituir a função dos profissionais, mas sim beneficiá-los pela complementação das metodologias já utilizadas, pela facilidade de acesso as informações e pela aceleração no processo de reconhecimento das espécies.

2.1 Análise de Vegetais

Segundo Sakane [88] um herbário é uma *coleção* de plantas mortas, secas e montadas de forma especial, destinadas a servir como documentação para vários fins. Os herbários abrigam uma grande quantidade de informação e dados sobre a diversidade vegetal. Pela comparação manual pura e simples com outros espécimes da coleção herborizada é possível realizar entre outras tarefas:

- Identificar material desconhecido;
- Realizar levantamento da flora de uma determinada área;

- Reconstituir o clima de uma região;
- Avaliar a ação devastadora do homem ou da ação deletéria da poluição;
- Reconstituir o caminho seguido por um botânico coletor;

A identificação vegetal é uma importante tarefa em vários campos de pesquisa como biodiversidade, ecologia, farmacologia entre outros. O processo tradicional desenvolvido por Linnaeus [3, 107] utiliza comparação de ramos férteis, flores e frutos dissecados, prensados e armazenados sobre papel cartão [53, 58]. Porém, esta abordagem traz alguns problemas quando da análise das flores e frutos, pois estes são encontrados apenas em algumas estações do ano e são diretamente dependentes à idade da planta e ao meio. Na maioria dos casos o material disponível para estudos é apenas a folha. Segundo [96] aproximadamente mais de 275.000 espécies de plantas que possuem folhas podem ser reconhecidas/distinguidas apenas por suas folhas.

O estudo das folhas para classificação vegetal implica na coleta de inúmeros atributos da estrutura foliar. O levantamento de atributos visuais em folhas não é um processo tão recente. Hickey [45] foi quem primeiro elaborou um método, em paleobotânica, com critérios para a extração dessas características, visando à classificação e à identificação das espécies vegetais, especificamente de vegetais angiospermas e dicotiledôneas. Atualmente, os atributos coletados estão em maior número do que o trabalho pioneiro de Hickey e podem ser divididos em atributos de geometria básica (área, perímetro, simetria), atributos de cor, forma, textura e complexidade, obtidos através da análise do contorno foliar e da análise da forma interna dos órgãos foliares.

Muito é possível conseguir-se pelo simples manusear de exsicatas¹ foliares de um herbário. Porém este é um processo difícil e complexo devido à natureza da planta. Embora a folha preserve sua característica fundamental, esta pode apresentar uma grande variação em seu padrão. Em uma mesma planta esta variação ocorre devido à maturidade de suas estruturas, a diferente exposição ao sol, impurezas, fungos e/ou doenças, ocasionando assim diferenças de tamanho, cor, textura, forma foliar entre outros. Folhas de uma mesma espécie, porém de diferentes plantas, podem apresentar, além dos fatores acima citados, variação em seu padrão devido ao meio (solo, iluminação), ao clima e ao ecossistema no qual as folhas desenvolveram-se.

Todas estas dificuldades presentes na taxonomia manual refletem-se nos métodos automatizados existentes para tal. Isso implica na existência de poucos trabalhos de classificação vegetal através de folhas na área de visão computacional ([60, 81, 102, 108]) e, dentro desse reduzido conjunto, nenhum deles utiliza o atributo textura para classificação, sendo que o mesmo pode contribuir significativamente para o sucesso no processo de identificação.

Em se tratando de textura as dificuldades encontradas na taxonomia manual também estão presentes no processo automatizado. Os principais problemas podem ser sumarizados da seguinte forma:

¹ exsicata: exemplar dissecado de uma planta qualquer, conservado nos herbários.

- Variância a cor: mesmo em uma análise intraclases há uma variância de coloração considerável entre diferentes amostras e até mesmo entre diferentes partes de uma mesma folha. Isso pode ser causado por diversos fatores, desde problemas na aquisição nas amostras (diferença entre scanners, iluminação não controlada, etc), até interferências naturais como a idade das folhas e/ou a exposição ao sol;
- Presença de ruídos: por se tratar de entidades biológicas, as folhas estão sujeitas a apresentarem vários tipos de ruídos naturais como impurezas, lesões causadas pela ação do tempo e/ou animais, fungos ou pestes. Além destes, sobreposições em partes adjacentes podem ocorrer durante a aquisição das imagens. Como resultado, temos a criação de dobras e/ou sombras que podem modificar a percepção de textura no ambiente bidimensional;
- Variância de tamanho: as folhas apresentam um tamanho natural variável, o que pode levar a uma modificação da textura apresentada. Este efeito também pode ocorrer à medida que a folha envelhece, dificultando assim o processo de classificação caso as folhas analisadas não advenham de uma mesma época;
- Variância de rotação: a influência do ambiente também pode trazer uma leve rotação no sentido da textura. Além disso, erros provenientes na aquisição podem inserir este tipo de dificuldade na análise;
- Simetria: devido à riqueza biológica existente, algumas espécies apresentam folhas não simétricas, esta característica pode influenciar a análise, uma vez que a textura pode se apresentar diferente em um dos lados.

Além destes entraves quando da análise individual da folha, temos que a similaridade entre classes é consideravelmente alta enquanto a similaridade intraclases não é adequada. Desta forma podemos apreciar o problema de classificação automática de folhas através de textura como uma difícil e complexa tarefa.

Com o intuito de solucionar as dificuldades expostas o Projeto TreeVis se propôs a desenvolver um método de classificação vegetal através da análise sistemática dos atributos foliares. Este trabalho, portanto, contribui sinergicamente com os demais módulos do projeto através da análise da textura da superfície foliar, extraindo características para posterior classificação. A seguir uma breve descrição do projeto TreeVis e seus módulos já existentes.

2.2 Projeto TreeVis

O TreeVis (*Tree Vision System*) vem sendo desenvolvido há sete anos e encontra-se na versão 1.0. Possui em sua base de dados 31 classes de vegetais devidamente catalogadas por gênero e espécie, consolidando uma base de dados composta por 600 amostras de folhas. Essas classes

pertencem a dois diferentes ecossistemas brasileiros, Mata Atlântica e Serrado, sendo que um considerável número de espécies é do mesmo gênero (*Passiflora*), dificultando assim o processo de classificação, uma vez que possuem características parecidas.

O TreeVis apresenta quatro pilares fundamentais [34], são eles (i) Exploração sistemática das características das folhas por meio de um vasto número de atributos, isto é, são utilizados 165 elementos de medidas para compor um vetor de características, sendo distribuídos nas seguintes categorias: geometria, cor, forma e textura/complexidade. (ii) Sinergismo obtido pela combinação dos atributos presentes no vetor de características, onde a associação das características pode trazer melhores resultados do que cada parte individualmente; (iii) Análise estatística, na qual se baseia a classificação e o reconhecimento. É neste fundamento onde se define a metodologia de comparação e identificação de espécies; (iv) Metodologia de utilização, onde o especialista do domínio terá a preocupação de aplicar seu conhecimento para garantir a consistência das informações que serão adquiridas pelo TreeVis.

Na Figura 2.1 pode-se observar seu ambiente de trabalho e algumas propriedades extraídas das amostras.

Figura 2.1: Ambiente de trabalho do projeto TreeVis [77].

Cinco módulos funcionais compõem o sistema, são eles: Estrutura de Amostragem, Controle Central, Extração de Características, Treinamento/Identificação e Base de Dados. A Figura 2.2 apresenta estes módulos e seu inter-relacionamento.

2.2.1 Textura no TreeVis

O ponto fundamental explorado pelo TreeVis (como ferramenta de visão computacional) é a obtenção de um vetor de características representativas (módulo 3 apresentado acima), isto é, que melhor diferencie os objetos a serem reconhecidos [34]. No sistema atual, uma folha para ser reconhecida necessita ser representada por um vetor de 165 elementos, dentre os quais

Figura 2.2: Diagrama de blocos apresentando os módulos que compõem o sistema TreeVis e suas respectivas conexões [34].

apenas 30 desses (18%) são referentes à textura da folha. Os métodos empregados na atual versão para descrição de características de textura, são a análise de histograma e descritores de Fourier. Esses métodos possuem uma taxa de 65% de acerto na classificação de espécies, considerados pouco efetivos se avaliarmos o grande número de espécies presentes na natureza e o erro de 35% obtido nessa classificação. Esse baixo percentual está relacionado ao fato de os métodos não terem sido sistematicamente testados, ou seja, seu emprego junto ao sistema, para composição do vetor de características, não seguiu uma metodologia criteriosa, sendo apenas empregados como técnicas iniciais de avaliação da viabilidade do estudo da textura para descrição/classificação das plantas. A literatura apresenta diversas técnicas possivelmente mais eficazes na tarefa de caracterização de textura. A proposta é estudar os métodos constituintes do estado da arte que melhor se adaptem ao problema apresentado de descrição e caracterização das folhas, trazendo assim melhores resultados para o módulo de textura/complexidade. Assim, sinergicamente com os aprimoramentos já realizados do TreeVis pelos trabalhos de Plotze [77], que utilizou a análise e identificação de espécies vegetais através das características internas de seus órgãos foliares (foco concentrado no conjunto de nervuras e esqueleto) e no trabalho de Falvo [34], que abordou o contorno foliar para identificação de espécies, espera-se conseguir um melhor percentual de acerto na classificação e ferramentas interessantes aplicáveis à biotecnologia e laboratórios morfofisiológicos.

Análise de Imagens

A análise e processamento de imagens (PI) é uma das principais tarefas envolvidas em um sistema de visão computacional. Desta maneira, este capítulo procura: (1) definir a área de PI, apresentando os conceitos básicos envolvidos e procurando dar uma visão geral da área, (2) apresentar conceitos básicos sobre segmentação de imagens e (3) descrever os alguns métodos computacionais de análise de textura utilizados durante o desenvolver desta pesquisa.

3.1 Introdução a Análise e Processamento de Imagens

Os objetivos do uso do processamento digital de imagens consistem na melhoria da informação visual para a interpretação humana e no fornecimento de subsídios para a sua interpretação, inclusive gerando produtos que possam ser posteriormente submetidos a outros processamentos [39]. A área de processamento digital de imagens tem atraído grande interesse nas últimas duas décadas. A evolução da tecnologia de computação digital, bem como o desenvolvimento de novos algoritmos para lidar com sinais bidimensionais está permitindo uma gama de aplicações cada vez maior. Como resultado dessa evolução, a tecnologia de processamento digital de imagens vem ampliando seus domínios, que incluem as mais diversas áreas, bem como, as mais variadas aplicações.

Uma imagem monocromática pode ser descrita por uma função $f(x, y)$ de intensidade luminosa, sendo seu valor f , em qualquer ponto de coordenadas espaciais (x, y) , proporcional ao brilho da imagem (ou níveis de cinza) naquele ponto. Já no caso de uma imagem que possui informações em intervalos ou bandas distintas de frequência, é necessária uma função $f(x, y)$

para cada banda [39]. É o caso de imagens coloridas padrão RGB¹, que são formadas pela informação de cores primárias, como o vermelho, verde e azul. Já uma imagem *binária* é representada por apenas dois valores inteiros: 0 ou 1, onde convencionalmente o valor 1 está associado ao objeto de interesse (foreground) e, o valor 0 corresponde ao fundo (background) da imagem.

Uma imagem digital é uma função $f(x, y)$ discretizada tanto em coordenadas espaciais quanto em brilho. Uma imagem digital pode ser considerada como sendo uma matriz cujos índices de linhas e de colunas identificam um ponto na imagem, e o correspondente valor do elemento da matriz identifica o nível de cinza naquele ponto. Os elementos dessa matriz digital são chamados de *pixels*². Quanto mais *pixels* uma imagem tiver melhor é a sua resolução e qualidade.

Os *pixels* de uma imagem $f(x, y)$, referenciados na forma $p(x, y)$, podem possuir até oito pixels adjacentes, esse conceito é conhecido como *vizinhança de um pixel*. Seja o pixel $p(x, y)$, seus quatro vizinhos horizontais e verticais são: $f(x+1, y)$, $f(x-1, y)$, $f(x, y+1)$ e $f(x, y-1)$ e seus quatro vizinhos diagonais são: $f(x+1, y+1)$, $f(x-1, y+1)$, $f(x-1, y-1)$ e $f(x+1, y-1)$. Duas definições de vizinhança são normalmente utilizadas [28]: *vizinhança de 4*, definida apenas pelos vizinhos horizontais e verticais e *vizinhança de 8*, definida pelos vizinhos horizontais, verticais e diagonais.

Outro conceito importante em processamento de imagens é a definição de distância de dois pixels. Diversas medidas de distância podem ser encontradas na literatura, contudo a métrica mais utilizada é a distância euclidiana. Dados os pixels p e q com coordenadas (x, y) e (s, t) respectivamente, a distância euclidiana entre eles é definida como:

$$De(p, q) = \sqrt{(x - s)^2 + (y - t)^2} \quad (3.1)$$

A seguir serão brevemente apresentados mais alguns conceitos importantes referentes às técnicas de processamento de imagens.

3.2 Segmentação de Imagens

O alvo da segmentação é obter, a partir de uma imagem digitalizada pré-processada, um conjunto de *primitivas* ou *segmentos significativos* que contém a informação semântica relativa à imagem de origem. Em geral, as primitivas usadas para segmentar um determinado objeto são as informações *naturais* do mesmo: contornos e regiões.

Usualmente a detecção de regiões numa imagem pode ser feita com um dos dois objetivos:

¹do inglês *Red, Green e Blue*

²do inglês *picture elements*

- extrair uma determinada região ou;
- dividir (particionar) a imagem num conjunto de regiões disjuntas cuja união representa a imagem inteira.

Considera-se uma região da imagem o conjunto de pontos *ligados* onde, de qualquer ponto da região pode-se chegar a qualquer outro ponto por um caminho inteiramente contido nessa região. Na literatura há diversos métodos para detecção de regiões em imagens. Um dos mais simples e utilizados é a limiarização ou binarização (threshold em inglês).

3.2.1 Limiarização

Tomando-se *a priori* o primeiro e segundo plano (objeto e fundo respectivamente) como as informações importantes da imagem $f(x, y)$. Uma forma de separar o primeiro plano do fundo é através da limiarização. O objetivo da binarização é marcar os pixels que pertencem às verdadeiras regiões de primeiro plano com um valor simples (1) e as regiões de fundo (segundo plano) com uma intensidade diferente (0). E assim gerar o que se chama de imagem binária (ou máscara) que é uma imagem preto-branca apresentando somente duas classes, o primeiro plano de cor preta sobre o fundo de cor branca ou o contrário.

A limiarização é baseada na utilização do histograma. No caso do primeiro plano ser bem diferenciado em relação ao fundo, o histograma apresenta distintamente duas classes na forma de dois picos separados por um *vale*. Limiarizar então consiste em escolher no histograma um valor T , tal que um pixel na imagem binária $g(x, y)$ é dada por:

$$g(x, y) = \begin{cases} 0 & \text{se } f(x, y) < T \\ 1 & \text{se } f(x, y) \geq T \end{cases} \quad (3.2)$$

Este processo é muitas vezes usado para dissociar o fundo dos objetos presentes na imagem. Há muitas técnicas na literatura para se escolher um bom valor de T . Uma abordagem bem conhecida, eficiente e não paramétrica é o método de Otsu [72]. Primeiro os cálculos são feitos da relação entre as classes de variância (interna e externa) para cada valor de limiar em potencial. As classes aqui são os pixels de primeiro e segundo planos, e o objetivo é encontrar o limiar que maximiza a variância das intensidades entre duas classes e as minimiza dentro de cada classes. Esta relação (razão) é calculada para todos os níveis de limiar em potencial. Nível este no qual a razão é máxima se é o limiar escolhido. Sendo a imagem uma função de intensidade $f(i)$ com N pixels com intensidade variando de 1 até L , Otsu define a variância entre classes como:

$$\sigma^2 = \omega_1(\mu_1 - \mu_T)^2 + \omega_2(\mu_2 - \mu_T)^2 \quad (3.3)$$

onde:

$$\omega_1 = \sum_{i=0}^T P(i) \quad (3.4)$$

$$\omega_2 = \sum_{i=T+1}^L P(i) \quad (3.5)$$

$$\mu_1 = \sum_{i=0}^T iP(i)/\omega_1 \quad (3.6)$$

$$\mu_2 = \sum_{i=T+1}^L iP(i)/\omega_2 \quad (3.7)$$

$$\mu_T = \omega_1\mu_1 + \omega_2\mu_2 \quad (3.8)$$

sendo $P(i)$ a probabilidade de um pixel ter intensidade i :

$$P(i) = \frac{n_i}{N} \quad (3.9)$$

O método de Otsu irá calcular a função acima para todo T . Assim o limiar T ótimo será aquele onde a função σ^2 é máxima.

3.2.2 Morfologia Matemática

Inicialmente elaborada por Georges Matheron e Jean Serra [93], a morfologia matemática, inicialmente definida para imagens binárias e logo estendida para imagens em níveis de cinza e cromáticas, contém ferramentas úteis para processamento de imagens baseadas em geometria e forma.

Baseada na teoria de conjuntos e em operações lógicas as operações morfológicas simplificam as imagens, mantendo as principais características dos seus objetos. Está fora do escopo deste trabalho apresentar base em teoria dos conjuntos e operações lógicas, estas ser encontradas em [39].

3.2.2.1 Operadores Morfológicos

De um modo geral, todos os operadores morfológicos baseiam-se no conceito da aplicação de um *elemento estruturante* percorrendo sobre uma imagem, de modo análogo ao que ocorre com as máscaras de convolução nas operações de filtragem. A partir do seu formato e tamanho, tem-se a possibilidade de testar e de quantificar de que maneira o elemento estruturante *está ou não está contido* na imagem.

As operações de dilatação e erosão podem ser consideradas como operadores básicos, sendo os demais (abertura e fechamento) operações elaboradas a partir destas.

Figura 3.1: Erosão, abertura, dilatação e fechamento. O elemento estruturante é o pequeno círculo presente em várias posições em (b) [39].

- Dilatação: é a aplicação de um elemento estruturante B de forma concêntrica sobre um conjunto definido de pontos A (brancos ou pretos) em uma imagem, de maneira que o elemento estruturante adicione informação sobre a vizinhança destes pontos. Ou seja,

pode-se imaginar que o elemento estruturante desliza sobre um conjunto de pontos dilatando sua vizinhança numa proporção que varia conforme as dimensões do elemento estruturante. Esta operação é utilizada principalmente para preencher intervalos e lacunas indesejáveis na imagem. A dilatação de um conjunto A pelo conjunto B é definida por:

$$A \otimes B = \{c \in Z^2 \mid c = a + b, \text{ para algum } a \in A, b \in B\} \quad (3.10)$$

onde Z^2 denota uma imagem binária. O resultado da operação de dilatação pode ser visto na Figura 3.1d.

- **Erosão:** é o inverso da dilatação. A aplicação do elemento estruturante ocorre analogamente à operação anterior, porém, ao invés de dilatar a vizinhança do ponto percorrido inserindo informação, o elemento retira informação (gerando erosão nas áreas percorridas). Esta operação é utilizada principalmente para eliminar detalhes irrelevantes, como ruídos, e abrir intervalos ou lacunas em regiões de conexão indesejadas. A dilatação de um conjunto A pelo conjunto B é definida por:

$$A \ominus B = \{c \in Z^2 \mid c + b \in A, \text{ para todo } b \in B\} \quad (3.11)$$

O resultado da operação de erosão pode ser visto na Figura 3.1b.

- **Abertura:** é derivada das operações de dilatação e erosão. O operador de abertura aplica uma erosão seguida de uma de dilatação na imagem. Esta seqüência de operações visa eliminar pequenos ruídos na imagem e abrir lacunas em regiões de fraca conexão entre objetos, através da erosão, e posteriormente tenta restaurar as dimensões reais de objetos da imagem através da dilatação. Os ruídos e fracas conexões eliminados com a erosão não retornam à imagem após a dilatação. A abertura de um conjunto A pelo conjunto B é definida por:

$$A \circ B = (A \ominus B) \otimes B \quad (3.12)$$

O resultado da operação de abertura pode ser visto na Figura 3.1c.

- **Fechamento:** também derivada das operações de dilatação e erosão, trata-se da operação inversa da abertura, aplicando primeiramente uma dilatação seguida de uma erosão. Esta seqüência de operações visa restaurar conexões fracas entre objetos da imagem.

$$A \bullet B = (A \otimes B) \ominus B \quad (3.13)$$

O resultado da operação de fechamento pode ser visto na Figura 3.1e.

Com estes operadores é possível construir um filtro morfológico para eliminação de ruídos em imagens segmentadas. Isto pode ser realizado usando-se o operador de abertura seguido do operador de fechamento com um elemento estruturante maior que qualquer ruído em A .

3.3 Análise Textura

Embora não haja uma definição precisa sobre textura, este atributo é facilmente percebido por humanos e é uma fonte rica de informações visuais - com respeito à natureza e tridimensionalidade dos objetos físicos. De modo geral, texturas são padrões visuais complexos compostos por entidades, ou subpadrões, que possuem brilho, cor, profundidade, tamanho, etc. Deste modo, a textura pode ser considerada um agrupamento de similaridades em uma imagem [85]. As propriedades locais dos subpadrões causam efeitos perceptivos como luminosidade, uniformidade, densidade, aspereza, regularidade, linearidade, frequência, fase, direcionalidade, randomicidade, suavidade, granulação, etc., da textura como um todo [61]. Uma grande coleção de exemplos de texturas pode ser vista em [16].

Computacionalmente, há quatro interesses principais em análise de textura [68]:

1. Extração de características: computar características de uma imagem digital capaz de descrever suas propriedades de textura numericamente;
2. Discriminação: particionar uma imagem texturizada em regiões, cada qual contendo uma percepção de textura homogênea;
3. Classificação: determinar a classe a que uma textura pertence dentre um número pré-definido de classes;
4. Reconstrução: reconstruir superfícies tridimensionais a partir de informações de textura;

A extração de características (1) é o primeiro estágio em análise de textura. Os resultados obtidos deste estágio são usados para discriminação (2), classificação (3) e/ou reconstrução (4) de texturas. Desta forma, o projeto concentra-se nos itens 1 e 3, uma vez que objetiva-se identificar espécies vegetais por meio da análise de textura foliar.

A seguir é apresentado uma revisão limitada sobre técnicas de extração de características, no capítulo seguinte abordam-se algumas técnicas de classificação.

As abordagens para análise de textura são usualmente categorizadas em quatro categorias [68], são elas:

- **Estrutural:** Abordagens estruturais [61] descrevem textura como primitivas bem definidas (microtextura) e/ou arranjos espaciais hierárquicos dessas primitivas (macrotextura). Esta abordagem provê uma boa descrição simbólica da imagem. Entretanto, essa característica é normalmente mais útil em tarefas de síntese do que em análise de textura. Os poucos descritores existentes não são muito funcionais em texturas naturais devido à grande variabilidade de micro e macro texturas existentes. Uma ferramenta poderosa em análise de textura estrutural é a morfologia matemática [93, 24]. A análise de microestruturas ósseas é um exemplo da aplicação da técnica [68].
- **Estatística:** em contraste com os métodos estruturais, a abordagem estatística não busca entender explicitamente a hierarquia estrutural da textura. Em vez disso, uma representação indireta da textura por propriedades não determinísticas que governam sua distribuição e relação entre tons de cinza da imagem é utilizada. Métodos baseados em estatística de segunda ordem podem alcançar uma alta taxa de discriminação se comparados com métodos espectrais e estruturais [109]. A discriminação de texturas por humanos utilizando-se de propriedades estatísticas é apresentada em [54]. De acordo com este estudo, texturas em tons de cinza são discriminadas espontaneamente apenas se seus momentos de segunda ordem forem diferentes nos padrões apresentados. Igualdade nos momentos de segunda ordem, mas diferentes momentos de terceira ordem requerem um esforço cognitivo mais alto para que haja a discriminação de padrões. Esta talvez seja uma indicação de que, em um processamento automatizado, estatísticas de até segunda ordem sejam mais relevantes [71]. Neste contexto, as matrizes de co-ocorrência [43] é a técnica mais popular para análise de textura. Seu emprego obteve sucesso em várias aplicações. Uma abordagem multidimensional da técnica também vem obtendo bons resultados em classificação de texturas [103].
- **Espectral:** técnicas como Fourier [85], Gabor [31, 13] e transformadas Wavelet [65, 62] representam a imagem em um espaço cujo sistema de coordenadas tem uma interpretação relacionada às características de uma textura (como frequência ou tamanho). Métodos baseados na transformada de Fourier mostram-se pobres na prática, isto devido à falta de localização espacial. Filtros de Gabor solucionam este problema, porém sua utilidade é limitada na prática porque não existem filtros de resolução simples que possa localizar uma estrutura espacial em texturas naturais. Comparadas com Gabor, a transformada Wavelet possui algumas vantagens: variando-se a resolução espacial, permite-se representar texturas em uma escala mais adequada. Existe uma ampla faixa de escolhas para a função Wavelet a ser empregada, tornando essa abordagem adequada para a análise de textura em uma aplicação específica.
- **Baseadas em modelo:** a análise de textura usando modelos fractais [76] e estocásticos [29, 23], procura interpretar uma textura pela criação de modelos. Os parâmetros obtidos na estimação do modelo podem então ser utilizados em análise de imagens. Modelos fractais

podem ser aplicados em análise e discriminação de textura [76, 22], porém a falta de orientação seletiva pode ser um empecilho à sua utilização em determinadas aplicações.

3.3.1 Técnicas para Extração de Características

Dentre as abordagens anteriormente apresentadas algumas das técnicas empregadas nesta pesquisa estão brevemente descritas a seguir.

3.3.1.1 Características de Primeira Ordem

Sendo a imagem uma função $f(x, y)$, com $x = 0, 1, \dots, N - 1$ e $y = 0, 1, \dots, M - 1$ e possuindo valores discretos $i = 0, 1, \dots, G - 1$, onde G é o número de intensidades possíveis da imagem. O histograma é uma função mostrando o número de pixels da imagem que possuem uma determinada intensidade, dada por:

$$h(i) = \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} \delta(f(x, y), i) \quad (3.14)$$

onde $\delta(j, i)$ é a função de Kronecker

$$\delta(j, i) = \begin{cases} 1, & j = i \\ 0, & j \neq i \end{cases} \quad (3.15)$$

O histograma é obviamente uma simples e concisa fonte de informação estatística presente na imagem. O cálculo do histograma dá-se sobre cada pixel isoladamente, contendo, deste modo, informações estatísticas de primeira ordem. Dividindo os valores $h(i)$ pelo número total de pixels da imagem, obtêm-se uma função de densidade probabilidade, dada por:

$$p(i) = \frac{h(i)}{NM} \quad i = 0, 1, \dots, G - 1 \quad (3.16)$$

Dada uma imagem, o histograma pode ser facilmente calculado, e sua disposição pode indicar características da imagem. Desta forma, propriedades estatísticas de primeira ordem podem ser utilizadas para descrever tais características. Tais propriedades (também chamadas de momentos centrais) são definidas pelas equações abaixo:

Média:

$$\mu = \sum_{i=0}^{G-1} ip(i) \quad (3.17)$$

Variância:

$$\sigma^2 = \sum_{i=0}^{G-1} (i - \mu)^2 p(i) \quad (3.18)$$

Kurtose:

$$\mu_4 = \sigma^{-4} \sum_{i=0}^{G-1} (i - \mu)^4 p(i) - 3 \quad (3.19)$$

Duas outras propriedades também são amplamente utilizadas:

Energia:

$$E = \sum_{i=0}^{G-1} [P(i)^2] \quad (3.20)$$

Entropia:

$$H = - \sum_{i=0}^{G-1} p(i) \log_2[p(i)] \quad (3.21)$$

Outras possíveis características derivadas do histograma são: mínimo, máximo, intervalo e mediana.

É importante notar que os itens média e variância podem não denotar informações relevantes sobre textura. Isto ocorre quando o processo de aquisição não é controlado (iluminação, sombras, etc.). Nestes casos a normalização destes parâmetros pode ser útil no processo de extração de características. Para tal, utiliza-se frequentemente, $\mu = 0$ e $\sigma = 1$, dados pela equação:

$$f'(x, y) = \frac{f(x, y) - \mu}{\sigma} \quad (3.22)$$

3.3.1.2 Matrizes de Coocorrência

A maior vantagem em se usar atributos de primeira ordem é obviamente sua simplicidade. Entretanto, estes não podem caracterizar completamente uma textura. Julesz mostrou, em seu famoso trabalho de percepção visual de texturas por humanos [54], que texturas em tons de cinza são discriminadas espontaneamente apenas se seus momentos de segunda ordem forem diferentes nos padrões apresentados. Mesmo se forem achados contra-exemplos desta conjectura, a importância das estatísticas de segunda-ordem é certa. Assim sendo, o principal método estatístico utilizado em análise de texturas é baseado na definição de distribuições de probabilidades conjuntas entre pares de pixels.

O histograma de segunda ordem é definido como a matriz de coocorrência $h_{d\theta}(i, j)$ [43]. Quando dividida pelo número total de pixels vizinhos $R(d, \theta)$ na imagem, esta matriz torna-se a estimação da probabilidade conjunta, $p_{d\theta}(i, j)$ de dois pixels, a uma distância d em uma dada direção θ , possuir um particular valor i e j (coocorrência).

Existem duas versões das matrizes de coocorrência, uma simétrica onde pares separados por d e $-d$ em uma dada direção θ são contados, e outra não simétrica onde apenas pares separados pela distância d são contados. Formalmente, dada uma imagem $f(x, y)$ com um conjunto G de intensidade, a matriz $h_{d\theta}(i, j)$ está definida tal que sua (i, j) entrada é igual a:

$$f(x_1, y_1) = i \quad \text{and} \quad f(x_2, y_2) = j$$

onde

$$(x_2, y_2) = (x_1, y_1) + (d \cos \theta, d \sin \theta)$$

Esta formulação denota a criação, para cada distância d e direção θ , de uma matriz quadrada de dimensão igual ao número de níveis de cinza presentes na imagem. Devido à natureza do alto custo computacional envolvido, freqüentemente apenas poucos ângulos θ e distâncias d são utilizados, como sugere [43]. Ainda conforme Haralick [43], a classificação de texturas *finas* requerem pequenos valores de d , enquanto texturas mais *grossas* requerem altos valores. É possível realizar uma redução nos níveis de cinza presentes na imagem como forma de diminuir o custo computacional, porém, haverá perda de informação.

As matrizes geradas contem G^2 elementos, ou seja, muitos dados para análise em um tempo razoável. Um reduzido número de características apresentadas em [43] podem ser calculadas usando as matrizes de coocorrência. Algumas das equações são apresentadas a seguir:

Segundo momento angular (Energia):

$$E = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} [p(i, j)]^2 \quad (3.23)$$

Correlação:

$$C = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{ijp(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3.24)$$

Contraste:

$$\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i - j)^2 p(i, j) \quad (3.25)$$

Valor absoluto:

$$\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} |i - j| p(i, j) \quad (3.26)$$

Diferença inversa:

$$\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{p(i, j)}{1 + (i - j)^2} \quad (3.27)$$

Entropia:

$$H = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p(i, j) \log_2[p(i, j)] \quad (3.28)$$

Probabilidade máxima:

$$M = \max_{i,j} p(i, j) \quad (3.29)$$

onde μ_x, μ_y e σ_x, σ_y denotam a média e desvio padrão da soma das linhas e colunas respectivamente. Um conjunto mais amplo de características derivadas das matrizes de co-ocorrência podem ser encontrado em [83].

3.3.1.3 Descritores de Fourier

Fourier formulou no início do século XVIII a teoria de que qualquer função que se repita periodicamente³ pode ser representada como uma soma de senos e/ou cossenos de frequências diferentes, cada um multiplicado por um coeficiente próprio (séries de Fourier)(ver Figura 3.2). A idéia foi recebida com ceticismo pelo meio científico da época, porém hoje a transformada de Fourier, em especial a transformada discreta de Fourier bi-dimensional, é uma ferramenta matemática de grande aplicabilidade na solução dos problemas de processamento digital de imagens (sinais bi-dimensionais) pois, muitas vezes, é conveniente a mudança do domínio do tempo ou espaço (x, y) para o domínio da frequência facilitando, assim, o seu processamento [39].

A transformada de Fourier, $F(u)$, de uma função contínua de uma variável $f(x)$ é:

$$F(u) = \int_{-\infty}^{\infty} f(x) e^{-2j\pi ux} dx \quad (3.30)$$

³mesmo funções não periódicas podem ser representadas por integrais de senos e/ou cossenos, desde que a área sob a curva da função seja finita.

Figura 3.2: A função e constitui-se pela soma das quatro funções $e = a + b + c + d$. Fourier formulou no início do século XVIII a teoria de que qualquer função que se repita periodicamente pode ser representada como uma soma de senos e/ou cossenos de frequências diferentes [39].

dada $F(x)$, a transformada inversa para $f(x)$ pode se obtida usando-se

$$f(x) = \int_{-\infty}^{\infty} F(u) e^{-2j\pi ux} du \quad (3.31)$$

Juntas, essas funções formam o par transformadas de Fourier, que em 2D são:

$$F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-j\pi(ux+vy)} dx dy \quad (3.32)$$

e

$$f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u, v) e^{-j\pi(ux+vy)} du dv \quad (3.33)$$

Para funções discretas, podemos utilizar as DFTs⁴, que são

$$F(u) = \frac{1}{M} \sum_{x=0}^{M-1} f(x) e^{-j2\pi ux/M} \quad (3.34)$$

para $u = 0, 1, \dots, M-1$ e

$$f(x) = \frac{1}{M} \sum_{u=0}^{M-1} F(u) e^{-j2\pi ux/M} \quad (3.35)$$

para $x = 0, 1, \dots, M-1$. Ao contrário do caso contínuo, as transformadas direta e inversa de Fourier sempre existem, desde que $f(x)$ não possua valores infinitos.

O domínio (valores de u) de $F(u)$ é chamado de domínio da frequência, porque u determina a frequência dos componentes da transformada. Assim, cada um dos termos de $F(u)$ é chamado de componente de frequência da transformada.

No caso bidimensional as DFTs são:

$$F(u, v) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-j2\pi(ux/M + vy/N)} \quad (3.36)$$

para $u = 0, 1, \dots, M-1$ e $v = 0, 1, \dots, N-1$ onde sua transformada inversa dá por:

$$f(x, y) = \frac{1}{MN} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u, v) e^{j2\pi(ux/M + vy/N)} \quad (3.37)$$

para $x = 0, 1, \dots, M-1$ e $y = 0, 1, \dots, N-1$. Deste modo, o espectro de Fourier, o ângulo de fase e o espectro de potência são, respectivamente:

$$|F(u, v)| = \sqrt{R^2(u, v) + I^2(u, v)} \quad (3.38)$$

$$\phi(u, v) = \tan^{-1} \left[\frac{I(u, v)}{R(u, v)} \right] \quad (3.39)$$

⁴do inglês *discrete Fourier transform*

$$P(u, v) = |F(u, v)|^2 = R^2(u, v) + I^2(u, v) \quad (3.40)$$

Temos que cada termo de $F(u, v)$ contém todos os valores de $f(x, y)$, modificados pelos valores exponenciais, logo não é possível fazer associações um a um dos coeficientes com *pixels*. Entretanto pode-se falar em termos de características da imagem. Por exemplo, o coeficiente de $F(0, 0)$ ⁵ denota a intensidade média da imagem, coeficientes de baixos índices (frequências) correspondem a componentes da imagem que varia pouco, enquanto que coeficientes de alta frequência são associados com variações bruscas de intensidade.

Na caracterização de textura temos que, eliminando-se os elementos periódicos do espectro ($F(0, 0)$), obtém-se o elemento básico da textura onde: os picos predominantes no espectro indicam a principal direção da textura e a posição dos picos em relação ao centro indicam sua frequência. Computacionalmente essa caracterização por análise do espectro é frequentemente efetuada por meio de componentes radiais ou angulares do espectro de potência (i.e., analisando a soma das componentes do espectro ao longo de determinado raio ou de determinada direção).

Expressando-se o espectro em coordenadas polares, levando a uma função $S(r, \theta)$, sendo que S é uma função do espectro e r e θ são variáveis nesse sistema de coordenadas. Para cada direção θ temos $S_\theta(r)$, assim como para cada r temos $S_r(\theta)$. A análise de $S_\theta(r)$ para um valor fixo de θ fornece o comportamento do espectro ao longo de uma direção radial a partir da origem, enquanto a análise de $S_r(\theta)$ para um valor fixo de r leva ao comportamento ao longo de uma circunferência centrada na origem [39].

Uma descrição global é obtida através das funções:

$$S(r) = \sum_{\theta=0}^{\pi} S_\theta(r) \quad (3.41)$$

$$S(\theta) = \sum_{r=1}^R S_r(\theta) \quad (3.42)$$

em que R é o raio de uma circunferência centrada na origem. Para um espectro de $N \times N$, R é tipicamente escolhido como $N/2$.

Os resultados das equações 3.41 e 3.42 constituem um par de valores $[S(r), S(\theta)]$ para cada par de coordenadas (r, θ) . Variando-se essas coordenadas, pode-se gerar funções unidimensio-

⁵na prática, quando queremos trabalhar uma imagem no domínio da frequência, é comum realizar o *shift* (i.e., mover a origem da transformada de Fourier para as coordenadas de frequência $(M/2, N/2)$), ou seja, o centro do retângulo de frequência.

nais $S(r)$ e $S(\theta)$ que constituem descrições de energia espectral da textura para uma imagem ou região em questão [39].

Uma característica da *energia espectral* é que sua distribuição acumulada ao longo da variação da frequência, possui maior variação na faixa das baixas frequências e se estabiliza ao atingir frequências mais altas, sinalizando uma variação de energia mínima.

3.3.1.4 Gabor Wavelets

Para o cálculo de características multiescala, vários métodos são adotados. Os mais comumente usados são os filtros de Gabor e transformadas wavelets. Embora criticados pela sua não ortogonalidade, que resulta em características redundantes em diferentes escalas ou canais [98], os filtros de Gabor são utilizados tanto na extração de características quanto na segmentação de imagens [26, 50]. De outro lado, a transformada wavelet, diferentemente da transformada de Fourier, possui capacidades de localização temporal sobre as características do sinal. Por esta razão, há um interesse recente em aplicações utilizando transformadas wavelet em análise de textura. Desse modo aplicações que fazem uso das transformadas wavelets em conjunto com filtros de Gabor (Gabor wavelets) vêm se tornando freqüentes na literatura.

O filtro de Gabor 2D é um método de processamento de sinais criado por Denis Gabor em 1946 [36]. Ele tem sido utilizado em análise de textura por várias razões, dentre elas: representação de frequência e orientação similares ao sistema visual humano, propriedades de localização espacial, orientação seletiva e seletividade espaço-frequência [59]. Filtros de Gabor são, essencialmente, funções complexas seno e cosseno moduladas por uma função gaussiana [48]. Devido à sua característica de representação de frequência e orientação, que são similares aos campos receptivos do córtex visual pré-estriado presente no sistema visual humano [30], eles têm sido aplicados com sucesso na segmentação de imagens [50], reconhecimento de faces [95], melhoria e identificação de impressões digitais [59], etc.

Um filtro de Gabor 2-D é, basicamente, uma função gaussiana bidimensional modulada com uma senóide orientada com uma determinada frequência W e em uma determinada direção θ . Sua forma bi-dimensional no domínio do espaço e da frequência é dada pelas equações 3.43 e 3.44, respectivamente.

$$g(x, y) = \left(\frac{1}{2\pi\sigma_x\sigma_y} \right) e^{-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right) + 2\pi j W x} \quad (3.43)$$

$$G(u, v) = e^{-\frac{1}{2}\left[\frac{(u-W)^2}{\sigma_u^2} + \frac{v^2}{\sigma_v^2}\right]} \quad (3.44)$$

onde $\sigma_u = 1/2\pi\sigma_x$, $\sigma_v = 1/2\pi\sigma_y$ e W é empiricamente determinado com valores entre $[0.01 - 0.4]$. A Figura 3.3 mostra um exemplo de um filtro de Gabor no domínio do espaço e da frequência respectivamente.

Figura 3.3: (a) parte real de um filtro de Gabor no domínio do espaço e (b) parte real de um filtro de Gabor no domínio de Fourier.

As funções de Gabor formam um conjunto de filtros completo, porém não ortogonal. Expandindo-se o sinal a partir de um filtro base pode-se criar um conjunto ortogonal que provê uma descrição localizada das frequências. A esse conjunto de filtros de Gabor similares entre si dá-se o nome de *Gabor wavelets*. Sendo $g(x, y)$ a Gabor Wavelet mãe, então o conjunto de filtros pode ser obtido por apropriadas dilatações e rotações em $g(x, y)$ usando-se a função 3.45 [66].

$$g_{mn} = a^{-m} G(x', y') \quad (3.45)$$

para

$$a > 1, m, n \in I \quad (3.46)$$

$$x' = a^{-m}(x \cos \theta + y \sin \theta) \quad (3.47)$$

e

$$y' = a^{-m}(-x \sin \theta + y \cos \theta) \quad (3.48)$$

onde $\theta = n\pi/K$ é o número total de orientações. O fator de escala a^{-m} nas formulações acima é necessário para garantir que a energia seja independente de m [66].

Os parâmetros de um filtro de Gabor são, a frequência W , o parâmetro de orientação θ e as escalas σ_x e σ_y da função gaussiana. As diferentes orientações θ e frequências W são, dessa forma, parâmetros chaves em uma aplicação de processamento de texturas. Basicamente, o procedimento consiste na convolução de uma imagem de entrada por uma família de filtros

de Gabor que apresentam em sua composição várias escalas e orientações de uma determinada configuração original (Gabor wavelets), sendo que há inúmeras formas para escolha de tal configuração.

Determinando os parâmetros dos filtros A literatura apresenta diversos trabalhos utilizando a aplicação de filtros de Gabor em imagens como forma de discriminar texturas, sendo que estes apresentam diferentes justificativas para a escolha dos parâmetros de frequência (W), orientação (θ) e sigmas (σ_x, σ_y). No trabalho [50], por exemplo, os autores utilizam apenas quatro orientações ($0^\circ, 45^\circ, 90^\circ$ e 135°), com o intuito de diminuir o custo computacional, e utilizam uma regra de escolha de frequências baseada em estudos psicofísicos. Já no trabalho [84], os autores fazem uso de um conjunto de frequências, orientações e escalas determinadas de forma empírica. No presente trabalho, entretanto, optou-se por fazer a escolha de parâmetros com base em um modelo matemático presente no trabalho [66], criando um conjunto de filtros que busca a cobertura máxima do espectro de Fourier com a menor redundância possível de informação. Esta característica pode ser vista na representação visual da Figura 3.4. Desse modo, a equação 3.49 descreve como obter os sigmas ideais (σ_u, σ_v) e por conseguinte (σ_x, σ_y).

$$\sigma_v = \frac{\tan\left(\frac{\pi}{2K}\right) \left[U_h - 2 \ln 2 \left(\frac{\sigma_u^2}{U_h} \right) \right]}{\sqrt{2 \ln 2 - \frac{(2 \ln 2)^2 \sigma_u^2}{U_h^2}}} \quad (3.49)$$

sendo

$$\sigma_u = \frac{(a - 1)\mu_0}{(a + 1)\sqrt{2 \ln 2}} \quad (3.50)$$

$$a = (U_h/U_l)^{\frac{1}{S-1}} \quad (3.51)$$

e

$$\mu_0 = \frac{U_h}{a^{S-s_i}} \quad (3.52)$$

onde $W = \mu_0$, K é a quantidade de rotações, S é a quantidade de escalas, $s_i = 1, 2, \dots, S$ e U_h e U_l representam a frequência mínima e máxima, respectivamente.

3.3.1.5 Fractais

Desde longa data temos caracterizado elementos geométricos como o ponto, as curvas e as superfícies em termos de suas dimensões topológicas. Com base neste conceito dizemos

Figura 3.4: Conjunto de filtros de Gabor wavelets no domínio da frequência gerados pela metodologia de Manjunath and Ma [66]. Os parâmetros utilizados foram $U_h = 0.3$, $U_l = 0.05$, $K = 6$ and $S = 4$.

que ponto tem dimensão zero, a reta tem dimensão um o plano tem dimensão dois e o espaço usual tem dimensão três. No entanto, seria de certa forma *injusto* atribuir a uma curva tão elaborada como a de Koch [28] dimensão unitária, como a de uma reta comum. Para resolver este problema, na década de 70, Beneto Mandelbrot apresentou ao mundo um novo campo da matemática, chamado de Geometria Fractal. Seu trabalho mostrou que um determinado objeto pode assumir valores fracionários em vez de apenas números inteiros, excedendo assim sua dimensão topológica [70]. Uma interpretação conceitual poderosa é que a dimensão fractal pode ser uma medida de 'complexidade' do objeto [18]. Na prática, podemos caracterizar a dimensão fractal como uma medida da superfície efetiva de contato entre o objeto e seu meio [4]. Portanto, quanto maior a superfície, maior será sua dimensão fractal.

A Geometria Fractal pode ser utilizada para representar estruturas geométricas de grande complexidade, inclusive fenômenos na natureza onde não podem ser utilizadas as geometrias tradicionais. Embora as abordagens estatísticas [25], espectrais [50] e estruturais [106] apresentem bons resultados em análise de textura, estes métodos falham quando da distinção de muitos padrões *naturais* que apresentam uma estrutura não periódica [55]. Isso se deve ao fato de que texturas *naturais* exibem padrões randômicos, porém persistentes. Exemplos desse tipo de textura são amplamente encontrados na natureza (e.g. nuvens, fumaça, modelos de terrenos, líquidos, superfícies foliares).

A teoria dos fractais oferece uma alternativa a essas abordagens. Texturas naturais possuem uma dimensão topológica não inteira e, em muitos casos, também apresentam uma estrutura não periódica. Desta forma, torna-se interessante fazer uso fractais na caracterização desse tipo

de estrutura. O problema de classificação fica então reduzido a estimar a dimensão fractal do objeto, uma vez que essa característica é inerente a região/superfície do mesmo [82].

As folhas e suas estruturas, apesar de não serem fractais perfeitos (sua dimensão fractal tende para zero à medida que observamos em escalas cada vez maiores), são um desses fenômenos que podem ser caracterizados e descritos usando-se complexidade fractal. O projeto TreeVis já conta com essa teoria aplicada à análise de vegetais [81, 78, 79, 80, 77]. Porém, estes trabalhos fazem uso da forma interna e externa de órgãos foliares e não da textura.

Vários métodos vem sendo desenvolvidos para estimar a dimensão fractal (DF) em análise de imagens. Pentland [76], por exemplo, faz uso do espectro de potência da transformada de Fourier modelados como movimentos brownianos. Peleg et al. [75] adaptou a idéia de Mandelbrot (método ϵ -blanket) usando-o para análise de superfícies. O método box-counting, desenvolvido por Gangepain and Roques-Carmes [37], e sua versão melhorada chamada de diferencial box-counting (DBC) Sarkar and Chaudhuri [90, 89], Chaudhuri and Sarkar [22], vem sendo usado em várias aplicações de classificação, comparação de texturas e caracterização de objetos. Mais recentemente [104] e [101] utilizaram a teoria de multifractais aplicados a classificação de texturas e segmentação de imagem, enquanto [4] faz uso do método de Bouligand Minkowski para estimar a DF de imagens.

Embora haja um amplo conjunto de técnicas e abordagens para estimação da dimensão fractal de texturas, a maioria é baseada nas teorias tradicionais como *Box-counting* e *Bouligand-Minkowski*, brevemente descritos abaixo.

Box-counting O princípio básico para estimar a dimensão fractal de um objeto está do conceito de auto-similaridade. Infelizmente diferentes métodos atribuem diferentes valores de DF , especialmente quando da caracterização de texturas. Uma técnica muito conhecida e utilizada é o Box-counting Gangepain and Roques-Carmes [37]. Esta é técnica é baseada na divisão da imagem em caixas quadradas de tamanho ϵ e, na contagem do número dessas caixas $N(\epsilon)$ que contenham pelo menos uma porção do objeto em análise. Quando o tamanho das caixas é alterado, quantidades distintas de caixas podem ser computadas, a Figura 3.5 ilustra este processo. A dimensão fractal pelo método *Box-counting* é baseada na relação entre o tamanho das caixas e o número de caixas necessárias para *cobrir* o objeto efetivamente, sendo definida pela equação abaixo.

$$\dim_{box} = -\lim_{\epsilon \rightarrow 0} \frac{\log N(\epsilon)}{\log(\epsilon)} \quad (3.53)$$

O cálculo de $N(\epsilon)$ para diversos valores de ϵ produz o gráfico de uma reta. O valor absoluto da inclinação desta reta nos dá uma estimativa da dimensão fractal do respectivo objeto. Várias adaptações para análise de textura foram realizadas sobre este método, incluindo uma versão 3D [5, 56] e uma adaptação utilizando multifractais [22].

Figura 3.5: Divisão de uma imagem pelo método Box-counting. As caixas em tom cinza são as que possuem uma porção do contorno em análise. Adaptado de [4].

Bouligand-Minkowski Um dos métodos mais preciso para estimar a dimensão fractal é o de Bouligand-Minkowski [100]. Ele é baseado no estudo da área de influência, $A(r)$, criada pela dilatação de um objeto A por um disco de raio r . Esta área de influência $A(r)$ é altamente sensível a mudanças estruturais do objeto, assim, qualquer pequena alteração no mesmo pode ser percebida. Semelhantemente ao *Box-counting*, a estimativa da dimensão fractal então é dada pelo coeficiente angular do gráfico $\log A(r) \times \log(r)$ da área de influência versus o raio r para diversos valores de r , como definido pela equação abaixo:

$$\dim_{blm} = 2 - \lim_{\epsilon \rightarrow 0} \frac{\log A(r)}{\log(r)} \quad (3.54)$$

Os métodos que utilizam o coeficiente angular como estimativa da dimensão fractal (Bouligand-Minkowski e Box-counting por exemplo) não são, originalmente, multiescala. Uma adaptação que utiliza a primeira derivada de $\log A(r)$ como forma de prover informações adicionais sobre características do objeto tornam esses métodos ainda mais poderosos [67]. Dessa forma, para análise multiescala da dimensão fractal é necessário que seja obtido um gráfico $\log A'(r) \times \log(r)$, no qual A' é o resultado da derivada numérica do ponto $(r, A(r))$ do gráfico $\log A(r) \times \log(r)$. Deste novo gráfico, ilustrado na Figura 3.6, informações como *pico de fractalidade*, *escala de máxima fractalidade* e *largura de alta fractalidade* são utilizados como forma de caracterizar os objetos. Apesar de a técnica original funcionar sobre imagens binárias, artigos reportam alterações no método que o fazem capaz de caracterizar texturas em imagens tons de cinza [33].

Bouligand-Minkowski Volumétrica Para estimar a dimensão fractal de Bouligand-Minkowski em uma imagem não binária (tons de cinza) propõe-se ([7]) considerar a imagem em um espaço 3-dimensional $S(x, y, z)$ (volumétrico), com (x, y) denotando a posição 2D e a terceira

Figura 3.6: A direita gráfico log-log gerado pelo método de Minkowski. A esquerda gráfico da dimensão MultiEscala. Adaptado de [81].

coordenada (z) denotando a intensidade do pixel [7]. A superfície $S \in R^3$ formada por esta modelagem é mostrada na Figura 3.7.

Figura 3.7: Superfície gerada pela modelagem volumétrica de uma imagem em tons de cinza [7].

Estima-se a DF de S pelo gráfico $\log V(r)$ vs. $\log(r)$ formado pela dilatação da superfície S por um raio r contínuo. Uma vez que a imagem é discreta e não contínua, calcula-se $V(r)$ para diversos valores de r :

$$FD = 3 - \lim_{r \rightarrow 0} \frac{\log V(r)}{\log(r)} \quad (3.55)$$

com

$$V(r) = \{p \in R^3 | \exists p' \in S : |p - p'| \leq r\} \quad (3.56)$$

onde $V(r)$ é o volume de influência obtido pela dilatação de cada ponto de S , usando uma esfera de raio r .

De um ponto de vista matemático, uma característica importante da dimensão fractal é o pequeno número de parâmetros a serem configurados quanto a aplicação da técnica. Especificamente no método de Bouligand-Minkowski apenas o valor de r é necessário.

Bouligand-Minkowski Volumétrica Multiespectral Embora haja muitos métodos para estimar a dimensão fractal de uma imagem, todos trabalham apenas com imagens em tons de cinza. É sabido que a informação de cor pode ser muito útil em análise de imagens [94, 2], em especial quando se trata de imagens que apresentam texturas naturais (superfícies foliares, modelos de terrenos, etc.). Desta forma, um método para estimar a DF de imagens multiespectrais (coloridas) torna-se muito interessante.

Na literatura apenas o trabalho de She and Huang [94] adaptou um método de dimensão fractal para análise e classificação de texturas coloridas (multiespectrais). Porém com foco na análise local, para fins de segmentação.

Com o intuito de tornar a informação de cor útil Casanova et al. [21] propuseram estimar a dimensão fractal baseada na interação entre os canais de cor. Seja (R, G, B) denotando os componentes de cor da imagem I . Considerando cada banda de cor como uma superfície no espaço 3-dimensional $S(x, y, z)$ onde, x e y são as coordenadas da imagem e z a intensidade da cor em determinada banda. Define-se por espaço intercores a interação das superfícies geradas pelos componentes R , G e B da imagem original. Na Figura 3.8 é apresentado uma superfície simples (b) (gerada a partir de uma imagem em tons de cinza) e o espaço intercores (c) (gerado pelos componentes (R, G, B)).

Figura 3.8: Diferença entre as superfícies geradas da imagem original (a) em escala de cinza (b) e com seus componentes RGB (c).

Embora equação utilizada para estimar a DF seja a mesma utilizada para imagens em tons de cinza (3.55), a diferença dos resultados é conseguida pela interação das três superfícies presentes no modelo S multiespectral [21]. No cálculo de $V(r)$ para vários valores de r estamos automaticamente calculando a interação entre as bandas de cores. Se as bandas apresentarem mesma intensidade teremos uma forte interação, o caso inverso (fraca interação) ocorre quando há discrepância entre as intensidades. As Figuras 3.9 e 3.10 exemplificam esse processo pela dilatação de superfícies multiespectrais para diferentes valores de r .

Figura 3.9: Processo de dilatação de um modelo S para vários valores de r , apresentando fraca interação entre as bandas de cores.

Figura 3.10: Processo de dilatação de um modelo S para vários valores de r , apresentando forte interação entre as bandas de cores.

Este método implica na estimação da dimensão fractal baseada no conceito de auto-similaridade (inerente aos fractais) e auto-afinidade (inerente ao inter-relacionamento entre as cores). O método apresenta grande vantagem sobre a análise da DF em tons de cinza. Isso pode ser exemplificado pela Figura 3.11 que mostra a DF estimada para uma superfície simples (c) (derivada da imagem original (a) pré-processada para tons de cinza⁶ (b)) e para uma superfície multiespectral (e) (gerada pela mesma imagem original (d)).

Observa-se o potencial do método uma vez que diferentes imagens podem ser separadas com o uso da informação de cor. Em adição, devido ao método trabalhar implicitamente com a interação dos canais de cores, este resolve três problemas comuns na análise de imagens coloridas que são [94]:

⁶o método utilizado para transformação da imagem em tons de cinza foi a média dos canais (R, G, B).

Figura 3.11: Comparação entre as DF estimadas pelo modelo multiespectral e pelo modelo em escalas de cinza)

- Problemas de iluminação - variações na distribuição geométrica do objeto pode afetar significativamente sua aparência (e.g. sombras, regiões escuras).
- Variação na intensidade e contraste da imagem - muitos métodos em análise não são robustos, pois utilizam parâmetros (e.g. thresholds) que dependem de características da imagem como a intensidade e contraste.
- Presença de texturas - regiões de texturas coloridas são mais difíceis de segmentar, especialmente para métodos baseados em reconhecimento de bordas ou crescimento por regiões. Algoritmos que fazem segmentação de imagens baseados em reconhecimento de padrões podem obter bons resultados, porém são específicos para determinada aplicação.

A iluminação não se apresenta com um grande problema na estimação da DF multiespectral, uma vez que a análise ocorre sobre a interação dos canais de cores e que o processo de dilatação das esferas não sofre influência da tonalidade geral da imagem. Prova disto é que uma imagem com pouco e uma imagem com muita iluminação possuem a mesma dimensão fractal (ver Figura 3.12).

Figura 3.12: (a) DF para uma imagem com baixa iluminação e (b) DF para a mesma imagem com alta iluminação.

Em adição o método não utiliza parâmetros que sejam influenciados pela variação de intensidade da imagem sendo, desta forma, igualmente funcional para imagens com alto e baixo contraste, obtendo o mesmo resultado.

Muitas são as vantagens da DF volumétrica multiespectral de Bouligand-Minkowski sobre o método proposto por She and Huang [94]. Esta se apresenta mais precisa, rápida, é idealmente adequada para análise de textura global e local e realiza a análise da interação entre os canais de cor em apenas um estágio ([94] realiza essa análise em três estágios, obtendo DF para cada combinação de cor (RB, RG, GB)), resultando assim em uma única dimensão fractal para cada escala.

3.3.1.6 Momentos de Cromaticidade

No tangente a análise de texturas um importante atributo é a informação de cor. Vários trabalhos utilizam características de cor de forma a promover a discriminação de texturas [17, 73, 49]. Essas abordagens tradicionais assumem que a textura pode ser caracterizada pelo histograma de cor de uma dada região.

Paschos [74] propôs uma solução muito simples para o problema de reconhecimento de texturas coloridas. O trabalho baseia-se no conceito de cromaticidade sobre o espaço de cores CIE XYZ. Este espaço de cores é definido pela seguinte transformação [110]:

$$X = 0.607 \times R + 0.174 \times G + 0.200 \times B, \quad (3.57)$$

$$Y = 0.299 \times R + 0.587 \times G + 0.114 \times B, \quad (3.58)$$

$$Z = 0.066 \times G + 1.111 \times B. \quad (3.59)$$

As cromaticidades (x, y) são derivadas a partir de XYZ da seguinte forma:

$$x = \frac{X}{X + Y + Z} \quad (3.60)$$

$$y = \frac{Y}{X + Y + Z} \quad (3.61)$$

O diagrama de cromaticidade é, então, uma representação bidimensional da imagem onde cada pixel produz um par de valores (x, y) . Define-se então o diagrama de cromaticidade da imagem I com dimensões L_x L_y como sendo:

$$T(x, y) = \begin{cases} 1, & \text{se } \exists(i, j) : I(i, j) \text{ produzindo } (x, y), \\ 0, & \text{caso contrário,} \end{cases} \quad 0 \leq i \leq L_x - 1, 0 \leq j \leq L_y \quad (3.62)$$

Associado com o diagrama de cromaticidade temos sua distribuição bidimensional (i.e histograma) definido como:

$$D(x, y) = k, \text{ onde } k = \text{nro de pixels produzindo } (x, y). \quad (3.63)$$

A Figura 3.13 mostra um exemplo do diagrama e do histograma de cromaticidade.

Figura 3.13: Um exemplo de: (a) diagrama de cromaticidade e (b) sua distribuição bidimensional (e.g. histograma). Adaptado de [74].

Estas duas funções podem ser caracterizadas, aproximadamente, por seus (m, l) momentos definidos como:

$$M_T(m, l) = \sum_{x=0}^{X_S-1} \sum_{y=0}^{Y_S-1} x^m y^l T(x, y) \quad (3.64)$$

$$M_D(m, l) = \sum_{x=0}^{X_S-1} \sum_{y=0}^{Y_S-1} x^m y^l D(x, y) \quad (3.65)$$

onde, $m, l = 0, 1, 2, \dots$, e X_S, Y_S são as dimensões discretizadas de $x - y$. Visto que $x, y \in [0, 1]$ (ver Equações 3.60 e 3.61), o espaço discreto $X_S \times Y_S$ é produzido reescalando-se e discretizando-se, i.e., $x = [x \times 100]$, $y = [y \times 100]$, assim $X_S = Y_S = 100$. O trabalho de [74] demonstra que um pequeno número de momentos é capaz de discriminar diferentes classes de texturas.

3.3.1.7 Descritores de Cor Baseados na Estrutura Espacial

Embora nos últimos anos vários trabalhos venham sendo desenvolvidos com o objetivo de utilizar a informação de cor no aperfeiçoamento das técnicas de análise de textura, a estrutura espacial não é considerada quanto a utilização de técnicas baseadas em descritores de primeira ordem derivados do histograma ([17, 73, 49]).

Vários métodos vem sendo propostos na literatura de forma a solucionar tal limitação. Thai and Healey [99], em uma abordagem de fotometria, propôs, com bons resultados, mensurar características de cor e textura pela aplicação de filtros de Gabor sobre o modelo de oponência cromática (ver [92]). Mais recentemente [46] propuseram um novo modelo, baseado em aspectos físicos da cor (colorimetria), onde a imagem colorida é analisada a partir da integração da dimensão espacial e do comprimento de onda emitidos pela luz. O autor demonstra que, uma cena colorida definida como uma função de energia tri-dimensional $E(x, y, \lambda)$ (ou $E(u, v, \lambda)$ no domínio das frequências), onde (x, y) denotas as coordenadas espaciais e λ descreve o comprimento de onda, pode ser caracterizada a partir da multiplicação de duas funções Gaussianas centradas em (u, v) e λ respectivamente. Isso implica que uma Gaussiana tridimensional pode ser utilizada na caracterização de cor/textura em conjunto no domínio da frequência, o que é equivalente a se convolucionar um filtro de Gabor $h(x, y)$ no domínio do espaço. Como complemento Geusebroek et al. [38] demonstrou que o espectro de cores pode ser aproximadamente reconstruído a partir de derivadas de $E(x, y, \lambda)$ com respeito à λ a um dado comprimento de onda λ_0 . Assim, para caracterizar cor e textura em conjunto temos:

$$\begin{aligned}\hat{E}^{\lambda_0}(x, y) &= h(x, y) * \tilde{E}^{\lambda_0}(x, y) \\ \hat{E}_{\lambda}^{\lambda_0}(x, y) &= h(x, y) * \tilde{E}_{\lambda}^{\lambda_0}(x, y) \\ \hat{E}_{\lambda\lambda}^{\lambda_0}(x, y) &= h(x, y) * \tilde{E}_{\lambda\lambda}^{\lambda_0}(x, y)\end{aligned}\tag{3.66}$$

onde:

$$\begin{aligned}\tilde{E}^{\lambda_0}(x, y) &= \int E(x, y, \lambda) G^{\lambda_0\sigma_\lambda}(\lambda) d\lambda \\ \tilde{E}_{\lambda}^{\lambda_0}(x, y) &= \int E(x, y, \lambda) G_{\lambda}^{\lambda_0\sigma_\lambda}(\lambda) d\lambda \\ \tilde{E}_{\lambda\lambda}^{\lambda_0}(x, y) &= \int E(x, y, \lambda) G_{\lambda\lambda}^{\lambda_0\sigma_\lambda}(\lambda) d\lambda\end{aligned}\tag{3.67}$$

Na equação 3.66, $\tilde{E}$ caracteriza a energia da distribuição espectral. A primeira derivada $\tilde{E}_{\lambda}$ compara a região azul do espectro com a região amarela, e a segunda derivada $\tilde{E}_{\lambda\lambda}$ compara a região central (verde) do espectro com outras duas regiões (magenta). Fixando os parâmetros

da equação 3.66 em $\lambda_0 = 520nm$ e $\sigma_\lambda = 55nm$, para uma câmera RGB temos a seguinte transformação linear:

$$\begin{bmatrix} \tilde{E} \\ \tilde{E}_\lambda \\ \tilde{E}_{\lambda\lambda} \end{bmatrix} = \begin{pmatrix} 0.06 & 0.63 & 0.31 \\ 0.19 & 0.18 & -0.37 \\ 0.22 & -0.44 & 0.06 \end{pmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (3.68)$$

Desta forma, características de cor e sua respectiva estrutura espacial são obtidas pela aplicação de um conjunto de filtros de Gabor em cada canal $\tilde{E}$, $\tilde{E}_\lambda$ e $\tilde{E}_{\lambda\lambda}$.

Reconhecimento de Padrões

Conforme apresentado anteriormente este trabalho foca-se na análise de textura foliar, especificamente na extração de características e a subsequente classificação. A fase de classificação está relacionada à identificação de espécimes por meio do reconhecimento de padrões a partir de uma série de variáveis independentes, selecionadas de um modelo teórico que descreve características de textura. Desta forma, serão apresentados neste capítulo: (1) métodos para reconhecimento de padrões lineares com base em análise de dados multivariados, (2) não lineares com base na teoria das Redes Neurais Artificiais e (3) métodos simples para combinação de diferentes classificadores (comitê de máquinas). Também serão apresentadas brevemente algumas técnicas para (4) redução de dimensionalidade de dados, (5) validação cruzada e, por fim (6) o teste estatístico de Grubb's para detecção de outliers.

4.1 Análise Discriminante

A análise discriminante é uma técnica estatística multivariada usada na resolução de problemas que envolvem a separação de conjuntos distintos de observações e a alocação de novas observações em um dos conjuntos definidos *a priori* [40]. Trata-se de uma técnica estatística apropriada para identificar a qual grupo um determinado elemento tem mais chances de pertencer e que variáveis melhor separam uma população em diferentes grupos. Os objetivos da Análise Discriminante podem ser apresentados como:

- Identificar as variáveis que melhor contribuem para discriminação entre dois, ou mais, grupos.

- Usar as referidas variáveis na construção de um modelo, ou regra, que permita sintetizar as diferenças entre os grupos.
- Utilizar o modelo para classificar futuras observações em um dos grupos.

4.1.1 Análise Discriminante Linear

Em análise discriminante, a variável dependente (Y) descreve o grupo e as variáveis independentes (X) são as características que descrevem a observação/objeto como pertencente a determinado grupo. Caso assumamos que os grupos são linearmente separáveis, podemos usar o modelo de LDA¹ (Análise Discriminante Linear). Este modelo sugere que os grupos podem ser separados por uma combinação linear das características que descrevem os objetos. Se há apenas duas características, a separação entre os grupos de objetos pode ser realizada utilizando linhas. Se houver três características, o separador é um plano e se o número de características for maior que três, então o separador será um hiperplano.

A Análise Discriminante Linear [35, 41] é uma técnica bem conhecida para extração de características, redução de dimensionalidade e classificação. Ela vem sendo amplamente usada em muitas aplicações de visão computacional como por exemplo reconhecimento de faces [12] e recuperação de imagens [97].

O critério de classificação utilizado é minimizar a probabilidade de classificação errônea [52], ou seja, a regra obtida faz com que a proporção de objetos classificados de forma errada seja a menor possível. Isto é possível pois a técnica de LDA projeta os dados em um espaço de baixa dimensionalidade onde a razão entre variância intraclasses e entre-classes é maximizada². Baseada na teoria de Bayes, a regra de classificação pode ser vista como a atribuição do objeto ao grupo com probabilidade condicional mais elevada.

Para g grupos, a regra de Bayes é atribuir o objeto ao grupo i quando:

$$P(i|\mathbf{x}) > P(j|\mathbf{x}), \text{ para } \forall j \neq i \quad (4.1)$$

O objetivo portanto é saber a probabilidade $P(i|\mathbf{x})$ de que um objeto pertença ao grupo i , dado um conjunto de características $\mathbf{x}$. Na prática entretanto, o valor de $P(i|\mathbf{x})$ é difícil de obter. Possui-se porém $P(\mathbf{x}|i)$, isto é, a probabilidade de se obter um determinado conjunto de características $\mathbf{x}$ dado que o objeto pertence ao grupo i .

Afortunadamente, há uma relação entre as duas probabilidades condicionais, conhecida como *teorema de Bayes*:

¹do inglês Linear Discriminant Analysis

²esta transformação ótima pode ser calculada facilmente pela resolução de um problema clássico de autovalores

$$P(i|\mathbf{x}) = \frac{P(\mathbf{x}|i) \cdot P(i)}{\sum_{\forall j} P(\mathbf{x}|j) \cdot P(j)} \quad (4.2)$$

Sendo que a probabilidade *a priori* $P(i)$ é a probabilidade da escolha do grupo i sem que nenhuma característica do objeto seja conhecida. Podemos assumir que a probabilidade *a priori* é igual para todos os grupos ou é baseada no número de amostras em cada grupo. Na prática, entretanto, usar a regra de Bayes diretamente é impraticável pois se necessita de uma grande quantidade de dados. É então, usual, supor uma distribuição e calcular estas probabilidades teoricamente. Se assumirmos que cada grupo tem uma distribuição normal multivariada e possui a mesma matriz de covariância, podemos então utilizar a análise discriminante de Fisher [52].

Seja $f_i(\mathbf{x})$ a função densidade da população i , $i = 1, 2, \dots, g$, a regra de discriminação que minimiza as probabilidades de erros de classificações incorretas é dado pela seguinte forma: para um vetor de observações $\mathbf{x}$ fixo, calcula-se o valor da densidade $f_i(\mathbf{x})$ para cada população i , $i = 1, 2, \dots, g$, sendo o elemento amostral classificado na população que tiver o maior valor de $f_i(\mathbf{x})$ ³, ou seja, classifica-se o elemento amostral naquela população k , tal que:

$$f_k(\mathbf{x}) = \arg \max \{f_i(\mathbf{x}), i = 1, 2, \dots, g\} \quad (4.3)$$

sendo:

$$f_i(\mathbf{x}) = -\frac{1}{2} \ln(|S_i|) - \frac{1}{2} (x - \mu_i)' S_i^{-1} (x - \mu_i) \quad (4.4)$$

onde μ e S_i representam, respectivamente, o vetor de médias e a matriz de covariâncias da população i , $i = 1, 2, \dots, g$. Assumindo que as g matrizes de covariâncias S_i são iguais, estas podem ser estimas pela matriz de covariâncias combinada S definida por:

$$S = \frac{(n_1 - 1)S_1 + (n_2 - 1)S_2 + \dots + (n_g - 1)S_g}{(n_1 + n_2 + \dots + n_g) - g} \quad (4.5)$$

Johnson and Wichern [52] apresentam mais detalhes sobre a construção matemática da função discriminante.

³ $f_i(\mathbf{x})$ representa neste caso $P(i|\mathbf{x})$

4.2 Redes Neurais

Redes Neurais Artificiais (RNA) são sistemas inspirados nos neurônios biológicos e na estrutura massivamente paralela do cérebro, com capacidade de adquirir, armazenar e utilizar conhecimento experimental. Sua capacidade de solucionar problemas advém da simulação do cérebro humano, inclusive em seu comportamento, ou seja, aprendendo, errando e fazendo descobertas.

A idéia básica é de que um sistema composto por diversas unidades simples (neurônios artificiais) e ligados de maneira apropriada, possam gerar comportamento interessante e complexo. Este comportamento é determinado pela estrutura dos neurônios, estrutura das ligações (topologia da rede) e pelos valores das conexões (pesos sinápticos). Devido a esta similaridade com a estrutura cerebral, algumas características básicas como procura paralela e endereçamento pelo conteúdo, aprendizado, associação, generalização e robustez de degradação gradual são parecidas ao comportamento humano [14].

Várias aplicações destes sistemas são relatadas na literatura, podendo, dependendo dos objetivos a que se destinam, serem sumarizados em seis categorias [44]: associação e reconhecimento de padrões, aproximação de funções, controle, filtragem e previsão não linear. Para tais aplicações, diferentes topologias podem ser utilizadas, podendo ser basicamente redes feed-forward, possuindo uma ou mais camada de processadores, cujo fluxo de dados é sempre em uma única direção, isto é, não existe realimentação ou, redes recorrentes, que são redes com conexões entre processadores da mesma camada e/ou com processadores das camadas anteriores (realimentação). Além disso, diferentes tipos de aprendizado são relatados, sendo usualmente classificados em três paradigmas principais: aprendizados supervisionados (Perceptron, MLP, RBF), aprendizado não supervisionado (SOM, ICA, ART, Hopfield) e aprendizado por reforço (Programação dinâmica).

Deste modo, diferentes soluções para identificação de espécies apresentam-se quando da utilização das diferentes teorias e arquiteturas existentes em redes neurais artificiais. Dentre os variados tipos, a rede MLP (Multilayer Perceptron) é uma das soluções mais tradicionais ao problema de classificação. Estas redes possuem a importante característica de resolverem problemas não linearmente separáveis, tem sido utilizadas com sucesso na resolução de vários problema de classificação supervisionada [44]. A seguir uma breve descrição do funcionamento desse sistema.

4.2.1 Perceptron Multicamadas

As RNAs do tipo perceptron multicamadas, ou MLP⁴, são RNAs *feed-forward* que apresentam pelo menos uma camada intermediária ou escondida [87]. A Figura 4.1 apresenta o

⁴do inglês multilayer perceptron

grafo arquitetural de uma MLP exemplo com duas camadas ocultas. Sua arquitetura faz uso de funções de ativação não lineares e diferenciáveis em todos os pontos, sendo a função sigmoideal a mais utilizada:

$$y_j = \frac{1}{1 + \exp(-net_j)} \quad (4.6)$$

onde $-net_j$ é a soma ponderada de todas as conexões sinápticas do neurônio j , e y_j é a saída do neurônio j .

Figura 4.1: Grafo arquitetural de uma MLP com duas camadas ocultas. Adaptado de [44].

O algoritmo de aprendizado mais conhecido para treinamento destas redes é o algoritmo back-propagation [86], a maioria dos métodos de aprendizado para RNAs do tipo MLP utiliza variações deste algoritmo. Este algoritmo é supervisionado e utiliza pares (entrada, saída desejada) para, por meio de um mecanismo de correção de erros (gradiente descendente ou regra delta), ajustar os pesos da rede. O treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido. Estas duas fases são chamadas de fase *forward* e fase *backward*. A fase forward é utilizada para definir a saída da rede para um dado padrão de entrada. A fase backward utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões. A Figura 4.2 ilustra este processo.

Na fase forward a saída de cada neurônio é dada por:

$$y_j = f_j(net_j) \quad (4.7)$$

onde:

$$net_j = \sum_{i=1}^n x_i w_{ji} + \theta_i \quad (4.8)$$

sendo que a constante n representa o número de conexões de entrada do nodo j , w_{ji} representa o peso da conexão entre a entrada x_i e o nodo j , θ_i é o peso do *bias* e f_j é uma função de ativação não linear diferenciável, como por exemplo a função sigmoideal apresentada acima.

Figura 4.2: Ilustração do fluxo do sinal nas duas fases de aprendizado da MLP (forward e backward). Adaptado de [44]

A fase backward realiza o ajuste dos pesos utilizando a saída fornecida pela fase forward (y_j) pela seguinte equação:

$$\Delta w_{ji} = \eta \delta_j x_i \quad (4.9)$$

onde δ será definido como:

$$\delta_j = (d_j - y_j) f'(net_j) \quad (4.10)$$

se o nodo estiver na camada de saída, e

$$\delta_j = f'(net_j) \sum_l \partial_l w_{lj} \quad (4.11)$$

caso contrário. Aqui $f'(net_j)$ denota a derivada da função de ativação, d_j é a saída desejada, y_j é a saída obtida e η é a taxa de aprendizado. A derivação completa destas equações podem ser vistas em [44].

O treinamento desta rede termina quando um determinado número de ciclos é realizado ou quando, a soma dos erros quadráticos de todos os padrões apresentados, seja menor que um determinado valor. O erro é definido por:

$$E = \frac{1}{2} \sum_p \sum_{j=1}^k (d_j^p - y_j^p)^2 \quad (4.12)$$

onde E é a medida de erro total ou função de custo a ser minimizada, p o número de padrões apresentados e k o número de unidade de saída.

4.3 Comitê de Máquinas

Um comitê de máquinas ou *ensemble* consiste de um conjunto de componentes (classificadores), cada um representando uma proposta de solução, cujas classificações, no caso de problemas de classificação de padrões, ou estimativas, no caso de problemas de regressão, são combinadas de formas diversas visando um ganho de desempenho [44].

Este paradigma originou-se do trabalho de Hansen and Salamon [42], que mostraram que a habilidade de generalização pode ser significativamente melhorada por meio da composição de várias redes neurais artificiais, ou seja, treinamento independente de várias redes neurais artificiais e posterior composição das saídas individuais. Este incremento é conquistado caso alguns requisitos sejam atendidos pelos componentes do *ensemble*, os principais são [44]:

- cada um dos componentes deve apresentar bom desempenho quando tomado isoladamente;
- o comportamento de cada componente deve ser o mais descorrelacionado possível frente aos demais.

Desta forma diferentes propostas de solução podem explorar diferentes aspectos relevantes de um problema, enquanto muitas vezes uma única proposta de solução não é capaz de explorar todos os aspectos relevantes simultaneamente. Esta é a mais forte motivação para o emprego de um comitê de máquinas.

4.3.1 Geração de Componentes

Os resultados mais expressivos presentes na literatura empregam redes neurais artificiais como componentes, porém outros tipos de classificadores também podem ser utilizados para tal tarefa. O objetivo então é encontrar classificadores de bom desempenho e que generalizam de forma descorrelacionada (e.g. dois classificadores são considerados diversos se eles não apresentam os mesmos erros de classificação frente a um mesmo conjunto de amostras, ou seja, se as amostras classificadas erroneamente pelos classificadores diferem em algum grau).

A literatura apresenta várias formas e conceitos para gerar componentes diversos e descorrelacionados [44], a aplicação de tais técnicas depende fortemente dos classificadores a serem utilizados como componentes do comitê de máquinas. Porém, de maneira geral, podem ser resumidos em:

- Pré-processamento de parâmetros e aspectos estruturais: onde a diversificação dos componentes é alcançada modificando-se os parâmetros do classificador (caso este o possua) (e.g. pesos, arquitetura e/ou algoritmo de treinamento em redes neurais artificiais).
- Pré-processamento dos dados de treinamento: o objetivo aqui é produzir conjuntos de treinamento distintos, que podem conduzir a classificadores que generalizam de forma diversa mesmo que mantidos idênticos os parâmetros e aspectos estruturais do mesmo. Re-amostragem dos dados (*Bagging*) [15], re-amostragem adaptativa (*Boosting*) [91] e utilização de variáveis distintas são os métodos mais utilizados. Estas técnicas serão brevemente descritas a seguir.

1. *Bagging*⁵ foi proposto por Breiman [15]. Nesta abordagem, são gerados vários conjuntos de treinamento a partir de amostragem uniforme do conjunto original de dados, com reposição, e então se obtém uma proposta de solução a partir de cada um desses conjuntos de treinamento. Os conjuntos de treinamento têm o mesmo número de amostras do conjunto original, mas algumas amostras do conjunto original podem aparecer mais de uma vez, fazendo com que outras amostras não sejam selecionadas. Essa distinção aleatória entre os vários conjuntos de treinamento confere diversidade aos modelos de classificação ou regressão que são obtidos a partir de cada um desses conjuntos.
2. *Boosting* foi proposto por Schapire [91]. Nesta abordagem, os vários conjuntos de treinamento não são gerados a partir de uma amostragem uniforme com reposição, como no caso do bagging. A probabilidade de escolha de uma amostra depende da contribuição desta para o erro de treinamento dos componentes já treinados, isto é, caso uma amostra não tenha sido corretamente classificada pelos componentes já gerados, a probabilidade de escolha desta aumenta em relação às demais amostras, quando do treinamento de novos componentes. Conseqüentemente, esta amostra terá uma chance maior de ser escolhida para compor o conjunto de dados do próximo componente a ser gerado. Portanto, apenas o primeiro componente do ensemble é treinado a partir de uma amostragem uniforme do conjunto de dados original. É necessário, assim, que os vários componentes do ensemble sejam treinados seqüencialmente, visando redefinir a probabilidade de escolha das amostras na geração dos próximos conjuntos de treinamento.

⁵do inglês bootstrap aggregating

3. Variáveis distintas: em algumas aplicações específicas é possível obter conjuntos de treinamento distintos pela simples consideração de um elenco de variáveis diferentes para o vetor de entrada. Desse modo, cada componente do ensemble toma um subconjunto de variáveis de entrada distinto dos demais, embora possa haver variáveis comuns entre eles. Uma abordagem muito comum é utilizar variáveis provenientes de fontes/técnicas distintas em cada um dos classificadores componentes do ensemble.

4.3.2 Métodos de Combinação

Quanto à combinação dos classificadores componentes, as abordagens predominantes são o voto baseado na pluralidade ou voto majoritário, média simples ou média ponderada [42]. O problema trata da combinação de M classificadores diferentes $f_j, j = 1, \dots, M$, utilizados para classificação do padrão $\mathbf{x}$ em K classes, $U = \{1, \dots, K\}$. A saída do j -ésimo classificador para a k -ésima classe será denotada por u_j^k . A saída do comitê de máquinas será denotada por $\hat{f}(\cdot)$. Logo, a combinação de múltiplos componentes pode ser vista como a determinação de $\hat{f}(\mathbf{x})$ usando as saídas $\hat{f}_j(\mathbf{x})$ de todos os M componentes.

- Média simples e média ponderada: é um dos métodos mais populares de combinação. Ele se refere a uma combinação linear da saída dos componentes. Uma única saída pode ser criada a partir de um conjunto de saídas via média simples, ou por meio de uma média ponderada, a qual considera o desempenho relativo dos componentes a serem combinados. Neste método, a saída do comitê de máquinas será a classe com maior valor médio, conforme mostra a equação a seguir:

$$\hat{f}(\mathbf{x}) = \max_{k \in U} S_k \quad (4.13)$$

onde,

$$S_k = \frac{1}{M} \sum_{j=1}^M \alpha_j u_j^k \quad (4.14)$$

sendo α_j peso relativo de cada classificador. Este fica definido como $\alpha_j = 1$ o no caso de média simples e

$$\alpha_j = \log \frac{e(f_j)}{\sum_{j=1}^M e(f_j)} \quad (4.15)$$

para média ponderada, $e(f_j)$ denota o erro total associado a cada classificador .

- Votação: O resultado apoiado pela maioria dos componentes é definido como a saída do comitê de máquinas, segundo a equação a seguir:

$$\hat{f}(\mathbf{x}) = k^* \quad (4.16)$$

se

$$k^* = \max_k \left(\sum_{j=1}^M G_j^k(\mathbf{x}) \right) \quad (4.17)$$

onde:

$$G_j^k(\mathbf{x}) = \begin{cases} 0 & \text{se } \hat{f}_j(\mathbf{x}) \neq k \\ 1 & \text{se } \hat{f}_j(\mathbf{x}) = k \end{cases} \quad (4.18)$$

Embora a votação tenha a vantagem de não requerer recursos computacionais ou espaço de memória extra, esta pode piorar o desempenho do comitê de máquinas, caso existam componentes com desempenho global ruim. Isto ocorre porque os rótulos de todos os componentes têm o mesmo peso, independente do seu desempenho global. O princípio de votação é exatamente o que é conhecido como votação majoritária.

4.4 Análise de Componentes Principais

A técnica denominada de análise de componentes principais, popularmente chamada de PCA⁶, foi introduzida por Karl Pearson em 1901 e está fundamentada no artigo de Hotelling [47]. Seu objetivo principal é o de explicar a estrutura de variância e covariância de um vetor aleatório composto de p -variáveis aleatórias, por meio da construção de combinações lineares das variáveis originais. Estas combinações lineares são chamadas de componentes principais e são não correlacionadas entre si. A partir de p -variáveis originais é possível obter p -componentes principais. No entanto, em geral deseja-se obter uma redução do número de variáveis a serem avaliadas e uma interpretação das combinações lineares construídas, ou seja, a informação contida nas p -variáveis originais é substituída pela informação contida em k ($k < p$) componentes

⁶do inglês *Principal Component Analysis*

principais não correlacionadas. Desta forma, o sistema de variabilidade do vetor aleatório composto de p -variáveis originais é aproximado pelo sistema de variabilidade do vetor aleatório que contém as k -componentes principais. A qualidade da aproximação depende do número de componentes mantidas no sistema e pode ser medida por meio de técnicas próprias.

Uma vez determinadas as componentes principais, os seus escores numéricos podem ser calculados para cada elemento amostral. Deste modo, os valores de cada componente podem ser analisados, usando-se técnicas estatísticas usuais como análise discriminante e/ou outros tipos de classificadores.

Seja S a matriz de covariâncias amostral definida na equação 4.5 e $\hat{\lambda}_1, \hat{\lambda}_2, \dots, \hat{\lambda}_p$ os autovalores da matriz S , e sejam $\hat{e}_1, \hat{e}_2, \dots, \hat{e}_p$ os autovetores correspondentes normalizados. Então, a j -ésima componente principal $\hat{Y}_j$ amostral estimada é definida por:

$$\hat{Y}_j = \hat{e}_j' X = \hat{e}_{j1} X_1 + \hat{e}_{j2} X_2 + \dots + \hat{e}_{jp} X_p, j = 1, 2, \dots, p \quad (4.19)$$

Algumas das principais propriedades das componentes principais amostrais são apresentadas a seguir:

- A variância estimada de $\hat{Y}_j$ é igual a $\hat{\lambda}_j, j = 1, 2, \dots, p$.
- A covariância entre as componentes $\hat{Y}_j$ e $\hat{Y}_k$ é igual a zero, para todo $k \neq j$, que significa dizer que estas componentes são não correlacionadas.
- A variância total explicada pela j -ésima componente amostral é dada por:

$$\frac{\hat{\lambda}_j}{\sum_{i=1}^p \hat{\lambda}_i} \quad (4.20)$$

Em termos práticos, para fazer uso das k componentes principais amostrais consideradas mais relevantes na análise de dados, é necessário calcular os seus valores numéricos para cada elemento amostral valores esses chamados de escores das componentes.

4.5 Validação Cruzada

Validação cruzada é uma prática estatística utilizada para se estimar as probabilidades de classificações incorretas. Estas probabilidades é que demonstrarão a precisão e a qualidade do classificador obtido.

Existem vários métodos capazes de testarem a estabilidade de um modelo de classificação. Todos partem do princípio onde se divide o conjunto de amostras em subconjuntos de treinamento e teste. Entre eles temos: validação holdout, validação cruzada K-fold e validação cruzada leave-one-out.

4.5.1 *Holdout*

O método Holdout (validação por divisão em duas partes) é um dos métodos mais comuns para estimar a generalização de erro. Aqui observações são escolhidas randomicamente do conjunto inicial para formar o conjunto de treinamento, as observações restantes farão parte do conjunto de testes. É comum designar menos de um terço do conjunto inicial para ser usado como conjunto de testes [35].

4.5.2 *K-fold*

No método de validação cruzada com K-fold (K-dobras), o conjunto original de observações é particionado em K subconjuntos mutuamente excludentes e de tamanhos aproximadamente iguais. Dos K subconjuntos criados, um é utilizado como subconjunto de testes, e os restantes $K - 1$ são utilizados como dados de treinamento. O processo de validação cruzada é então repetido K vezes (folds), onde cada subconjunto é utilizado exatamente uma vez como conjunto de testes. Os K resultados obtidos são então combinados para produzir uma única estimação de erro.

4.5.3 *Leave-one-Out*

O método de validação cruzada *leave-one-out* utiliza uma única observação do conjunto original como teste, e as observações restantes como subconjunto de treinamento. Este processo é repetido até que todas as observações sejam utilizadas uma vez como teste. Esse método pode ser considerado um caso especial do método K-fold onde o número de subconjuntos (K) é igual ao número de elementos do conjunto original.

4.6 Teste de Grubb's

Estatísticos vem desenvolvendo várias maneiras para detectar observações discordantes ou também designadas por outliers. O teste de Grubb's (também chamado de ESD⁷) é uma das mais simples e conhecidas formas de realizar tal processo.

⁷do inglês Extreme Studentized Deviate

O primeiro passo é quantificar quão distantes uma amostra está das outras. Isto se dá pelo cálculo do score Z como sendo a diferença do possível outlier em relação à média populacional dividido pelo desvio padrão. Se Z for grande é indício que a amostra é um possível outlier.

$$Z = \frac{|\mu - x|}{\sigma} \quad (4.21)$$

Esta abordagem é aplicável apenas se tivermos conhecimento da média (μ) e do desvio padrão (σ) dos dados. Nem sempre conhecer esses valores reais é possível. Desta forma uma estimativa da média real ($\bar{x}$) pode ser realizada sobre os dados amostrais e então o desvio padrão estimado sobre os valores de $\bar{x}$. Obviamente a presença de um ou mais outliers pode alterar os valores de $\bar{x}$ e σ . Porém, posto que a presença de outliers altera ambos os valores de numerador (diferença entre o valor e a média) e o denominador (desvio padrão de todos os valores), o escore Z acaba por não sofrer influência significativa. De fato Z não pode ser maior que $(N-1)/\sqrt{N}$, onde N é o número de amostras.

Grubb's e outros autores tabularam os valores críticos para Z (Ver anexo I 7.1)[11]. Estes valores críticos indicam o limite que, para um determinado nível de significância, a amostra deve ser rejeitada. Se calcularmos um escore Z maior que o valor crítico tabulado para um nível de significância α , significa que há apenas uma probabilidade de $\alpha * 100\%$ de aquela amostra realmente pertencer à distribuição em questão. É importante notar que o método de Grubb's apenas testa o valor Z mais extremo.

Uma vez identificado o outlier pode-se optar por excluí-lo da análise ou tratá-lo de forma diferenciada no estudo. Se a decisão tomada for a remoção é necessário realizar o teste de Grubb's novamente para verificar um possível segundo outlier nos dados. Este processo altera o valor crítico uma vez que o número de amostras N diminui.

Sistema de Visão

Para um melhor entendimento, o processo e os resultados desta pesquisa serão apresentados sob o ponto de vista de um sistema típico de visão computacional. Pode-se definir um sistema de visão computacional como o conjunto de métodos e técnicas através dos quais sistemas computacionais podem ser capazes de interpretar imagens.

A organização de um sistema de visão computacional é dependente da aplicação. A implementação específica de tal sistema depende também se sua funcionalidade é pré-especificada ou se existe alguma parte de aprendizagem durante a operação. Existem, entretanto, funções típicas encontradas em vários sistemas de visão computacional. Para o referido sistema de análise e identificação de espécies vegetais por meio da análise de textura foliar, foram definidas as seguintes etapas (Figura 5.1):

Figura 5.1: Etapas envolvidas no sistema de análise e identificação de espécies vegetais por meio da análise de textura foliar.

- Aquisição de imagem: Segundo [39] a etapa de aquisição é quando a imagem do sensor é transformada em uma imagem digital sobre a forma de uma tabela de valores discretos inteiros chamados *pixels*. Os valores dos *pixels* geralmente indicam a intensidade da luz em uma ou várias faixas de cor (o que forma imagens em tom de cinza ou coloridas).

- Pré-processamento: antes de um método de visão computacional ser aplicado em uma imagem para extrair informação, é geralmente necessário processar a imagem para assegurar-se que ela satisfaz as condições do método. Exemplos incluem redução de ruídos (para assegurar que as informações são verdadeiras), aumento de contraste (para assegurar que as informações relevantes serão detectadas) e seleção de regiões de interesse específicas (segmentação e extração de uma ou mais regiões que contém um objeto de interesse).
- Extração de características: essa etapa consiste em extrair características matemáticas da imagem em vários níveis de complexidade. Exemplos básicos incluem detecção de bordas, cantos ou pontos. Exemplos sofisticados incluem detecção de textura, formato e movimento.
- Classificação: o reconhecimento de padrões, ou classificação, é uma das tarefas mais importantes após a etapa de extração de características. No problema de identificação dos órgãos foliares, os métodos de reconhecimento de padrões são utilizados para tentar descobrir, baseado nas características extraídas, a qual espécie uma determinada folha pertence.

A seguir, serão apresentados em detalhes, os conceitos e métodos envolvidos em cada etapa, descrevendo detalhadamente todo o procedimento experimental adotado, desde a aquisição das imagens até a configuração e obtenção dos classificadores utilizados.

5.1 Aquisição

A aquisição da imagem é o processo mais importante de um sistema de visão computacional, pois é este quem determina a qualidade da imagem a ser utilizada nas etapas seguintes. Problemas que podem ser facilmente solucionados nesta fase, podem trazer dificuldades extras as etapas seguintes ou até mesmo impossibilitar a continuação do trabalho. Assim, visando evitar maiores dificuldades, um procedimento científico único foi adotado para coleta e digitalização das folhas/amostras.

As amostras foram coletadas *in vivo* e cada folha foi submetida a um processo de limpeza para retirada de impurezas (tais como poeira, sedimentos, restos de insetos etc.), ajustada para que o seu eixo central (linha que une as extremidades basal e apical) ficasse na posição vertical, e digitalizada individualmente (frente e verso) com o auxílio de um scanner de mesa a uma resolução padrão de 1200dpi¹ (*pontos por polegada*).

Para cada imagem de folha coletada foi definido um padrão para a construção do nome do respectivo arquivo de imagem. O nome ficou definido como *cXX_WWW_F.png*, sendo *XX*

¹do inglês *dots per inch*

um número composto por dois dígitos denotando o número da classe/espécie ², *WWW* um número composto por três dígitos identificando o número da folha/amostra da referida classe/espécie e *F* um caráter *a* ou *b* identificando a imagem de frente e verso respectivamente.

Nenhum procedimento de normalização extra foi adotado uma vez que o scanner possui condições de iluminação e resolução controladas. Utilizou-se armazenagem com compressão *lossless*, que viabiliza a compressão dos dados sem perda de informações.

5.2 Pré-Processamento

Essa etapa permite corrigir um certo número de defeitos e imperfeições aparecidos durante a aquisição da imagem, que podem ter como causa características físicas do sistema, as condições deficientes de iluminação ou do próprio objeto a ser digitalizado, etc. O pré-processamento não é indispensável, mas, na maioria dos casos, necessário.

Sendo assim, após a preparação inicial das amostras, todas passaram por um pré-processamento para que fossem obtidas as amostras de textura (janelas texturais) mais representativas de cada classe. Este processo visa extrair e descartar texturas que apresentem ruídos e/ou variância de cor, tamanho e rotação (ver Seção 2.1).

O pré-processamento aplicado envolve basicamente: (1) segmentar a folha, separando-a do fundo da imagem; (2) extrair janelas/amostras de textura da respectiva folha; (3) descartar janelas texturais que não estejam em conformidade com o padrão apresentado pela amostra ou que possuam algum tipo de ruído, restando assim apenas as texturas mais representativas; (4) descartar possíveis amostras que apresentem um padrão incomum para aquela determinada classe.

5.2.1 Segmentação

Utilizando técnicas de segmentação e morfologia matemática, descritas nas Seções 3.2 e 3.2.2 respectivamente, procura-se delimitar a região foliar da imagem adquirida pelo o scanner, separando-se assim a folha do fundo da imagem.

Com esse objetivo uma limiarização automática, utilizado o método de Otsu [72], é executada sobre a imagem original 5.2a resultando na imagem binária exemplificada pela Figura 5.2b

Em seqüência um filtro morfológico para eliminação de ruídos é aplicado às imagens segmentadas. Isto pode ser realizado usando-se o operador de abertura seguido do operador de fechamento (ambos apresentados no Capítulo 3.2.2) com um elemento estruturante maior que qualquer ruído em *A*. Este processo aqui denominado de filtro *F* pode ser definido por:

²utilizar-se-á aqui o termo computacional classe de dados como equivalente ao termo biológico espécie, ou seja, uma classe é um conjunto de amostras/folhas de uma mesma espécie

$$F = (A \circ B) \bullet B \quad (5.1)$$

Definiu-se o elemento estruturante empiricamente como sendo de formato circular e com tamanho de raio equivalente a $1/100$ do maior eixo da imagem original.

O resultado é uma máscara que delimita a região foliar da imagem separando a assim folha do fundo da imagem. O resultado pode ser visto na Figura 5.2c

Figura 5.2: (a) imagem original (b) resultado após limiarização automática de Otsu e (c) resultado após aplicação do filtro morfológico F com elemento estruturante circular.

5.2.2 Extração Janelas Texturais

A abordagem de identificação proposta tem como característica principal a análise da microtextura foliar. Para tanto, é necessária a extração de janelas que abranjam áreas disjuntas da amostra em questão, tanto para que haja maior representatividade, como para solucionar o problema de variabilidade de textura na superfície foliar de uma mesma espécie. Dessa forma, um algoritmo automático realiza a extração randômica de w janelas de cada amostra, totalizando assim $x \times w$ janelas texturais (x amostras $\times w$ janelas). A Figura 5.3 apresenta a extração de 30 janelas texturais de uma folha da classe C12 ($w = 30$).

Cada janela textural foi salva separadamente da folha original com adição do sufixo $_wYY$ após o $_F$, onde YY é um número composto por dois dígitos denotando o número da janela textural de uma determinada amostra.

5.2.3 Descarte de Janelas Texturais

O descarte de janelas texturais de uma mesma amostra previamente extraídas torna-se interessante devido à grande variabilidade de texturas apresentadas por uma mesma folha/amostra e a necessidade de exemplos de textura *limpos*, ou seja, sem a presença de ruídos (fungos, pestes, lesões, etc.), sem grandes variações de coloração e sem informações estruturais (nervuras

Figura 5.3: Exemplo de extração das Janelas texturais de uma amostra.

primárias e secundárias) (ver seção 2.1). Ou seja, este pré-processamento visa escolher w' janelas texturais que melhor descrevem a textura da amostra em análise de um dado conjunto de w janelas. Podemos considerar portanto, as janelas texturais com ruídos como observações discordantes da base de dados.

Sendo $f(x, y)$ a imagem que representa uma janela textural w de uma amostra qualquer e $q_1(x, y), q_2(x, y), \dots, q_4(x, y)$ segmentos de imagens disjuntos (quadrantes não sobrepostos) de $f(x, y)$ com tamanho igual a $1/4$ da imagem original (e.g. $f(x, y) = 128 \times 128$ e $q_x(x, y) = 64 \times 64$), a janela w pode ser caracterizada por um conjunto de p atributos na forma $\mathbf{x} = x_1, x_2, \dots, x_p$ onde, cada elemento deste conjunto representa um ponto no espaço p -dimensional. Uma abordagem simples para obter janelas texturais sem grandes diferenças de tonalidade, e sem presença grandes segmentos com ruídos diversos (lesões, fungos, sujeira) é utilizar média e variância dos segmentos da imagem i para compor o vetor de características $\mathbf{x}$ da seguinte forma:

$$\mathbf{x}_i = \mu_{q_1}, \sigma_{q_1}, \mu_{q_2}, \sigma_{q_2}, \dots, \mu_{q_p}, \sigma_{q_p} \quad (5.2)$$

onde:

$$\mu_{q_x} = \frac{1}{mn} \sum_{x=1, y=1}^{m, n} q_x(x, y) \quad (5.3)$$

e

$$\sigma_{q_x}^2 = \frac{1}{mn} \sum_{x=1, y=1}^N (q_x(x, y) - \mu)^2 \quad (5.4)$$

sendo mn as dimensões dos segmentos q_x , neste caso $m = 64$ e $n = 64$.

De acordo com [11] a identificação de um outlier em dados multivariados é usualmente realizada pelo emprego do princípio de *reduced subordering*. Neste método transformamos uma observação multivariada $\mathbf{x}$, de dimensão p , em um escalar $R(\mathbf{x})$. Pode-se então ordenar as amostras $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$ em termos de seus valores $R_j = R(\mathbf{x}_j) (j = 1, 2, \dots, n)$. Tem-se então que a observação $\mathbf{x}_i$ com maior valor de R_n é um candidato a ser declarado como um outlier.

Há claramente perda de informações na estrutura multivariada quando do emprego de *reduced subordering*. Portanto, a pergunta chave é: como escolher a métrica de redução $R(\mathbf{x})$ com o mínimo de perda possível? Uma técnica muito utilizada é representar uma observação multivariada $\mathbf{x}$ por meio de uma métrica de distância. Considerando que as variáveis componentes de $\mathbf{x}$ são dependentes pode-se utilizar a distância de Mahalanobis assim definida:

$$R(\mathbf{x}; \mathbf{x}_0) = \sqrt{(\mathbf{x} - \mathbf{x}_0)^T S^{-1} (\mathbf{x} - \mathbf{x}_0)} \quad (5.5)$$

onde Σ é a matriz de covariância e $\mathbf{x}_0$ reflete localização dos dados ou da distribuição que lhe está subjacente. Uma abordagem muito comum, caso os dados sigam uma distribuição normal, é considerar a média real μ como o ponto referencial $\mathbf{x}_0$.

Temos então os escalares R_i que denotam o grau de similaridade entre o padrão $\mathbf{x}_i$ e a média μ . Descarta-se então a observação $\mathbf{x}_i$ com maior valor de R_n como sendo um outlier e iterativamente recalcula-se a média do conjunto de janelas e as distâncias R_i até que o número de padrões restantes na base seja igual a w' . Teremos assim um conjunto de janelas similares e representativas da amostra em análise. A Figura 5.4 ilustra este processo, no topo as janelas texturais descartadas e abaixo os padrões restantes (w'). A localização das w' janelas mais representativas sobre a superfície da amostra pode ser verificada na Figura 5.3 observando-se os quadrantes em vermelho.

5.2.4 Descarte de Amostras

Teoricamente amostras/folhas de uma mesma classe/espécie devem apresentar o mesmo padrão. Porém na natureza nem sempre isso é realidade. Ações de agentes externos citados na Seção 2.1 podem fazer com que uma ou mais amostras apresentem um padrão de cor e/ou textura completamente diferentes das demais. Tratar todas as peculiaridades presentes nas amostras é uma tarefa computacionalmente impraticável.

Figura 5.4: Separação das cinco janelas mais representativas ($w' = 5$) dentre o conjunto de 30 janelas ($w = 30$) extraídas da amostra em análise. Conforme Figura 5.3.

Desta forma, optou-se por eliminar da base de dados de treinamento amostras muito discrepantes. Considera-se aqui como pré-requisito no TreeVis que, para a adição de uma nova classe/espécie no sistema, seja necessário um número mínimo de amostras/folhas para que tal procedimento seja aplicável. Desta forma dá-se maior credibilidade ao sistema devido à alta amostragem.

Obviamente esse descarte também pode ser realizado na base de dados de teste quando as amostras estiverem em número suficiente grande. Porém a existência de várias amostras/folhas não é um pré-requisito para que o usuário possa utilizar o sistema em questão.

Uma abordagem simples e semelhante à utilizada na seção anterior (descarte de janelas texturais) será adotada para realizar descarte de amostras e/ou, em outras palavras, eliminação de outliers.

Seja $f_w(x, y)$ uma janela textural w' de uma determinada amostra i , um vetor de características com p atributos, da forma $\mathbf{x} = x_1, x_2, \dots, x_p$, pode ser composto pela média e variância das janelas texturais da amostra i da seguinte forma:

$$\mathbf{x}_i = \mu_{f_1}, \sigma_{f_1}, \mu_{f_2}, \sigma_{f_2}, \dots, \mu_{f_p}, \sigma_{f_p} \quad (5.6)$$

onde:

$$\mu_{f_x} = \frac{1}{mn} \sum_{x=1, y=1}^{m, n} f_x(x, y) \quad (5.7)$$

e

$$\sigma_{f_x}^2 = \frac{1}{mn} \sum_{x=1, y=1}^N (f_x(x, y) - \mu)^2 \quad (5.8)$$

sendo mn as dimensões de f_x .

Igualmente ao método empregado anteriormente no descarte de janelas texturais usar-se-á aqui o princípio de *reduced subordering* para descarte de amostras. Utilizando a distância de Mahalanobis (equação 5.5), com ponto referencial $\mathbf{x}_0$ igual à média simples μ de todas as amostras da referida classe em análise, reduz-se então a observação multivariada $\mathbf{x}_i$ a um escalar $R(\mathbf{x})$. Ordenam-se as amostras $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$ em termos de seus valores $R_j = R(\mathbf{x}_j) (j = 1, 2, \dots, n)$. Nesse ponto, diferentemente do realizado na seção anterior, onde se eliminava janelas iterativamente até que restassem apenas w' janelas, aqui elimina-se apenas *outliers* altamente discordantes em relação à média populacional.

Segundo [11] uma amostra x_i pode ser considerada discordante se seu valor $R_{(n)}$ mostrar-se excessivamente extremo perante uma dada distribuição F . Isso pode ser verificados por meio do teste de Grubb's (Seção 4.6). Para um determinado nível de significância α obtêm-se por meio da Tabela 7.1 o valor crítico para o escore Z . Se o escore calculado for maior que o valor crítico a amostra é eliminada da base de dados e o teste é repetido. A Figura 5.5 ilustra este processo, na parte inferior da figura observa-se uma amostra discordante e acima as amostras consideradas normais.

5.3 Extração de Características

Os chamados métodos de extração de características, possuem as habilidades de extrair características das imagens gerando assim o chamado vetor de características. Um vetor de características é uma representação numérica de uma imagem ou parte dela, descrevendo seus detalhes mais representativos. O vetor de características é um vetor n -dimensional contendo esses valores. Essa nova representação da imagem propicia vantagens ao processo de reconhecimento de imagens, pela redução da dimensionalidade dos dados e representabilidade obtida.

Embora individuais e com características próprias, os métodos de extração de características aqui empregados podem ser divididos em dois grupos:

Figura 5.5: Amostra considerada discordante da classe C11 conforme teste de Grubb's.

1. Grupo dos métodos que utilizam como fonte imagens previamente convertidas para tons de cinza, ou seja, não utilizam informações de cor como atributo;
2. Grupo dos métodos que fazem uso da informação de cor como forma de enriquecer a informação presente no vetor de características.

Ou em três abordagens distintas sendo (ver Figura 5.6):

1. Abordagem estatística;
2. Abordagem espectral;
3. Abordagem baseada em modelos;

Figura 5.6: Categorização dos métodos de análise de textura em grupos e abordagens

Desta forma está-se por cobrir e utilizar todos os aspectos possíveis em análise de textura. A seguir descreve-se, o procedimento e a configuração de cada método empregado neste trabalho.

5.3.1 Características de Primeira Ordem

As características de primeira ordem média, variância, kurtose, energia e entropia, dadas pelas Equações 3.17, 3.18, 3.19, 3.20 e 3.21 respectivamente, são obtidas a partir do histograma (função de densidade probabilidade dada pela equação 3.16) da imagem $f(x, y)$.

O vetor de características $\mathbf{x}$ fica então composto por 6 variáveis independentes entre si da seguinte forma:

$$\mathbf{x} = [\mu, \sigma^2, \mu_4, E, H] \quad (5.9)$$

Este processo pode ser melhor entendido observando-se a Figura 5.7.

Figura 5.7: Processo de extração das características de primeira ordem.

5.3.2 Coocorrência

Diferentemente das características de primeira ordem, as matrizes de coocorrência (ou estatísticas de segunda ordem) levam em consideração não apenas os *pixels* da imagem mas também seu inter-relacionamento.

Com objetivo de diminuir o custo computacional uma redução nos níveis de cinza é realizada. Transformam-se os 256 níveis originais da imagem $f(x, y)$ em apenas 16 níveis. Após este pré-processamento calcula-se a versão não simétrica de $h_{d\theta}(i, j)$ a partir de $f(x, y)$ para 2 distâncias $d = 1, 2$ e 4 ângulos $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$, totalizando assim 8 matrizes. Obtêm-se então $p_{d\theta}(i, j)$ a partir da divisão de cada $h_{d\theta}(i, j)$ pelo número total de pixels vizinhos $R(d, \theta)$. Sobre matrizes de coocorrência $p_{d\theta}(i, j)$ obtidas, características de energia, entropia e correlação são calculadas pelas equações 3.23, 3.28 e 3.24 respectivamente.

O vetor de características $\mathbf{x}$ fica então composto por 32 variáveis (8 matrizes x 3 características cada) independentes entre si da seguinte forma:

$$\mathbf{x} = [H(p_{1,0^\circ}), E(p_{1,0^\circ}), C(p_{1,0^\circ}), H(p_{1,45^\circ}), \dots, H(p_{2,0^\circ}), \dots, C(p_{2,135^\circ})] \quad (5.10)$$

Este processo pode ser melhor entendido observando-se a Figura 5.8.

Figura 5.8: Processo de extração das características de segunda ordem.

5.3.3 Fourier

Os descritores de Fourier são muito conhecidos e utilizados em análise de textura [39]. Há na literatura muitas variações e implementações diferentes deste método. Na presente pesquisa utilizaremos suas formas mais tradicionais, aquelas efetuadas por meio da análise dos componentes radiais e radiais/angulares do espectro de potência (i.e., analisando a soma das componentes do espectro ao longo de determinado raio e de determinada raio/direção).

Dada a imagem $f(x, y)$, a transformada de Fourier $F(u, v)$ é obtida pela equação 3.36 e conseqüentemente seu espectro de potência pode ser calculado pela equação 3.40. Para solucionar problemas de intensidade das imagens o espectro de potência é normalizado pela componente $F(0, 0)$ e esta então é eliminada do espectro. A partir deste ponto obtêm-se o elemento básico da textura através de duas diferentes análises:

1. Análise de componentes radiais: consiste na soma das componentes para diferentes raios (equação 3.42). No caso discreto, para uma imagem $N \times N$, R é determinado como sendo $N/2 - 1$. As R energias E_r obtidas são então chamadas de descritores de Fourier.

O vetor de características $\mathbf{x}$ para imagens de 128×128 fica então composto por 63 variáveis independentes entre si da seguinte forma:

$$\mathbf{x} = [E_1, E_2, \dots, E_{63}] \quad (5.11)$$

Este processo pode ser melhor entendido observando-se a Figura 5.9.

Figura 5.9: Processo de extração das características de Fourier (componentes radiais)

2. Análise de componentes radiais/angulares: consiste na soma das componentes para diferentes raios (equação 3.42) e diferentes ângulos (equação 3.41). Optou-se aqui pela utilização de 8 frequências radiais (5, 10, 15, 20, 30, 40, 50, 60] e 8 setores orientados com ângulos de (0°, 45°, 90°, 135°, 180°, 225°, 270°, 315°). As 64 energias obtidas (8 frequências $\times$ 8 orientações) são então chamadas de descritores de Fourier.

O vetor de características $\mathbf{x}$ para imagens de 128×128 fica então composto por 64 variáveis independentes entre si da seguinte forma:

$$\mathbf{x} = [E_1, E_2, \dots, E_{64}] \quad (5.12)$$

Este processo pode ser melhor entendido observando-se a Figura 5.10.

Figura 5.10: Processo de extração das características de Fourier (componentes radiais/angulares).

5.3.4 Gabor Wavelets

A não ortogonalidade dos filtros de Gabor wavelets resulta na presença de informações redundantes em seus descritores. Desta forma, a metodologia proposta por [66] foi à escolhida por sua capacidade de solucionar este problema. A partir da definição do número de rotações K , escalas S e intervalos de frequências U_h, U_l cria-se um conjunto de filtros de Gabor wavelets constituído por KS filtros de simetria par (modulados por uma função cosseno, conforme exemplo na Figura 3.3(a)). A escolha da parte real dos filtros de Gabor wavelets (simetria par) está fundamentada no trabalho [64]. Assim sendo, cada filtro é definido por $g_{mn}(x, y)$ onde $m = 1, 2, \dots, K$, $n = 1, 2, \dots, S$ e seus sigmas (σ_u, σ_v) e por conseguinte (σ_x, σ_y) são definidos numericamente pela equação 3.49.

Sendo $f(x, y)$ a imagem de em análise e $g_{mn}(x, y)$ o filtro de Gabor wavelets com rotação m e escala n , o vetor de características é obtido pela convolução dos mn -ésimos filtros com a imagem, conforme mostra a equação abaixo.

$$r_{mn}(x, y) = f(x, y) * g_{mn}(x, y) \quad (5.13)$$

Sendo $r_{mn}(x, y)$ a imagem filtrada pelo filtro de Gabor wavelets com rotação m e escala n e $R_{mn}(u, v)$ sua transformada no domínio de Fourier, o descritor E_{mn} é obtido pelo cálculo da energia da mn -ésima imagem filtrada, definida por:

$$E_{mn} = \sum_{x,y} [r_{mn}(x, y)]^2 = \frac{1}{pq} \sum_{u,v} |R_{mn}(u, v)|^2 \quad (5.14)$$

onde E é a energia, p e q são as dimensões da imagem, r e R são a imagem no domínio do espaço e da frequência respectivamente.

Dessa maneira, o vetor de características $\mathbf{x}$ é constituído pelas energias resultantes de cada imagem filtrada. Sendo K o número total de rotações e S o número total de escalas, a composição de $\mathbf{x}$ é obtida pela seguinte equação:

$$\mathbf{x} = [E_{00}, E_{01}, \dots, E_{10}, E_{11}, \dots, E_{KS}] \quad (5.15)$$

Este processo pode ser melhor entendido observando-se a Figura 5.11.

Figura 5.11: Processo de extração das características por filtros de Gabor wavelets.

5.3.5 Fractais

A teoria dos fractais é muito conhecida na análise de formas, porém, em análise de texturas, mesmo havendo várias implementações para tal objetivo, ainda é pouco utilizada. Na presente pesquisa utilizaremos a análise da DF fractal para texturas por duas novas técnicas, a de Bouligand-Minkowski volumétrica e Bouligand-Minkowski volumétrica multiespectral. Este método foi desenvolvido neste mestrado [7], destinado para aplicação em análise de texturas de superfícies foliares.

1. Bouligand-Minkowski volumétrica:

Dada a imagem $f(x, y)$ e sua representação em 3-dimensional, onde (x, y) denota a posição 2D e a terceira coordenada (z) denotando a intensidade do pixel realiza-se a dilatação das esferas até r_{max} estimando-se a cada passo o valor de $V(r)$.

No método de estimação da dimensão fractal por Bouligand-Minkowski volumétrica a disposição dos pontos de interesse altera o este processo de dilatação. À medida que o valor de r cresce, as esferas produzidas pelos diferentes pontos da superfície S começam a interagir umas com as outras. Esta interação altera (causa efeitos) no valor de $V(r)$, ou seja, no volume de influência calculado para um determinado raio. Essa característica possibilita a percepção de alterações no padrão da textura, visto que diferentes texturas apresentam diferenças na organização de seus pixels.

Desta forma cada padrão produz um crescimento de $V(r)$ característico para aquela determinada textura. Isto torna possível o uso dos os valores de $V(r)$ como descritores de textura uma vez que $V(r)$ descreve, indiretamente, a organização dos pixels e, conseqüentemente, a complexidade da textura.

Desta forma, o vetor de características $\mathbf{x}$ consiste na concatenação do logaritmo do volume de influência $V(r)$ calculado para todos os valores de $r \in E$, onde E é o conjunto das distâncias Euclidianas para um determinado r_{max} :

$$E = \{1, \sqrt{2}, \sqrt{3}, \dots, r_{max}\} \quad (5.16)$$

$$\mathbf{x} = [\log V(1), \log V(\sqrt{2}), \log V(\sqrt{3}), \dots, \log V(r_{max})] \quad (5.17)$$

Note que o valor $V(r)$ quando $r = 0$ não é considerado no conjunto de descritores. Uma vez que este valor corresponde ao número de pontos da superfície da imagem. Para imagens de igual tamanho ele não possui relevância, já para imagens de diferentes tamanhos este pode ser utilizado como fator normalizador.

O uso de diferentes valores de r permite o estudo da complexidade da textura em diferentes escalas. Neste contexto características de macro e micro textura estão implicitamente presentes nos descritores.

Este processo pode ser melhor entendido observando-se a Figura 5.12.

Figura 5.12: Processo de extração das características por DF de Bouligand-Minkowski volumétrica [7].

2. DF volumétrica multiespectral:

Também desenvolvido neste mestrado [21], o processo de extração de características via DF volumétrica multiespectral é semelhante ao apresentado acima. Diferenciando-se apenas na representação da imagem em S . Dada a imagem $f(x, y)$, sua superfície 3-dimensional $S(x, y, z)$ é obtida considerando cada banda de cor como uma superfície, ou seja, para cada par (x, y) que denotam as coordenadas da imagem, há 3 pontos z denotando a intensidade da cor para cada banda. Realiza-se assim a dilatação das esferas até r_{max} , estimando-se a cada passo o valor de $V(r)$.

Assim, de forma semelhante a DF volumétrica, o vetor de características $\mathbf{x}$ fica então composto da seguinte forma:

$$\mathbf{x} = [\log V(1), \log V(\sqrt{2}), \log V(\sqrt{3}), \dots, \log V(r_{max})] \quad (5.18)$$

Este processo pode ser melhor entendido observando-se a Figura 5.13.

Em ambos os casos (DF volumétrica e DF volumétrica multiespectral) utilizou-se vários valores de r_{max} para composição do vetor de características. O objetivo é determinar até que ponto a dilatação contribui com informações relevantes para classificação das texturas foliares.

5.3.6 Momentos de Cromaticidade

Os momentos de cromaticidade, derivados do diagrama de cromaticidade (momentos do tipo T) e de sua distribuição bidimensional (i.e histograma ou momentos do tipo D) são dados,

Figura 5.13: Processo de extração das características por DF de Bouligand-Minkowski volumétrica multispectral.

respectivamente, pelas equações 3.64 e 3.65. Utilizou-se, em ambos os tipos, valores de m e l sugeridos por [74], ou seja, $m = 0, 1, 2, \dots, 6$ e $l = 0, 1, 2, \dots, 6$.

O vetor de características $\mathbf{x}$ fica então composto por 6 variáveis independentes entre si da seguinte forma:

$$\mathbf{x} = [M_T(0, 0), M_T(0, 1), \dots, M_T(1, 0), M_T(1, 1), \dots, M_T(6, 6), M_D(0, 0), \dots, M_D(6, 6)] \quad (5.19)$$

Este processo pode ser melhor entendido observando-se a Figura 5.14.

Figura 5.14: Processo de extração das características derivadas dos momentos de cromaticidade.

5.3.7 Descritores de Cor Baseados na Estrutura Espacial

As características de cor derivados de sua respectiva estrutura espacial são obtidas pela aplicação de um conjunto de filtros de Gabor em cada canal $\tilde{E}$, $\tilde{E}_\lambda$ e $\tilde{E}_{\lambda\lambda}$ dados pela transformação de cada pixel RGB em $f(x, y)$ pela equação 3.68, obtendo-se assim $\hat{f}(x, y)$.

Dessa maneira, o vetor de características $\mathbf{x}$ é constituído pelas energias resultantes de cada banda de cada imagem filtrada. Sendo K o número total de rotações e S o número total de escalas utilizadas no filtro de gabor, a composição de $\mathbf{x}$ é obtida pela seguinte equação:

$$\mathbf{x} = [E_{00}, E_{01}, \dots, E_{10}, E_{11}, \dots, E_{KS}] \quad (5.20)$$

Este processo pode ser melhor entendido observando-se a Figura 5.15.

Figura 5.15: Processo de extração dos descritores de cor baseados na estrutura espacial.

5.3.8 Descritores de Cor Baseados na Estrutura Espacial por Análise de DF

O método anterior analisa a imagem a partir integração da dimensão espacial (filtros de Gabor wavelets) e do comprimento de onda emitidos pela luz (dados pela transformação das bandas RGB nos subespaços). Uma nova proposta é caracterizar a estrutura espacial não por filtros de Gabor e sim através de uma técnica de DF. Esta alternativa justifica-se pelo fato de que nem sempre abordagens espectrais de análise de textura (i.e. filtros de Gabor) obtêm sucesso na caracterização de texturas naturais que exibem padrões randômicos, de estrutura não periódica, porém persistentes, como é o caso das texturas foliares.

Assim, a idéia é analisar cada subespaço $\tilde{E}$, $\tilde{E}_\lambda$ e $\tilde{E}_{\lambda\lambda}$ pela técnica de DF Bouligand-Minkowski volumétrica. Esses subespaços e/ou bandas de $\hat{f}(x, y)$ são dados pela transformação de cada pixel RGB em $f(x, y)$ pela equação 3.68. Dessa maneira, o vetor de características $\mathbf{x}$ é constituído pelos volumes de influência $V(r)$, a um dado $r_{\max}$, de cada subespaço/banda da imagem $\hat{f}(x, y)$ obtida.

Assim, de forma semelhante a DF volumétrica, o vetor de características $\mathbf{x}$ fica então composto da seguinte forma:

$$\mathbf{x} = [\log V_{\tilde{E}}(1), \log V_{\tilde{E}}(\sqrt{2}), \dots, \log V_{\tilde{E}}(r_{max}), \dots, \log V_{\tilde{E}_{\lambda}}(r_{max}), \dots, \log V_{\tilde{E}_{\lambda\lambda}}(r_{max})] \quad (5.21)$$

Este processo pode ser melhor entendido observando-se a Figura 5.16.

Figura 5.16: Processo de extração dos descritores de cor baseados na estrutura espacial por análise de DF Bouligand-Minkowski volumétrica.

5.4 Classificação

Uma vez obtidos os vetores de características é necessário avaliar qual destes promove uma melhor qualidade na identificação de espécies vegetais por meio da textura foliar. Também é necessário avaliar qual classificador melhor adapta-se ao problema em questão. Neste sentido, duas etapas de avaliação foram adotadas, sendo (ver também Figura 5.17):

1. Avaliação da qualidade da função discriminante obtida, onde como resultado seleciona-se os M melhores métodos de extração de características;

2. Utilizando-se dos vetores de características advindos dos M métodos, avalia-se qual classificador melhor adapta-se ao problema em questão.

Figura 5.17: Etapas envolvidas no processo de avaliação dos métodos e dos classificadores

Em ambas as etapas e nos diversos classificadores empregados utilizou-se o método de validação cruzada K-fold com 10 folds ($K = 10$) (Ver seção 4.5) como procedimento para se estimar a probabilidade de classificações incorretas. A seguir são apresentados os procedimentos de avaliação e configurações adotadas para cada método de classificação utilizado.

5.4.1 Avaliação da Qualidade da Função Discriminante Obtida

Com objetivo de avaliar qual método obteria os melhores resultados, utilizou-se o classificador LDA isoladamente para cada método de extração de características. O classificador LDA possibilita a análise individual para cada janela textural, porém, como mostrado anteriormente, cada amostra/folha é caracterizada não por uma, mas por w' janelas texturais, sendo que nem todas as janelas são classificadas corretamente. Assim, há a necessidade de combinar essas informações como forma de melhor descrever a folha. De modo a contornar esse problema, a média das probabilidades *a posteriori* de uma determinada amostra foi calculada utilizando-se as w' janelas texturais, e a amostra foi então atribuída à classe com maior probabilidade média *a posteriori* (maior grau de confiança). Assim sendo para cada método de análise de textura são apresentados 2 resultados sendo:

1. Classificação direta das janelas texturais (tipo 1);
2. Classificação das amostral/folha (tipo 2): considerando a média das probabilidades *a posteriori* das w' janelas texturais pertencentes à mesma amostra/folha j . Sendo portanto, $f_j(\mathbf{y})$ a função densidade da população $j, j = 1, 2, \dots, g$, classifica-se o elemento amostral naquela população k , tal que:

$$f_k(\mathbf{y}) = \arg \max \{f_j(\mathbf{y}), j = 1, 2, \dots, g\} \quad (5.22)$$

sendo:

$$f_j(\mathbf{y}) = \frac{1}{w'} \sum_{i=1}^{w'} f_i(\mathbf{x}) \forall x \in y \quad (5.23)$$

onde $f_j(\mathbf{y})$ denota a probabilidade *a posteriori* média da amostra j e y representa o conjunto de janelas texturais pertencentes a uma mesma folha j . Com esse procedimento, continua-se a atribuir o objeto ao grupo com probabilidade condicional mais elevada ($f_k(\mathbf{y})$), porém agora considerando-se várias janelas texturais para o cálculo desta.

Após a construção da função discriminante via LDA, é necessário avaliar a sua qualidade. Esta avaliação de qualidade é obtida, basicamente, por meio da (1) matriz de confusão e das variáveis de (2) probabilidade de acerto global, (3) erros de omissão e comissão, (4) índice *Kappa* e (5) confiança do classificador.

1. A matriz de confusão é quadrada e de dimensão igual ao número de classes avaliadas. Os resultados da classificação são colocados nas colunas da matriz, sendo que nas linhas correspondentes a diagonal principal coloca-se o número de observações classificadas corretamente e nas demais linhas o número de observações omitidas de cada classe.
2. Para avaliação do desempenho global sobre a totalidade das classes também pode ser usada a precisão global (ou probabilidade de acerto global) PG . O índice de precisão global é um parâmetro estatístico simples, derivado da matriz de confusão, que é dado pela divisão da soma dos valores da diagonal principal dessa matriz pela quantidade total de amostras usadas para o cálculo da mesma. Dada a matriz de confusão M , a PG pode ser calculada por:

$$PG = \frac{\sum_{i=1}^r m_{ii}}{n} \quad (5.24)$$

onde r é o número de linhas e colunas na matriz de confusão, m_{ii} é a contagem das observações na linha i e coluna i e n é o número total de observações.

3. Também é recomendável estimar as probabilidades de ocorrência dos erros do tipo 1 (omissão) e 2 (comissão) de classificações incorretas separadamente, e não apenas a probabilidade de acerto global da regra. É possível, por exemplo, ter uma função discriminante com alta probabilidade de acerto global, mas apresentando uma probabilidade alta

em algum dos erros parciais dos tipos 1 ou 2. Isso permitirá que se faça uma avaliação da qualidade da função em termos de erros de classificação e capacidade de discriminação.

- Erro tipo 1 (omissão): o elemento amostral pertence à população/classe k , mas a regra de classificação o classifica como sendo proveniente de uma população j ; onde $j, k = 1, 2, \dots, g$ sendo $k \neq j$.
- Erro tipo 2 (comissão): o elemento amostral pertence a qualquer população j , mas a regra de classificação o classifica como sendo proveniente da população k .

Quanto menor forem estas probabilidades, melhor será a função de discriminação. Os resultados destas probabilidades serão apresentados juntamente com a matriz de confusão onde a última coluna demonstra os erros de omissão (OM) para aquela classe (Erro 1) e a última linha demonstra os erros de comissão (CO) em uma determina classe (Erro 2). Os índices de omissão e comissão são dados respectivamente pelas equações 5.25 e 5.26.

$$OM_i = \frac{m_{i+} - m_{ii}}{m_{i+}} \quad (5.25)$$

$$CO_i = \frac{m_{+i} - m_{ii}}{m_{+i}} \quad (5.26)$$

onde m_{i+} é a soma da i -ésima linha, m_{+i} é a soma da i -ésima coluna.

4. Além da precisão global, erros tipo 1 e 2 também é utiliza-se o índice Kappa para avaliar a concordância entre a classificação e a verdade [27]. O índice Kappa trata-se de um índice consagrado na comunidade acadêmica para avaliar o grau de desempenho de uma regra de decisão qualquer quanto a sua exatidão. Muito utilizado em classificação de imagens de satélite, este índice também pode ser utilizado na avaliação de outros classificadores, pois, os dados da matriz de erros são discretos e com distribuição multinomial [27]. Os valores desse índice são inferiores aos valores de precisão global pois traduzem o ganho de precisão relativo a uma distribuição aleatória dos indivíduos pelas classes. O índice Kappa é dado por:

$$\hat{K} = \frac{\theta_1 - \theta_2}{1 - \theta_2} \quad (5.27)$$

onde

$$\theta_1 = \sum_{i=1}^r \frac{m_{ii}}{n} \quad (5.28)$$

e

$$\theta_2 = \sum_{i=1}^r \frac{m_{i+}m_{+i}}{n^2} \quad (5.29)$$

5. O classificador LDA também apresenta como resultado a probabilidade *a posteriori* ($f_i(\mathbf{x})$) para cada janela textural ($f_j(\mathbf{x})$) no caso de análise das amostras/folhas (ver Seção 5.4). É possível utilizar-se da média dessas probabilidades, para os padrões corretamente classificados, como forma de atestar a qualidade da regra de classificação obtida, e/ou *grau de confiança* de que o padrão pertença a sua classe.

5.4.2 Classificação Utilizando Redução de Dimensionalidade dos Dados

Embora individualmente cada método possa alcançar bons resultados, Jain and Zongker [51] em seu trabalho mostram que, a combinação de características (i.e. concatenação) advindas de diferentes técnicas de análise de texturas pode conduzir para uma maior precisão na tarefa de classificação quando comparado com o resultado de cada método individualmente.

Entretanto, combinar muitas características traz o conhecido problema do *mau da dimensionalidade*. A solução para isso é utilizar técnicas para redução da dimensionalidade dos dados. A técnica de dois passos PCA+LDA [12, 97] é um dos métodos mais convencionalmente utilizados para resolver este problema.

Nesta técnica um passo intermediário utilizando a técnica de PCA é realizado seguindo-se pela aplicação do método de classificação LDA sobre o subespaço gerado. Entretanto não se utiliza, para fins de classificação, todos os escores numéricos gerados pelo método PCA, e sim apenas k -componentes principais que representam o sistema de variabilidade do vetor características.

Assim sendo, aplica-se a técnica de análise de componentes principais para cada método de análise de textura e concatenam-se os escores numéricos resultantes para formar o novo vetor de características a ser utilizado na classificação. Sendo os vetores de características para os M métodos de análise de textura denotados como $\mathbf{x}_i, i = 1, \dots, M$, e sendo $\mathbf{y}_i = \hat{Y}_j, j = 1, 2, \dots, k$ o vetor com as k componentes principais mais relevantes (com variância total explicada igual ou superior a 99%) de um dado vetor aleatório $\mathbf{x}_i$. O novo vetor $\hat{\mathbf{x}}$ a ser utilizado como entrada para o classificador fica assim definido:

$$\hat{\mathbf{x}} = [\mathbf{y}_1, \mathbf{y}_2, \mathbf{y}_3, \dots, \mathbf{y}_M] \quad (5.30)$$

A definição da forma de combinação, e do número M de métodos concatenados para formação no novo vetor, irá depender dos resultados individuais de cada técnica.

5.4.3 Classificação por Comitê de Máquinas

O modelo de classificação via LDA oferece boa interpretabilidade, todavia sua precisão não é das mais eficientes, em particular para amplos conjuntos de dados [1]. Modelos de classificação mais complexos são conhecidos na literatura, dentre estes podemos citar o comitê de máquinas [44, 1]. Esse modelo consiste em um conjunto de componentes (classificadores), cada um representando uma proposta de solução, cujas classificações combinadas de formas diversas visando um ganho de desempenho.

O objetivo então é encontrar classificadores de bom desempenho e que generalizam de forma descorrelacionada. Modificação dos parâmetros e aspectos estruturais do classificador, e técnicas de re-amostragem de dados, como Bagging e Boosting, são amplamente utilizados para tal. Desafortunadamente, os métodos de re-amostragem de dados não conduzem a melhorias na qualidade de classificação via análise discriminante linear (LDA) [32]. Pesquisas mostram que, um comitê de máquinas composto por classificadores LDA e utilizando boosting para re-amostragem de dados fornece resultados similares ou inferiores a um classificador LDA simples [63]. Isso se deve ao fato de que os componentes LDA treinados com utilização de boosting são bastante similares. Também há de se considerar o fato de que o modelo LDA não possui parâmetros, não sendo possível assim construir componentes descorrelacionados por tal artifício.

Afortunadamente, o modelo LDA é sensível as variáveis de entrada. Desta forma, a utilização de modelos LDA como componentes para comitê de máquinas é possível, uma vez que a diversidade é alcançada pela utilização de variáveis distintas no treinamento de cada componente, gerando assim classificadores diversos e efetivos, e com, possivelmente, erros descorrelacionados. Interessantemente, essa abordagem tira proveito da alta dimensionalidade dos dados.

A idéia é alcançar a diversidade dos classificadores pela utilização de características advindas de diferentes métodos de análise de textura. O comitê de máquinas fica então composto por M classificadores, cada qual treinado com um subconjunto de descritores diferentes. A combinação dos componentes é realizada por média ponderada (equação 4.15, onde se considera o desempenho relativo dos componentes a serem combinados).

5.4.4 Classificação por Redes Neurais

O método de Redes Neurais Artificiais é bem conhecido e utilizado na literatura. Diversos trabalhos o utilizam o modelo perceptron multicamadas como classificador. Porém não há uma estrutura padrão, sendo que configuração do número de camadas, algoritmo de aprendizado e demais parâmetros utilizados são muitas vezes dependentes da aplicação.

Neste trabalho utilizou-se uma rede feed-forward com uma camada de entrada, duas camadas ocultas e uma camada de saída. A camada de entrada é composta por x neurônios, onde x é igual ao número de características utilizadas. A primeira camada oculta é composta por x^2 neurônios. A segunda camada oculta e a camada de saída são compostas por k neurônios cada, sendo k o número de padrões a serem identificados. Todos os neurônios em todas as camadas utilizam função de ativação sigmoideal. O algoritmo de aprendizado empregado é uma variação back-propagation conhecido como *Scaled Conjugate Gradient* [69], esse algoritmo é indicado para treinamento de redes com grande número de neurônios.

O critério de parada adotado foi 2000 ciclos de treinamento ou quando soma dos erros quadráticos de todos os padrões apresentados seja menor ou igual a 0.005. Utiliza-se nos experimentos as k componentes principais dos M métodos escolhidos como características de entrada (com variância total explicada igual ou superior a 99%). Adicionalmente normaliza-se esse vetor para que o mesmo possua média zero e desvio padrão unitário.

Experimentos e Resultados

Neste capítulo são apresentados e discutidos os experimentos realizados para identificação das espécies vegetais. Os experimentos foram divididos em três grupos principais: (1) assertões sobre o processo de aquisição da base de dados e pré-processamento, incluindo a descarte de *outliers*, (2) comparação dos métodos de extração de características, onde é apresentada a potencialidade desses métodos na identificação vegetal e (3) comparação dos métodos de classificação empregados neste projeto.

6.1 Base de Imagens

As imagens de folhas utilizadas foram coletadas pelo procedimento descrito em 5.1 *in vivo* no Campus da USP - São Carlos. A Figura 6.1 mostra um exemplar de cada espécie vegetal utilizada nos experimentos.

Foram coletadas um total de 800 amostras, divididas em 40 classes¹ (aqui denominadas de $C01, C02, C03, \dots, C40$), totalizando assim 20 exemplares/amostras por classe de frente e 20 de verso. A Figura 6.2 mostra as diferentes texturas encontradas em cada uma das espécies utilizadas (destaque para a alta similaridade entre classes, enquanto as Figuras 6.3, 6.4, 6.5, 6.6 e 6.7 mostram a variabilidade de texturas encontradas dentro de uma mesma espécie (similaridade intraclasses não adequada). É interessante notar neste ponto que o processo de aquisição foliar não é perfeito. Ou seja, a presença de sujeiras da folha ou do próprio vidro do digitalizador pode acarretar na presença de ruídos na imagem final. É oportuno considerar também o fato de

¹será empregado o termo *classe* computacional como equivalente ao termo *espécie* na taxonomia, ou seja, uma classe representa, computacionalmente, um conjunto de folhas de uma mesma espécie

Figura 6.1: 40 classes utilizadas nos experimentos.

Figura 6.2: Um exemplo de textura apresentado por cada uma das 40 espécies que compõe a base de dados.

Figura 6.3: Cinco exemplos de textura da classe/espécime C01.

Figura 6.4: Cinco exemplos de textura da classe/espécime C02.

Figura 6.5: Cinco exemplos de textura da classe/espécime C20.

Figura 6.6: Cinco exemplos de textura da classe/espécime C22.

Figura 6.7: Cinco exemplos de textura da classe/espécime C32.

que a digitalização de uma superfície 3D(folha) para 2D(imagem) implica no aparecimento de sombras e/ou sobreposições.

6.2 Análise e Discussão dos Resultados

A fase de aquisição (apesar de demandar uma grande quantidade de tempo) e a fase de segmentação ocorreram de forma normal sem maiores problemas. Nenhuma amostra precisou ser suprimida da base de dados por falta de qualidade e/ou outros motivos, assim como nenhuma amostra necessitou de interferência manual para que houvesse uma segmentação de forma satisfatória. Estes fatos demonstram que a aquisição de texturas foliares por digitalização com *scanner* é um bom método uma vez que possui resolução e iluminação controlada.

Para a extração das texturas utilizou-se uma janela de tamanho 128×128 como valor padrão. Verificou-se que, para a resolução utilizada, tamanhos de janelas superiores tornam-se impraticáveis devido ao tamanho reduzido de algumas amostras/folhas e também por alguns métodos de análise de textura serem bastante custosos computacionalmente quando empregados em imagens maiores. O número de janelas texturais extraídas foi de 50 ($w = 50$). Valores acima e abaixo deste foram utilizados porém, não houveram melhoras significativas na amostragem obtida.

A extração das janelas texturais sem sobreposição habilita a obtenção de uma quantidade amostral estatisticamente significativa e com razoável qualidade uma vez que há amostragem de todas as posições foliares. Em algumas classes porém, foi necessário eliminar-se essa restrição devido ao tamanho reduzido da folha/amostra, resultando assim que algumas janelas texturais contêm repetição parcial do padrão textural.

Na fase descarte das janelas texturais definiu-se $w' = 10$ uma vez que este número de janelas apresenta uma boa disposição sobre a amostra/folha cobrindo áreas diversas. O resultado foi uma boa qualidade e quantidade amostral sem presença de ruídos.

A próxima etapa era descartar possíveis amostras que apresentem um padrão incomum para aquela determinada classe. Para isso utilizou-se o teste de Grubb's com nível de significância $\alpha = 0,025$ para descarte de possíveis outliers amostrais. Desta forma, foram encontrados 38 outliers na base de imagens, divididos entre as classes conforme Tabela 6.1.

Podemos perceber que as classes C15, C17, C24, C25 são as que apresentam maior número de outliers, três cada. A Figura 6.8 ilustra as algumas janelas texturais das amostras 05 e 11 (texturas inferiores) da classe C17 descartadas da base de dados em comparação com algumas janelas texturais de várias amostras consideradas normais (texturas superiores).

Desta forma a base de dados originalmente composta por 8000 janelas texturais de 800 amostras fica com 762 amostras (7620 janelas texturais).

Classe	Nro de outliers	Classe	Nro de outliers	Classe	Nro de outliers	Classe	Nro de outliers
C01	1	C11	1	C21	0	C31	0
C02	1	C12	1	C22	0	C32	1
C03	0	C13	2	C23	1	C33	2
C04	0	C14	0	C24	3	C34	1
C05	0	C15	3	C25	3	C35	1
C06	0	C16	0	C26	1	C36	1
C07	2	C17	3	C27	1	C37	2
C08	0	C18	0	C28	0	C38	1
C09	1	C19	1	C29	2	C39	0
C10	0	C20	1	C30	0	C40	1

Tabela 6.1: Número de outliers encontrados em cada classe respectivamente

Figura 6.8: Acima: texturas consideradas normais de diversas amostras da classe *C17*.
Abaixo: texturas designadas como outliers através do teste de Grubb's com nível de significância $\alpha = 0.025$.

6.2.1 Avaliação da Qualidade dos Métodos de Análise de Textura

A seguir apresenta-se, para cada método de análise de textura, a matriz de confusão com os respectivos erros de omissão e comissão e as tabelas de resultado sumarizando o número de descritores utilizados, número de padrões corretamente classificados, probabilidade de acerto global, índice Kappa, erro máximo e grau de confiança para cada método.

6.2.1.1 Resultado Características de Primeira Ordem

Os resultados da Tabela 6.2 mostram que, para análise de textura foliar, as características de primeira ordem não são muito adequadas, apresentando uma taxa de acerto global baixa (36.12%) e um baixo índice Kappa (0.4776) o que demonstra um baixo ganho de precisão

relativo a uma distribuição aleatória dos indivíduos pelas classes. A baixa probabilidade *a posteriori* (35.53%) para as amostras corretamente classificadas demonstra uma baixa confiança do classificador em atribuir a amostra à classe em questão.

Nota-se que, a utilização de várias janelas texturais para composição de uma probabilidade *a posteriori* média da amostra (classificação tipo 2), auxiliou para elevar o grau de corretude do método (49.08%), porém considera-se ainda um percentual muito baixo.

Classificação Tipo	Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
1	5	2753	36.12	0.3448	99.47 - 1	35.53	30.18
2	5	374	49.08	0.4776	100.0 - 4	25.61	22.11

Tabela 6.2: Sumário da classificação usando LDA sobre descritores de primeira ordem (Base 1 com 7620 janelas texturais / Base 2 com 762 amostras)

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	Co(%)	
1	47.4								10.5	5.3		5.6	15		15		5																						15	5.3	76.6	
2		31.6											5								15	5																			25	
3			65	5													10																						15		30	
4				60				63.2				16.7					5													10											94.8	
5					85			5				5.3			10										11.8		5.3		16.7												54	
6						60																																				
7							44.4					10.5		10		5				5																	16.7				47.2	
8								65								5				15					17.6	15.8	5.3		16.7									5.3	80.6			
9				15									5.6				30																							50.6		
10			5.3						80					5		5					5	5.3							15			15.8		31.6		5.3			5.3	98.4		
11										89.5		5.6	5		15		15											36.8												93.2		
12						10						15.8								20																				30		
13				5				10.5					33.3				5														5		5.3					5.3		36.1		
14					5	5.6						5.3			35.3												15.8										5.6			72.5		
15			5.3					11.1		5				5	47.1	5					5						15.8							5.3						57.4		
16						15						5.3		5		15				5							21.1		5.6							5.6				62.4		
17													11.1			76.5										5.9				5.6									5.3	27.8		
18		5.3		20	20			10.5					5.6				20																					5.3	5	71.6		
19			5.3									5.3						94.7			10															31.6	5.3		5.3	5	15.8	83.4
20				10.5																	94.7		5.3							5			21.1							41.8		
21										38.9			21.1		20	15					45																				105.5	
22						5																15					5.3														10.3	
23													5.6											5.3																	51.9	
24																																									31.1	
25																																									31.1	
26													10.5		5	5.9											5.3											16.7	5	58.3		
27												5.3					10	5.9																						10.5	36.9	
28																																										41.6
29																																										72.2
30														5.6																											21.9	
31																																										88
32																																										5
33																																										10.5
34															5		5	5.9		5.3																					47.2	
35																																										36.1
36																																										75
37													5.3		15	5.9																									51.4	
38																																										47.6
39																																										72.9
40																																										10.6
Om(%)	52.6	68.4	35	40	15	40	55.6	35	100	20	10.5	84.2	66.7	100	52.9	85	23.5	80	5.3	5.3	55	85	26.3	29.4	100	94.7	68.4	65	61.1	20		100	11.1	68.4	26.3	47.4	44.4	42.1	45	73.7	49.1	

Tabela 6.3: Matriz de confusão, com respectivos erros de omissão e comissão, utilizando características de primeira ordem (base com 762 amostras).

Pela matriz de confusão dada pela Tabela 6.3 podemos observar muitas classes com elevado erro de omissão (C09, C14, C25, C26, C32, etc), sendo que apenas uma classe obteve 100% de acerto (C31). Há também, nas classes C04, C10, C11 e C21 principalmente, uma alta tendência

a erros de comissão, ou seja, amostras são atribuídas a estas classes, quando na verdade pertence à outra.

É importante salientar que outras características de primeira ordem, derivados do histograma, foram utilizadas para composição do vetor de características, porém não contribuíram para a melhora do resultado.

6.2.1.2 Resultado Matrizes de Coocorrência

A Tabela 6.4 exibe os resultados alcançados com o uso das matrizes de coocorrência. Os bons resultados de acerto global alcançados (57.28% e 79.52% para a segunda estratégia de classificação) e os baixos erros máximos apresentados em diversas classes (e.g. C12, C14, C16, C32) mostram que a técnica é robusta (i.e. há uma boa discriminação de todas as classes). Também pela matriz de confusão dada pela Tabela 6.5 podemos observar 3 classes com alto erro de comissão (C08, C22, C34), e 10 classes com 100% de acerto (C03, C04, C06, C11, C15, C17, C19, C23, C24, C33). Considera-se que a regra de classificação obtida por esses descritores é satisfatória uma vez que as probabilidades *a posteriori* dos erros e acertos indicam uma boa separabilidade entre as classes, em especial para a segunda estratégia de classificação.

Classificação Tipo	Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
1	32	4365	57.28	0.5619	77.50 - 1	77.69	60.37
2	32	606	79.52	0.7900	75.00 - 1	57.29	27.89

Tabela 6.4: Sumário da classificação usando LDA sobre descritores de coocorrência.

Testes foram realizados com versão simétrica da técnica e outros valores de distâncias e ângulos, porém nenhuma destas estratégias trouxe melhoras significativas. Uma redução maior na quantidade dos níveis de cinza (e.g. 8 níveis) piorou os resultados, enquanto um número maior de níveis de cinza (e.g. 32 e/ou 64 níveis) deixou o processo com custo computacional muito elevado.

Apenas as características de energia, entropia e correlação mostraram-se interessantes para o resultado final. As demais características propostas por [43] foram testadas, mas não contribuíram para melhora dos resultados.

6.2.1.3 Resultado Descritores de Fourier

A análise de textura pelos descritores de Fourier via componentes radiais apresenta resultados regulares, com uma probabilidade de acerto global de 58.41%, para classificação direta das janelas texturais, e de 78.08% para classificação das amostral/folha (Tabela 6.6). Um ponto importante é o aumento de quase 20 pontos percentuais quando da classificação amostral/folhas (tipo 2), é também notável a diminuição da confiança dos erros, demonstrando que algumas informações adicionais pode-se classificar essas amostras de maneira correta.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	Co(%)	
1	73.7														15																										15	
2		84.2																			5																				5	
3			100																																							
4				100																																						
5					90																5					17.6			5.6		10										38.2	
6		5.3				100																																			5.3	
7							77.8								5												10.5										22.2	5			42.7	
8					5			95					10.5		25											5.9		5.3											5.3		51.7	
9									84.2																													5.3		5.3		
10										80			10.5						5															5.3			10.5			31.3		
11									5.3		100								5																						20.8	
12												47.4																5.3													5.3	
13													77.8					5				5								5										15		
14							5							40	25							5				5.9															40.9	
15										5						100																									5	
16														10	25												5.9	10.5		5.6											32	
17														5.6		100											5.9			16.7									5.3	33.4		
18	5.3												11.1				80																5.3								21.6	
19		5.3																100																							20.8	
20																				89.5																					10.5	
21																					70						5.9	5.3				5									26.1	
22																						85																		21.1		
23																																									63.3	
24																																									21.1	
25																																									5.3	
26																						10	5				52.9														30	
27																																									42.2	
28																																									5.6	
29																																									31.6	
30																																										

Tabela 6.5: Matriz de confusão, com respectivos erros de omissão e comissão, utilizando características de coocorrência (base com 762 amostras).

A matriz de confusão (Tabela 6.7) apresenta as classes C12, C16 e C26 como as que obtiveram maiores erros de omissão (84.2%, 70% e 78.9% respectivamente). As demais classes com erro não superior à 43%. Isso demonstra que os descritores de Fourier possuem uma boa robustez, sendo capaz de classificar bem quase que a totalidade das classes envolvidas nos testes. Há também de se salientar as 6 classes com 100% de acerto (C03, C05, C08, C23, C24, C33) e as classes C07 e C17 com os maiores erros de comissão.

A utilização dos descritores de Fourier via componentes radiais/angulares apresenta resultados superiores (ganho de aproximadamente 7 pontos percentuais), frente ao método de Fourier que utiliza apenas as componentes radiais. Sua probabilidade de acerto global de 63.88% (classificação direta das janelas texturais), e conseqüentemente 85.17% para classificação das amos-

Classificação Tipo	Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
1	63	4451	58.41	0.5734	86.31 - 1	58.73	40.80
2	63	595	78.08	0.7752	84.21 - 1	46.07	23.00

Tabela 6.6: Sumário da classificação usando LDA sobre descritores de Fourier por análise de componentes radiais.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	Co(%)	
1	63.2								5.3									10																							15.3	
2		89.5																		10.5												5.3									15.8	
3			100										5.6																							5.3		5.3			16.1	
4				95																																						
5					100											5										17.6						10										32.6
6						90					10		15.8														5.3							5.3			11.1	10			57.4	
7							5	88.9					26.3	10	10					20							5.3					5	10.5				5.6			97.7		
8	21.1								100				5.3														10.5	10.5													47.4	
9										68.4																											5.3			5.3		
10											85																															
11												5.3	78.9																												5.3	
12		5.3					11.1						15.8															10.5						10.5							37.4	
13										5.3				77.8				15																							20.3	
14															65	30					5					5.3															40.3	
15																	94.1																								5	
16							5											10	30								17.6	15.8										5.6			49	
17																				20	94.1						5.9	5.3	5.6			5						5.3		5.3	84.1	
18	5.3																				60																				15.8	
19																						94.7																			15.8	
20		5.3																																							11.1	
21																																										10.5
22																																										
23																																										
24																																										
25																																										
26																																										
27																																										
28																																										
29																																										
30																																										
31																																										
32																																										
33																																										
34																																										
35																																										

Tabela 6.7: Matriz de confusão, com respectivos erros de omissão e comissão, utilizando descritores de Fourier por análise de componentes radiais.

tral/folha (ver Tabela 6.8), seu alto índice Kappa (0.8479), e seu erro máximo relativamente baixo (57.89% em 2 classes) tornam este método muito atrativo para classificação de folhas através da análise de textura. Outra importante variável é a baixa confiança dos erros (43.06% e 17.11%). Esse resultado demonstra que, o método não afirma que a amostra erroneamente classificada realmente pertence a uma determinada classe, ou seja, apesar de não classificados corretamente não há certeza em relação à classe em que essas amostras foram atribuídas.

Classificação Tipo	Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
1	64	4868	63.88	0.6295	73.15 - 1	65.83	43.06
2	64	649	85.17	0.8479	57.89 - 2	51.85	17.11

Tabela 6.8: Sumário da classificação usando LDA sobre descritores de Fourier por análise de componentes radiais/angulares.

Em sua matriz de confusão (Tabela 6.9) podemos observar 10 classes com 100% de acerto (C03, C05, C07, C11, C15, C19, C23, C24, C33, C35), sendo que destas, 5 classes são coincidentes com os resultados de Fourier com componentes radiais. Embora as classes C12, C16 e C26 apresentem os maiores erros de omissão, observamos uma queda nesses erros se com-

parados com o método anterior. A classe C07 persiste como sendo a classe com maior erro de comissão.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	Co(%)		
1	73.7																10																								10		
2		89.5																		5.3												10.5									15.8		
3			100	10									5.6																												15.6		
4				85																																							
5					100																					5.9			5.6		5											16.4	
6						95	5					10.5																								5.6					21.1		
7							100					31.6		10	25					20						5.3															91.8		
8		5.3						95					5.6															10.5													21.3		
9									78.9																												10.5				10.5		
10										95																																	
11											100																															5.3	
12												5	42.1													5.9	5.3							5.3								21.4	
13													15.8																													20.8	
14														77.8		65	20																								35		
15																	100																									20.8	
16																		10	50							23.5	21.1							5.3								59.8	
17																				5	94.1																					5.3	
18																																											5.3
19																																											
20																																											11.1
21																																											10.3
22																																											
23																																											5.3
24																																											
25																																											5.3
26																																											10.5
27																																											
28																																											5.3
29																																											
30																																											
31																																											
32																																											16.4
33																																											25.8
34																																											10.3
35																																											31.1
36																																											
37																																											15.8
38																																											21.1
39																																											
40																																											
Om(%)	26.3	10.5		15		5		5	21.1	5		57.9	22.2	35		50	5.9	20		5.3	20	10			41.2	57.9	26.3	10	5.6	5	15	42.1		5.3		15.8	5.6	26.3	10	10.5	85.2	20.3	

Tabela 6.9: Matriz de confusão, com respectivos erros de omissão e comissão, utilizando descritores de Fourier por análise de componentes radiais/angulares.

6.2.1.4 Resultado Gabor Wavelets

Para avaliar a melhor configuração do método, diferentes intervalos de frequência e diferentes combinações no número de escalas e rotações foram testados. A Tabela 6.10 apresenta as configurações utilizadas, bem como os resultados alcançados (com objetivo de avaliar e estudar o comportamento dos parâmetros apenas os resultados para classificação tipo 1 são apresentados).

Observamos que, os melhores resultados alcançados ficaram acima de 65% de acerto. Todos obtidos com 64 descritores (8 escalas ($S = 8$) e 8 rotações ($K = 8$)) e frequências variáveis. Observa-se que o aumento do número de filtros em diferentes escalas fornece resultados muito superiores (probabilidade de acerto global com $S = 8 > S = 6 > S = 4$) levando a uma melhor discriminação das texturas apresentadas, sendo que para $S > 8$ os resultados tendem a decair ($S = 10$ com 64.60% de acerto e $S = 12$ com 64.38% de acerto). O aumento do número de

Parâmetros				Número descritores	Nro de imagens corre- tamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
U_l	U_h	S	K							
0.03	0.3	2	4	8	2693	35.34	0.3366	92.35 - 1	33.51	26.67
0.03	0.3	2	6	12	2844	37.32	0.3566	89.44 - 1	37.00	29.40
0.03	0.3	2	8	16	2887	37.88	0.3727	90.55 - 1	39.72	30.78
0.03	0.3	3	4	12	3834	50.31	0.4903	86.31 - 1	48.41	35.76
0.03	0.3	3	6	18	3857	50.61	0.4934	85.78 - 1	50.12	37.20
0.03	0.3	3	8	24	3957	51.92	0.5068	81.57 - 1	52.06	38.14
0.03	0.3	5	4	20	4733	62.11	0.6113	79.47 - 1	60.75	41.83
0.03	0.3	5	6	30	4773	62.63	0.6167	78.94 - 1	62.18	42.76
0.03	0.3	5	8	40	4814	63.17	0.6222	75.26 - 1	63.48	43.83
0.03	0.3	8	4	32	4911	64.44	0.6353	76.31 - 1	65.30	43.51
0.03	0.3	8	6	48	4920	64.56	0.6389	77.89 - 1	66.60	44.59
0.03	0.3	8	8	64	4954	65.01	0.6411	75.78 - 1	67.57	45.97
0.03	0.3	10	8	80	4923	64.60	0.6397	75.26 - 1	68.70	46.18
0.03	0.3	12	8	96	4906	64.38	0.6346	75.78 - 1	68.66	46.88
0.01	0.3	8	8	64	5025	65.94	0.6507	71.57 - 1	67.25	46.20
0.02	0.3	8	8	64	4991	65.49	0.6412	77.89 - 1	67.94	45.60
0.05	0.3	8	8	64	4780	62.72	0.6171	74.73 - 1	66.23	44.99
0.03	0.2	8	8	64	4357	57.17	0.5607	75.26 - 1	59.88	40.32
0.03	0.4	8	8	64	5111	67.07	0.6622	74.00 - 1	72.27	48.59
0.01	0.4	8	8	64	5185	68.04	0.6722	73.68 - 1	72.19	49.37

Tabela 6.10: Sumário da classificação usando LDA sobre filtro de Gabor wavelets.

filtros rotacionados (K) não influencia significativamente a desempenho do sistema, entretanto esse aumento no número de descritores acrescenta em termos da confiabilidade obtida pela probabilidade *a posteriori* e erro máximo obtido.

Uma característica importante apresentada nos resultados é que os diferentes intervalos de frequência interferem, porém não significativamente, nos resultados alcançados. Quando os parâmetros utilizados são abaixo de 0.01 para a frequência inferior U_l , e acima de 0.4 para a frequência superior U_h , estes fazem com que o método adquira características muito semelhantes para diversas classes, não sendo possível calcular a matriz de covariância necessária para o LDA.

O parâmetro S é o mais importante para uma boa discriminação de texturas foliares. Uma possível explicação para esse comportamento é que, no problema em questão, as baixas frequências sejam mais significativas, de modo que uma caracterização, em separado, de diferentes bandas de frequência leva a resultados mais expressivos.

Considerando-se a pequena diferença entre as taxas de acertos alcançadas para diferentes conjuntos de filtros, o melhor vetor de características pode ser escolhido por:

1. Ser computacionalmente viável: utilizar o menor número de características possíveis;
2. Ser robusto: apresentar uma taxa de erro máxima pequena (discriminar bem todas as classes);
3. Ser confiável: possuir uma alta taxa de confiança;

Baseado nesses critérios, a configuração com $S = 8$, $K = 8$, $U_l = 0.01$ e $U_h = 0.4$ com 64 descritores, taxa de acerto de 68.04% e confiança média de 72.14% pode ser escolhido como o

melhor dentre o vasto número de conjunto testados. A Tabela 6.11 apresenta os resultados para as duas estratégias de classificação e a Tabela 6.12 apresenta a matriz de confusão para essa configuração do método.

Classificação Tipo	Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
1	64	5185	68.04	0.6722	73.68 - 1	72.19	49.37
2	64	670	87.92	0.8716	70.00 - 1	58.49	18.01

Tabela 6.11: Sumário da classificação usando LDA sobre descritores de Gabor wavelets.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	Co(%)			
1	84.2																																											
2		94.7																																								5.3		
3			100	5																																						5		
4				90																																								
5					100																																						46.4	
6						100																																					5.3	
7							94.4																																				40.5	
8								5.6	100																																	26.6		
9										100																																	5.3	
10											95																																5.3	
11												100																															5.9	
12													5																														10.9	
13														77.8																													5	
14															70																												5.3	
15																100																											5.3	
16																	10																										60.8	
17																		30																									41.3	
18																			15																								5.3	
19																				90																							26.4	
20																					100																						5.3	
21																						100																					5.3	
22																							75																				5.3	
23																								95																				
24																									100																			
25																										100																		
26																											58.8																5.6	
27																												57.9															5.6	
28																													84.2															
29																														85													5.3	
30																															88.9													
31																																95												
32																																	90										5.3	
33																																		15									20.3	
34																																			5									10.3
35																																												15.5
36																																												
37																																												
38																																												
39																																												
40																																												
Om(%)	15.8	5.3		10			5.6		5			42.1	22.2	30		70	5.9	10		25	5			41.2	42.1	15.8	15	11.1	5	10	26.3			10.5	16.7	15.8	5	15.8		87.9				

Tabela 6.12: Matriz de confusão, com respectivos erros de omissão e comissão, utilizando filtros de Gabor wavelets.

Podemos observar 14 classes com 100% de acerto (C03, C05, C06, C08, C09, C11, C15, C19, C20, C23, C24, C33, C34 e C35). As classes C12, C16, C25 e C26 apresentam erro de omissão acima de 30%. A classe C16 é a que possui um erro de comissão relativamente superior as demais, 60.8%.

6.2.1.5 Resultado Fractais

A dimensão fractal de Bouligand Minkowski volumétrica é um novo método, voltado à análise de texturas, proposto pela primeira vez no âmbito desta dissertação [7]. Neste método o

único parâmetro a ser escolhido é o valor de $r_{\max}$. Com objetivo de determinar até que ponto a dilatação contribui com informações relevantes para classificação das texturas foliares diferentes valores de $r_{\max}$ foram utilizados nos experimentos. Os resultados podem ser visualizados na Tabela 6.13.

Raio	Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
2	4	2360	30.97	0.2919	97.89 - 1	27.77	23.26
3	8	3716	48.77	0.4745	98.00 - 1	55.13	42.90
4	14	4185	54.92	0.5377	93.50 - 1	67.08	50.32
5	22	4630	60.76	0.5976	93.00 - 1	74.93	56.38
6	31	4875	63.98	0.6305	90.00 - 1	78.64	59.95
7	42	4945	64.90	0.6400	88.50 - 1	81.63	62.04
8	54	5024	65.93	0.6506	83.50 - 1	82.98	63.35
9	69	5090	66.80	0.6595	83.00 - 1	84.36	65.03
10	85	5120	67.19	0.6635	84.50 - 1	84.84	65.81
11	102	5153	67.62	0.6680	83.00 - 1	85.49	66.83
12	121	5166	67.80	0.6697	82.50 - 1	85.89	67.23
13	142	5210	68.37	0.6756	79.00 - 1	86.31	67.78
14	165	5160	67.72	0.6689	82.00 - 1	86.89	68.70
15	189	5138	67.43	0.6659	81.50 - 1	87.23	69.01
16	214	5122	67.22	0.6638	81.00 - 1	87.58	69.32
17	242	5090	66.80	0.6595	80.00 - 1	87.90	69.85
18	272	5131	67.34	0.6650	79.50 - 1	87.92	70.38
19	303	5066	66.48	0.6562	82.50 - 1	88.70	70.81
20	335	5047	66.23	0.6537	81.00 - 1	88.48	70.96

Tabela 6.13: Sumário da classificação usando LDA sobre descritores de DF Bouligand-Minkowski volumétrica para diversos raios.

Observa-se uma curva crescente na qualidade do método até utilização do raio $r_{\max} = 13$ com 142 descritores e, após este, o método estabiliza-se com pequeno decréscimo na probabilidade geral de acerto (em média 67%) até o $r_{\max} = 20$ com 335 descritores. Esses resultados indicam que, para $r_{\max} > 13$, o volume de influência $V(r)$ apurado não acrescenta mais informações relevantes para discriminação de textura.

Apesar da maior probabilidade *a posteriori* alcançada para grandes valores de $r_{\max}$ o melhor resultado alcançado, considerando-se (1) custo computacional; (2) baixo erro máximo e (3) boa confiança, é a configuração que utiliza $r_{\max} = 13$ com 68.37% de acerto, 79% de erro máximo e com uma confiança de acerto de 86.31%. Utilizando-se dessa configuração e considerando-se a média da probabilidade *a posteriori* das w' janelas texturais como estratégia de classificação obtêm-se um taxa de acerto de 88.45%, resultado esse que pode ser considerado muito bom, apesar de haver um pequeno aumento no erro máximo apresentado (ver Tabela 6.14).

Classificação Tipo	Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
1	142	5210	68.37	0.6756	79.00 - 1	86.31	67.78
2	142	674	88.45	0.8816	80.00 - 1	68.33	22.36

Tabela 6.14: Sumário da classificação usando LDA sobre descritores de DF Bouligand-Minkowski volumétrica.

A matriz de confusão dada pela Tabela 6.15 demonstra que, apesar de haver duas classes com alto erro de omissão (C16 com 80% e C32 com 57.9%) as demais classes apresentam

uma boa discriminação. Essa boa robustez é corroborada pelas 17 classes com 100% de acerto (C03, C04, C05, C06, C11, C15, C17, C19, C23, C24, C28, C30, C31, C33, C34, C35 e C39). A classe C37 é a que apresenta maior erro de comissão, ou seja, amostras são atribuídas a estas classes, quando na verdade pertence à outra.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	Co(%)		
1	73.7												5.6																												5.6		
2		89.5																																									
3			100																																								
4				100																																							
5					100											5																										5	
6						100																																					
7							66.7									5											5.3															10.3	
8		5.3	5.3				11.1	90					5.3															5.3														32.2	
9		5.3						89.5	5											5.3																						15.5	
10									90																																		
11										100																																	
12							5						84.2			10																										15	
13		5.3												83.3													5.3	5.3														15.8	
14							5								75	15					5	5																				30	
15																100																										10.5	
16															15	20																										10.5	
17		5.3															100									5.9															5.3	27.5	
18																10	95																									25.8	
19												5.3								100																						15.8	
20																					89.5																						
21																15					95																					15	
22																						85																					
23												5.3											100																			21.1	
24																								100																			
25																						5				94.1															5		
26															5	5										68.4																26.7	
27																10												89.5		5.6													15.6
28																														100												5.3	
29		5.3													5	5															77.8											15.3	
30																																100											
31																																											

Tabela 6.15: Matriz de confusão, com respectivos erros de omissão e comissão, utilizando descritores de DF Bouligand-Minkowski volumétrica.

Com objetivo de adicionar informações de cor ao método da dimensão fractal de Bouligand-Minkowski volumétrica desenvolveu-se neste mestrado, uma versão multiespectral [21]. Nessa implementação considera-se o volume $V(r)$ gerado pela interação das superfícies RGB da imagem como características. Como trata-se de um novo método é necessário investigar até que ponto a dilatação contribui com informações relevantes. Assim diversos valores de $r_{\max}$ foram testados, o resultado pode ser visto na Tabela 6.16.

Observa-se, como no método original, uma curva de qualidade crescente. Os melhores resultados foram alcançados com $r_{\max} = 15$ com 189 descritores e 73.46% de acerto. Porém, percebe-se uma constância nos resultados com valores de $10 < r_{\max} < 20$. A Tabela 6.17 demonstra o resultados alcançados para as classificações do tipo 1 e 2. Interessante notar o acréscimo de 5 pontos percentuais na estratégia de classificação tipo 1 (janelas texturais), quando comparadas a versão multiespectral e a versão volumétrica simples. Porém a há um decréscimo

de 1% (88.45% para 87.40%) quando se utiliza a média das w' para composição da probabilidade *a posteriori* amostral. Em contrapartida a esse resultado adverso temos o aumento da probabilidade *a posteriori* e a diminuição do erro máximo na versão multiespectral do método.

Raio	Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
2	4	2793	36.65	0.3502	97.00 - 1	39.63	35.50
3	8	3917	51.40	0.5015	94.50 - 1	61.75	48.45
4	14	4463	58.57	0.575	91.00 - 1	75.05	57.15
5	22	4857	63.74	0.6281	91.00 - 1	82.24	63.56
6	31	5066	66.48	0.6562	88.00 - 1	85.22	66.25
7	42	5205	68.31	0.6749	80.50 - 1	87.38	68.05
8	54	5320	69.82	0.6904	83.50 - 1	88.69	70.30
9	69	5417	71.09	0.7035	73.16 - 1	90.04	71.04
10	85	5507	72.27	0.7156	68.00 - 1	90.65	72.52
11	102	5542	72.73	0.7203	69.00 - 1	91.07	73.71
12	121	5566	73.04	0.7235	67.50 - 1	91.41	73.29
13	142	5594	73.41	0.7273	65.79 - 1	91.91	73.86
14	165	5594	73.41	0.7273	66.50 - 1	92.31	74.44
15	189	5598	73.46	0.7278	66.00 - 1	92.59	74.09
16	214	5592	73.39	0.7270	64.74 - 1	93.14	75.88
17	242	5602	73.52	0.7284	62.00 - 1	93.05	76.39
18	272	5589	73.35	0.7266	63.50 - 1	93.45	77.01
19	303	5587	73.32	0.7264	61.50 - 1	93.66	76.73
20	335	5606	73.57	0.7289	61.00 - 1	93.56	77.68

Tabela 6.16: Sumário da classificação usando LDA sobre descritores de DF Bouligand-Minkowski volumétrica multiespectral para diversos raios.

Classificação Tipo	Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
1	189	5609	73.60	0.7293	65.50 - 1	92.64	74.82
2	189	666	87.40	0.8708	50.00 - 1	77.50	26.59

Tabela 6.17: Sumário da classificação usando LDA sobre descritores de DF Bouligand-Minkowski volumétrica multiespectral.

A Tabela 6.18 apresenta a matriz de confusão para o método da DF Bouligand-Minkowski volumétrica multiespectral. Chama atenção o baixo erro máximo dentro de uma única classe (classe C16 com 50% e C14 com 40%), e as 14 classes com 100% de acerto (C04, C05, C06, C07, C08, C09, C17, C19, C20, C24, C31, C33, C35 e C39). Esses resultados levam a classificar este novo método como excelente, devido ao seu alto rendimento, robustez, confiança, baixa complexidade computacional e necessidade de configurar-se apenas 1 parâmetro.

6.2.1.6 Resultado Resultado Momentos de Cromaticidade

Não foi possível realizar a classificação entre classes utilizando os momentos de cromaticidade derivados do diagrama de cromaticidade e sua distribuição bidimensional. Ocorreu que, em diversas classes, os momentos calculados foram muito semelhantes, i.e. a coloração das texturas apresenta grande semelhança entre classes, resultando em informações redundantes. A existência de características idênticas resulta em uma matriz de covariâncias constante o que impede a análise discriminante linear.

Classificação Tipo	Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
1	192	6303	82.71	0.8227	47.36 - 1	94.20	72.43
2	192	720	94.48	0.9435	30.00 - 1	83.49	18.69

Tabela 6.19: Sumário da classificação usando LDA sobre descritores descritores de cor baseados na estrutura espacial.

ficação amostral se comparado com os filtros de Gabor wavelets para imagens em tons de cinza. Esse resultado demonstra que as informações de cor são altamente relevantes no processo de identificação de texturas foliares. Importante destacar também a grande confiabilidade de acertos dos resultados 94.20% e 83.49% em contraste com a baixa confiança para erros (18.69%) respectivamente.

Para obtenção destes resultados utilizou-se a mesma configuração dos filtros de Gabor wavelets em imagens tons de cinza ($S = 8$, $K = 8$, $U_l = 0.01$ e $U_h = 0.4$ com 64 descritores), porém aplicado aos 3 subespaços gerados, totalizando assim 192 descritores.

Tabela 6.20: Matriz de confusão, com respectivos erros de omissão e comissão, utilizando descritores de cor baseados na estrutura espacial.

A matriz de confusão do método (ver Tabela 6.20) corrobora a grande robustez do método. Observa-se que o erro máximo apresentado não ultrapassa 30% na classe C14 e 25% e 21.1%

nas classes C21 e C26 respectivamente. Salienta-se também que 55% das classes utilizadas nos experimentos (22 no total) obtiveram 100% de acerto (C01, C03, C04, C05, C07, C08, C09, C10, C11, C17, C18, C19, C20, C23, C24, C28, C30, C33, C35, C36, C38 e C40), resultados estes considerados excelentes.

6.2.1.8 Resultado Descritores de Cor Baseados na Estrutura Espacial por Análise de DF

Os ótimos resultados alcançados pelos descritores de cor baseados na estrutura espacial levam a acreditar que métodos de análise de textura que consideram, em conjunto, os aspectos físicos da cor e sua distribuição espacial, podem oferecer informações mais ricas do objeto em estudo.

Diferentemente do realizado por [46] (que utilizou filtros de Gabor) propõe-se aqui a utilização da DF Bouligand-Minkowski volumétrica como forma de caracterizar a distribuição espacial dos subespaços $\tilde{E}$, $\tilde{E}_\lambda$, $\tilde{E}_{\lambda\lambda}$ gerados pela transformação das bandas RGB. Os resultados alcançados são apresentados na Tabela 6.21.

Classificação Tipo	Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
1	207	6212	81.52	0.8105	53.00 - 1	95.86	75.71
2	207	705	92.51	0.9233	40.00 - 1	84.45	23.49

Tabela 6.21: Sumário da classificação usando LDA sobre descritores de cor baseados na estrutura espacial por análise de DF.

Com 81.52% e 92.51% de probabilidade de acerto global para classificação direta e amostral respectivamente o novo método pode ser considerado excelente para o problema de análise e discriminação de vegetais através de texturas foliares. A confiança alcançada, especialmente na classificação amostral (84.45% para acertos e 23.49% para erros), também corrobora a alta qualidade e precisão do método proposto. Em termos comparativos esta técnica supera, em aproximadamente 4 pontos percentuais na probabilidade geral de acerto, os demais modelos de análise de textura baseados em DF, tantos os baseados em imagens tons de cinza (Bouligand-Minkowski volumétrica) quanto a sua versão multiespectral.

Para obtenção destes resultados utilizou-se $r_{\max} = 9$ com 69 descritores, que aplicados aos 3 subespaços gerados, totalizando assim 207 descritores.

A Tabela 6.22 demonstra que, além de mais preciso, o método proposto é mais robusto que os modelos de análise de textura baseados em DF apresentados anteriormente. Observa-se um erro máximo de 40% na classe C14 e 31.6% na classe C32, as demais classes apresentam erros inferiores à 30%. Também há de se destacar as 19 classes com 100% de assertividade (a saber C03, C04, C05, C06, C08, C11, C18, C19, C20, C21, C22, C24, C25, C30, C31, C33, C35, C39 e C40) e as 3 classes com erros de comissão acima de 30% (C16, C26 e C37).

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	Co(%)			
1	94.7																																											
2		94.7																																										
3			100																																									
4				100																																								
5					100																																							
6						100																																						
7							94.4																																					
8								100																																				
9									89.5																																			
10										95																																		
11											100																																	
12												78.9																																
13													88.9																															
14														60																														
15															88.2																													
16																25																												
17																	75																											
18																		94.1																										
19																			100																									
20																				100																								
21																					100																							
22																						100																						
23																							94.7																					
24																								100																				
25																									100																			
26																										100																		
27																											73.7																	
28																												89.5																
29																													85															
30																														83.3														
31																															100													
32																																100												
33																																	68.4											
34																																		5.3										
35																																			89.5									
36																																				100								
37																																					89.5							
38																																						100						
39																																							88.9					
40																																								84.2				
Om(%)	5.3	5.3					5.6	10.5	5		21.1	11.1	40	11.8	25	5.9								5.3		26.3	10.5	15	16.7			31.6	10.5		10.5	11.1	15.8					92.5		

Tabela 6.22: Matriz de confusão, com respectivos erros de omissão e comissão, utilizando descritores de cor baseados na estrutura espacial por análise de DF.

6.2.2 Considerações Gerais

Um resultado facilmente observável e muito importante é a constatação que o uso da classificação amostral/folha (tipo 2), onde se utiliza a média das probabilidades *a posteriori* das w' janelas texturais, apresenta resultados muito superiores à classificação direta das janelas texturais (tipo 1). Embora haja um pequeno decréscimo na confiança dos acertos, todos os demais indicadores apresentam uma melhora substancial. Desta forma, combinar as informações de várias janelas textuais para obtenção de um resultado único mostra-se uma estratégia válida e necessária para sucesso do sistema.

Os resultados mostram que, dentro do conjunto de métodos analisados, os descritores de cor baseados na estrutura espacial (Gabor w./color - técnica que utiliza filtros de Gabor wavelets integrados às características do comprimento de onda emitidos pela luz refletida) é o melhor método para análise de texturas foliares (com probabilidade geral de acerto de 94.48%, ver Tabela 6.23). Em sequência temos os descritores de cor baseados na estrutura espacial por análise de DF (DF volumétrica/color - técnica que utiliza o novo método de DF Bouligand-Minkowski volumétrica na análise da estruturas geométrica presente na textura) com uma PGA de 92.51%,

DF volumétrica com 88.45%, Gabor wavelets com 87.92%, DF volumétrica multiespectral com 87.40% e a análise de Fourier com componentes radiais/angulares (85.17%).

Método	Número de descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
Primeira Ordem	5	374	49.08	0.4776	100.0 - 4	25.61	22.11
Coocorrência	32	606	79.52	0.7900	75.00 - 1	57.29	27.89
Fourier Componentes Radiais	63	595	78.08	0.7752	84.21 - 1	46.07	23.00
Fourier c. Radiais Angulares	64	649	85.17	0.8479	57.89 - 2	51.85	17.11
Gabor wavelets	64	670	87.92	0.8716	70.00 - 1	58.49	18.01
DF volumétrica.	142	674	88.45	0.8816	80.00 - 1	68.33	22.36
Momentos cromaticidade	6	0	0.00	0.0000	00.00 - 0	00.00	00.00
Gabor w. + cor	192	720	94.48	0.9435	30.00 - 1	83.49	18.69
DF v. multiespectral	189	666	87.40	0.8708	50.00 - 1	77.50	26.59
DF volumétrica + cor	207	705	92.51	0.9233	40.00 - 1	84.45	23.49

Tabela 6.23: Comparação resultados diversas técnicas

O erro máximo apresentado pelo classificador dentro de uma mesma classe também é o menor para a técnica de Gabor wavelets/cor (30%) e DF volumétrica/cor. Esta é uma importante característica pois demonstra que, dentro do conjunto apresentado, estas técnicas são as mais robustas, sendo capazes de discriminar bem todas as classes em estudo.

A confiança apresentada nos resultados é a sumarização da probabilidade *a posteriori* de que a amostra está corretamente classificada. Em um cenário ideal as amostras corretamente classificadas devem possuir alta confiança (i.e. certeza de que a amostra realmente pertença à classe designada), e as amostras classificadas erroneamente devem apresentar uma confiança baixa (i.e. demonstrando dessa forma que, embora a amostra tenha sido designada para aquela classe em questão não se pode afirmar, com precisão, que tal fato seja verdadeiro). Novamente podemos perceber que as técnicas que utilizam informação de cor são as que apresentam maior confiança nos acertos (Gabor wavelets/cor com 83.49% e DF volumétrica/cor com 84.45%), ou seja, pode-se dizer que uma determinada amostra está corretamente classificada utilizando-se o método de Gabor wavelets/cor com 83.49% de confiança em média. A menor confiança nos erros é obtida pelos métodos de Fourier com componente radiais/angulares (17.11%), Gabor wavelets (18.01%) e Gabor wavelets/cor (18.69%). Estes números demonstram, indiretamente, a qualidade da regra de decisão criada.

Salienta-se a grande importância da informação de cor na análise das texturas foliares, desde que considerada sua estrutura espacial como fonte de informação. Essa afirmação é corroborada pelo resultado obtido via técnica de momentos de cromaticidade, onde se utiliza o histograma na caracterização de textura. O fato das imagens apresentarem histogramas similares nas bandas RGB não o qualifica como um bom método para análise de texturas foliares. Também foram testados outros métodos de caracterização de texturas a partir do histograma, porém, como esperado não obtiveram bons resultados.

Embora tenha obtido ótimos resultados em outras bases de dados [7], o método de DF volumétrica, na versão multiespectral, não obteve resultados superiores frente sua versão original

(em escala de cinza). Isso talvez se deva ao fato de que as texturas foliares possuem uma distribuição de cor similar nas diversas classes estudadas. Porém esse resultado não deprecia a qualidade deste novo método de análise de textura, uma vez que o mesmo apresenta ótimos resultados, baixa complexidade computacional, relativa simplicidade conceitual, necessidade de ajustar apenas um parâmetro e capacidade de analisar imagens tons de cinza e coloridas com clareza e sem aumento de custo computacional.

Ainda referente ao método de DF volumétrica, sua utilização na análise das estruturas geométricas presentes na textura, integrados às características do comprimento de onda emitidos pela luz refletida, mostram-se muito promissores. Os resultados próximos, e por vezes superiores a métodos estado da arte (e.g. filtros de Gabor wavelets) levam a acreditar que esta abordagem pode vir a se tornar uma importante ferramenta na área de visão computacional.

É importante salientar que outras técnicas de análise de textura foram testadas, porém não obtiveram resultados satisfatórios quando analisados isoladamente. Por clareza e simplicidade neste trabalho optou-se por não apresentar esses resultados.

A Tabela 6.24 apresenta, de forma sumarizada, as classes com 100% de acerto e as classes que apresentam erro mais elevado em cada método. Podemos perceber que o método de Gabor wavelets/cor é o mais robusto de todos, pois apresenta um maior número de classes com acerto total. Em sequência temos os métodos que utilizam a DF volumétrica. Há certa recorrência de ótimos resultados nas classes C03, C04, C05, C08, C11, C19, C23, C24, C33 e C35, demonstrando assim que estas classes são as mais facilmente reconhecíveis. Também podemos observar a recorrência das classes C12, C14, C16 e C26 como as classes com maior erro de omissão, o que nos leva a concluir que são classes de difícil discriminação.

Método	Classes com 0.00% de omissão	Classes com maior erro de omissão
Primeira Ordem	C31	C09, C14, C25, C26, C32
Coocorrência	C03, C04, C06, C11, C15, C17, C19, C23, C24, C33	C12, C14, C16, C32
Fourier Componentes Radiais	C03, C05, C08, C23, C24, C33	C12, C16, C26
Fourier c. Radiais Angulares	C03, C05, C07, C11, C15, C19, C23, C24, C33, C35	C12, C26
Gabor wavelets	C03, C05, C06, C08, C09, C11, C15, C19, C20, C23, C24, C33, C34, C35	C12, C16, C25, C26
DF volumétrica	C03, C04, C05, C06, C11, C15, C17, C19, C23, C24, C28, C30, C31, C33, C34, C35, C39	C16, C32
Gabor w. + color	C01, C03, C04, C05, C07, C08, C09, C10, C11, C17, C18, C19, C20, C23, C24, C28, C30, C33, C35, C36, C38, C40	C14, C21, C26
DF v. multispectral	C04, C05, C06, C07, C08, C09, C17, C19, C20, C24, C31, C33, C35, C39	C16, C14
DF volumétrica + color	C03, C04, C05, C06, C08, C11, C18, C19, C20, C21, C22, C24, C25, C30, C31, C33, C35, C39, C40	C16, C26, C37

Tabela 6.24: Classes que apresentam maior e menor erro de omissão para cada método de análise de textura.

Todos esses dados obtidos nos leva a inferir que a técnica de Gabor wavelets/cor é a melhor dentre o conjunto testado. Ela apresenta uma alta robustez (55% das classes apresentaram 100% de acerto e a máxima probabilidade de erro não ultrapassa os 30%), alta probabilidade global de acerto (94.48%), mais elevado índice Kappa (0.9435) e maior diferença entre a confiança de

acerto e erros (64.8%). Em sequência temos a técnica de DF volumétrica/cor e a DF volumétrica simples.

6.2.3 Avaliação dos Classificadores

6.2.3.1 Resultado PCA+LDA

Acredita-se que a combinação das características, advindas de diferentes técnicas de análise de texturas, resulta em uma substancial melhora nos resultados alcançados. Isso se deve ao fato de que, cada método explora e caracteriza de diferentes formas os atributos da textura. Porém, combinar diretamente os descritores obtidos por simples concatenação não é uma boa estratégia. A grande quantidade de variáveis resultaria no conhecido problema do *mau da dimensionalidade* e em um alto custo computacional para qualquer classificador. Assim, com objetivo de combinar características dos diferentes métodos, utilizou-se a técnica de dois passos PCA+LDA. Esta abordagem reduz a dimensionalidade do conjunto de características através de combinações lineares das variáveis originais (componentes principais).

Os resultados obtidos por meio da concatenação de k componentes principais mais relevantes dos métodos de Gabor wavelets/cor e DF volumétrica/cor (com variância total explicada igual ou superior a 99%), são apresentados na Tabela 6.25.

Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
48	698	91.60	0.9139	65.00 - 1	76.07	24.22

Tabela 6.25: Resultados de classificação via PCA+LDA. Das 48 componentes principais utilizadas 45 são referentes ao método Gabor wavelets/cor e 3 do método DF volumétrica/cor.

Pode-se afirmar que o classificador construído não apresenta bons resultados. Com probabilidade de acerto global de 91.60% o método demonstra-se inferior, por exemplo, à técnica de Gabor wavelets/cor isoladamente. Embora se utilize as componentes principais que representam 99% da variância total explicada de cada método, ainda assim muitas informações importantes são descartadas quando da construção do classificador utilizando este subconjunto de características [57].

A composição desses resultados utilizou 45 e 3 componentes principais para representação de 99% da variância total explicada dos métodos de Gabor wavelets/cor e DF volumétrica/cor respectivamente. O gráfico de Pareto, representado nas Figuras 6.9 e 6.10, demonstra a variância total explicada para as 10 primeiras componentes principais de cada método. Percebe-se por esses gráficos a dependência linear mais elevada para os descritores de DF volumétrica/cor (82% da variância total representada por apenas uma componente principal).

A Tabela 6.26 apresenta a matriz de confusão obtida. É importante salientar que outras combinações de métodos foram testadas, porém nenhuma apresentou resultados superiores.

Figura 6.9: Variância total explicada para os 10 primeiros principais componentes. Método de Gabor wavelets/cor.

Figura 6.10: Variância total explicada para os 10 primeiros principais componentes. Método de DF volumétrica/cor.

[illegible]

Tabela 6.26: Matriz de confusão, com respectivos erros de omissão e comissão, para classificação via PCA+LDA, utilizando as componentes principais dos métodos de Gabor wavelets/cor e DF volumétrica/cor.

6.2.3.2 Resultado Comitê de máquinas

Outra forma de se combinar características é via classificação por comitê de máquinas. O único requisito para utilizar-se de tal estratégia é utilizar, na composição do comitê, classificadores de bom desempenho e que generalizam de forma descorrelacionada. Pela observação da Tabela 6.24 e matrizes de confusão podemos perceber que, dentre os métodos que apresentam bom desempenho (PGA acima de 80%), as amostras classificadas erroneamente diferem em algum grau. Tem-se dessa forma um cenário favorável à utilização do comitê de máquinas.

A Tabela 6.27 apresenta os resultados alcançados por tal estratégia. Utilizou-se na obtenção destes resultados, apenas 2 componentes/classificadores, cada um utilizando diferentes conjuntos de variáveis de entrada, i.e. descritores de Gabor wavelets/cor e DF volumétrica/cor respectivamente. A adição de componentes extras (utilizando os descritores dos demais métodos como Fourier, Gabor e coocorrência) não apresentou resultados superiores.

Com uma probabilidade de acerto global de 96.32% esses resultados demonstram que a técnica oferece um significativo ganho de desempenho. Observa-se também um incremento no

índice Kappa (0.9623), uma diminuição no erro máximo apresentado (26.31%) e um aumento na diferença entre a confiança média de acertos e erros (70.06%).

Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
399	734	96.32	0.9623	26.31 - 1	82.23	12.17

Tabela 6.27: Resultados utilizando comitê de máquinas com descritores de Gabor wavelets/cor e DF volumétrica/cor em cada componente.

A Tabela 6.28 apresenta a matriz de confusão para classificação via comitê de máquinas. Observam-se três classes com erros de omissão acima de 12% (C14, C26 e C32). A classe C37 é a que apresenta maior erro de comissão.

Tabela 6.28: Matriz de confusão, com respectivos erros de omissão e comissão, para classificação via comitê de máquinas, utilizando os descritores de Gabor wavelets/cor e DF volumétrica cor.

6.2.3.3 Resultado Redes Neurais

Adicionalmente realizou-se uma classificação via redes neurais. Neste experimento utilizou-se concatenadas as k componentes principais dos métodos de Gabor wavelets/cor e DF volumé-

trica/cor com variância total explicada igual ou superior a 99% (idem método de PCA+LDA). Com um total de 48 descritores (45 componentes principais advindas do método de Gabor wavelets/cor e 3 do método de DF volumétrica/cor) a rede neural fica composta de 48 unidades de entrada, 96 na primeira camada oculta e 40 na segunda camada oculta e camada de saída.

Em média 642 ciclos foram necessários para convergência da rede neural. Um total de 10 redes foram treinadas e testadas (método de validação cruzada K-fold com 10 folds), o desvio padrão apresentado foi de 0.02%. A Tabela 6.29 apresenta os resultados alcançados.

Nro descritores	Nro de imagens corretamente classificadas	Prob. Acerto Global (%)	Desvio Padrão %	Kappa	Erro máximo (%) e nro de classes	Confiança Acertos	Confiança Erros
48	647	84.24	0.02	0.8384	47.36 - 1	59.87	21.12

Tabela 6.29: Resultados utilizando rede neural artificial com descritores de Gabor wavelets/cor e DF volumétrica/cor.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	Co(%)		
1	84.2																	10.5	5							5		5			5.3										30.8		
2	5.3	78.9					5	5.3					5.9												5.3						5.3						5.3					37.2	
3			84.2					5.3				15.8						10.5																								31.6	
4				95	5									5																							5.3					15.3	
5					95																																						
6						90											5																									5	
7							75																																				
8								78.9														5.3																				5.3	
9									10				89.5																													10	
10										80																																5.3	
11											5																															5	
12																																										20.5	
13																																										10.3	
14																																										15	
15																																										15.8	
16																																										15.5	
17																																										10.3	
18																																										42.5	
19																																										26.3	
20																																										26.3	
21																																										26.1	
22																																											
23																																											
24																																											
25																																											
26																																											
27																																											
28																																											
29																																											
30																																											
31																																											
32																																											
33																																											
34																																											
35																																											
36																																											
37																																											
38																																											
39																																											
40																																											

Tabela 6.30: Matriz de confusão, com respectivos erros de omissão e comissão, para classificação via RNA, utilizando as componentes principais dos métodos de Gabor wavelets/cor e DF volumétrica/cor.

Com 84.24% de acerto global o método mostra-se inferior à utilização de comitê de máquinas e classificação via PCA+LDA. Adicionalmente a confiança de acertos e erros obtida

também apresenta resultados inferiores. Observando-se a matriz de confusão dada pela Tabela 6.30 percebe-se a que apenas a classe C27 obteve 100% de acerto, resultado esse também muito inferior aos demais métodos de classificação. Também se observa um grande número de classes com presença de erro de comissão, desta forma pode-se afirmar que a Rede Neural, como classificador de espécies vegetais, não é um método robusto.

Também há de se considerar o grande tempo de treinamento requerido para as redes neurais. Em média 27 minutos foram necessários para treinamento de cada RNA contra 12 segundos para o comitê de máquinas (6 segundos para cada componente LDA) e 19 segundos para o método de PCA+LDA. Talvez o grande número de neurônios da rede e o grande número de padrões sejam os responsáveis por esta demanda de tempo nas RNA. Outras configurações de rede, algoritmos de treinamento e outras formas de validação cruzada foram testadas, embora se tenha obtido um ganho no tempo gasto para treinamento, os resultados alcançados apresentaram-se inferiores.

Conclusão

7.1 Conclusão

A identificação de espécies vegetais é uma importante, porém difícil tarefa, principalmente devido à biodiversidade das espécies. Desde o processo de aquisição do espécime até a morosa comparação com as amostras já catalogadas em um herbário exigem um grande esforço dos taxonomistas e/ou profissionais de áreas correlatas.

Nesse contexto, esta pesquisa apresentou como os métodos computacionais de análise de imagens, em especial análise de textura, podem contribuir para identificação de espécies vegetais. O sistema TreeVis, associado aos bons resultados obtidos pelos métodos apresentados, pode complementar as metodologias empregadas pelos taxonomistas, facilitando e agilizando a tarefa de identificação de espécies.

Este trabalho teve como foco principal identificar espécies vegetais através de informações (características) extraídas, essencialmente, da textura foliar. Até então, dentre o reduzido conjunto de pesquisas em classificação vegetal automatizada, nenhum deles utiliza o atributo textura para classificação. É uma abordagem nunca antes utilizada em sistemas desse gênero, sendo uma metodologia nova e promissora.

Analisando os resultados obtidos, podemos concluir que na grande maioria dos casos, os experimentos que utilizam informações de cor em conjunto com características de textura alcançaram melhores resultados frente aos que utilizavam características cor e/ou textura isoladamente. Embora muito similares em sua coloração a informação de cor foliar pareceu responsável por um significativo melhoramento na qualidade dos resultados. Em especial destacam-se,

os descritores de cor baseados na estrutura espacial (técnica que utiliza filtros de Gabor wavelets integrados às características do comprimento de onda emitidos pela luz refletida), e os descritores de cor baseados na estrutura espacial por análise de DF.

No tangente aos métodos de reconhecimento de padrões podemos afirmar que a técnica utilizando comitê de máquinas mostra-se muito superior as demais metodologias testadas. Também há de se destacar que esta metodologia de classificação permite a utilização de diversos aspectos da textura em conjunto que, de forma sinérgica, contribui para a obtenção de melhores resultados. Além disso, esse tipo de classificador sinaliza a viabilidade da utilização de características derivadas de outros atributos foliares (e.g. forma, nervuras), em conjunto com as técnicas de análise de textura na geração de componentes diversos, podendo obter assim um maior poder de discriminação.

Para o desenvolvimento deste sistema, além dos aspectos biológicos, foram envolvidas as áreas de visão computacional, aprendizado de máquina, processamento de imagens e sinais entre outras. As imagens de folhas foram submetidas a diversas técnicas computacionais desde o processo de aquisição até classificação, o que torna esse trabalho diversificado e amplo.

O desenvolvimento de projetos multidisciplinares, como nesse trabalho sobre identificação de espécies vegetais, demanda além dos conhecimentos naturais sobre computação, o estudo e entendimento do problema biológico que está sendo abordado. Para este projeto, foi necessário realizar uma revisão bibliográfica sobre assuntos relacionados à taxonomia de espécies vegetais. Observou-se porém que as informações de textura propriamente dita não são utilizadas nos processos de taxonomia vegetal manuais. Esse fato torna esta pesquisa inovadora tanto na área da computação quanto na taxonomia vegetal.

Entre os benefícios e aplicações da identificação vegetal temos o conhecimento da flora com credibilidade científica, auxílio para o manejo sustentável dos recursos florestais, recomposição das informações sobre a flora original de uma área, atualmente em processo de degradação ou extinção e o subsídio para áreas da Botânica (fisiologia vegetal, citologia, paleobotânica, etc.) e áreas do conhecimento afins (ciências agrárias, ecologia, etc.).

7.1.1 Principais Contribuições

A principal contribuição deste trabalho foi o desenvolvimento e implementação de métodos computacionais para análise e identificação de vegetais por meio da textura foliar. De caráter inédito, tanto na biologia (por realizar classificação de vegetais por análise de textura foliar), quanto na computação (por desenvolver novas metodologias de extração de características, superiores inclusive a métodos estado da arte), esta pesquisa pode ser considerada de grande importância para ambas as áreas. As principais contribuições alcançadas ao longo do desenvolvimento deste projeto são apresentadas a seguir:

1. Criação de um banco de dados contendo texturas e contornos foliares que podem ser utilizados em futuros estudos de diversas técnicas em processamento digital de imagens e aprendizado de máquina;
2. Utilização da textura foliar na identificação de espécies vegetais, contribuindo assim com o módulo de textura/complexidade do projeto TreeVis [19, 20].
3. Desenvolvimento do método de dimensão fractal de Bouligand Minkowski volumétrica para análise textura. Com ótimos resultados a técnica se mostrou eficaz em vários problemas, superando inclusive diversos métodos estado da arte [7];
4. A adaptação de uma versão multiespectral do método de DF Bouligand Minkowski volumétrica para análise de texturas coloridas. Embora não tenha demonstrados bons resultados no problema de identificação vegetal em outras bases de dados esta técnica obteve resultados excelentes [21].
5. Caracterização de cor e textura pela utilização da teoria dos fractais na análise de aspectos físicos da cor (aplicação do método de DF Bouligand Minkowski volumétrica aos subespaços $\tilde{E}$, $\tilde{E}_\lambda$, $\tilde{E}_{\lambda\lambda}$).
6. Criação dos métodos baseados em redes complexas para análise de formas [8, 6, 9] e textura [10]. Embora não apresentados no contexto deste trabalho diversos métodos foram desenvolvidos neste mestrado e continuam sendo estudados pelos autores.

7.1.2 Trabalhos Futuros

Espera-se, com base no protótipo desenvolvido, a incorporação dos métodos ao projeto TreeVis. Possibilitando assim uma análise estatística completa e que forneça ao especialista uma lista das prováveis espécies a qual pertence à amostra.

Outra possibilidade é adequar este trabalho na identificação de outras bases de dados, ou a problemas cuja aplicação seja similar. Também se pode estudar a viabilidade de implementar um mecanismo que efetue a análise *in loco*.

Outro aspecto importante que pode contribuir na melhoria dos resultados é a adequação do processo de aquisição de imagens. A investigação do uso de câmeras fotográficas digitais com diferentes resoluções, sem problemas de iluminação, se possível.

Há também a necessidade de se investigar a utilização dos métodos de textura empregados em experimentos morfofisiológicos. Um exemplo prático é a utilização desse sistema, no estudo variação textural quanto à morfologia da folha quando um indivíduo advém de diferentes ecossistemas ou é exposto às condições ambientais diversas.

A Tabela 7.1 apresenta os valores críticos para Z scores. Estes valores críticos indicam o limite que, para um determinado nível de significância α , a amostra deva ser rejeitada.

n / α	$t_{n,0.1}$	$t_{n,0.05}$	$t_{n,0.025}$	$t_{n,0.01}$	$t_{n,0.005}$	$t_{n,0.001}$	$t_{n,0.0005}$
1	3.0777	6.3138	12.7062	31.8205	63.6567	318.3088	636.6192
2	1.8856	2.9200	4.3027	6.9646	9.9248	22.3271	31.5991
3	1.6377	2.3534	3.1824	4.5407	5.8409	10.2145	12.9240
4	1.5332	2.1318	2.7764	3.7469	4.6041	7.1732	8.6103
5	1.4759	2.0150	2.5706	3.3649	4.0321	5.8934	6.8688
6	1.4398	1.9432	2.4469	3.1427	3.7074	5.2076	5.9588
7	1.4149	1.8946	2.3646	2.9980	3.4995	4.7853	5.4079
8	1.3968	1.8595	2.3060	2.8965	3.3554	4.5008	5.0413
9	1.3830	1.8331	2.2622	2.8214	3.2498	4.2968	4.7809
10	1.3722	1.8125	2.2281	2.7638	3.1693	4.1437	4.5869
11	1.3634	1.7959	2.2010	2.7181	3.1058	4.0247	4.4370
12	1.3562	1.7823	2.1788	2.6810	3.0545	3.9296	4.3178
13	1.3502	1.7709	2.1604	2.6503	3.0123	3.8520	4.2208
14	1.3450	1.7613	2.1448	2.6245	2.9768	3.7874	4.1405
15	1.3406	1.7531	2.1314	2.6025	2.9467	3.7328	4.0728
16	1.3368	1.7459	2.1199	2.5835	2.9208	3.6862	4.0150
17	1.3334	1.7396	2.1098	2.5669	2.8982	3.6458	3.9651
18	1.3304	1.7341	2.1009	2.5524	2.8784	3.6105	3.9216
19	1.3277	1.7291	2.0930	2.5395	2.8609	3.5794	3.8834
20	1.3253	1.7247	2.0860	2.5280	2.8453	3.5518	3.8495
21	1.3232	1.7207	2.0796	2.5176	2.8314	3.5272	3.8193
22	1.3212	1.7171	2.0739	2.5083	2.8188	3.5050	3.7921
23	1.3195	1.7139	2.0687	2.4999	2.8073	3.4850	3.7676
24	1.3178	1.7109	2.0639	2.4922	2.7969	3.4668	3.7454
25	1.3163	1.7081	2.0595	2.4851	2.7874	3.4502	3.7251
26	1.3150	1.7056	2.0555	2.4786	2.7787	3.4350	3.7066
27	1.3137	1.7033	2.0518	2.4727	2.7707	3.4210	3.6896
28	1.3125	1.7011	2.0484	2.4671	2.7633	3.4082	3.6739
29	1.3114	1.6991	2.0452	2.4620	2.7564	3.3962	3.6594
30	1.3104	1.6973	2.0423	2.4573	2.7500	3.3852	3.6460
31	1.3095	1.6955	2.0395	2.4528	2.7440	3.3749	3.6335
32	1.3086	1.6939	2.0369	2.4487	2.7385	3.3653	3.6218
33	1.3077	1.6924	2.0345	2.4448	2.7333	3.3563	3.6109
34	1.3070	1.6909	2.0322	2.4411	2.7284	3.3479	3.6007
35	1.3062	1.6896	2.0301	2.4377	2.7238	3.3400	3.5911
36	1.3055	1.6883	2.0281	2.4345	2.7195	3.3326	3.5821
37	1.3049	1.6871	2.0262	2.4314	2.7154	3.3256	3.5737
38	1.3042	1.6860	2.0244	2.4286	2.7116	3.3190	3.5657
39	1.3036	1.6849	2.0227	2.4258	2.7079	3.3128	3.5581
40	1.3031	1.6839	2.0211	2.4233	2.7045	3.3069	3.5510
41	1.3025	1.6829	2.0195	2.4208	2.7012	3.3013	3.5442
42	1.3020	1.6820	2.0181	2.4185	2.6981	3.2960	3.5377
43	1.3016	1.6811	2.0167	2.4163	2.6951	3.2909	3.5316
44	1.3011	1.6802	2.0154	2.4141	2.6923	3.2861	3.5258
45	1.3006	1.6794	2.0141	2.4121	2.6896	3.2815	3.5203
46	1.3002	1.6787	2.0129	2.4102	2.6870	3.2771	3.5150
47	1.2998	1.6779	2.0117	2.4083	2.6846	3.2729	3.5099
48	1.2994	1.6772	2.0106	2.4066	2.6822	3.2689	3.5051
49	1.2991	1.6766	2.0096	2.4049	2.6800	3.2651	3.5004
50	1.2987	1.6759	2.0086	2.4033	2.6778	3.2614	3.4960
n>50	1.28	1.65	1.96	2.33	2.58	3.09	3.29

Tabela 7.1: Valores críticos para o escore Z com n graus de liberdade $\times$ nível α de significância

Referências Bibliográficas

- [1] T. Arodz, D. A. Yuen, and A. Z. Dudek. Ensemble of linear models for predicting drug properties. *Journal of Chemical Information and Modeling*, 46(1):416–423, 2006.
- [2] N. Asada and T. Matsuyama. Color image analysis by varying camera aperture. In *International Conference on Pattern Recognition*, pages I:466–469, 1992.
- [3] A. Ash, B. Ellis, L. J. Hickey, K. Johnson, P. Wilf, and S. Wing. Manual of leaf architecture - morphological description and categorization of dicotyledonous and net-veined monocotyledonous angiosperms by leaf architecture, 1999. URL <http://www.peabody.yale.edu/collections/pb/mla/mla.pdf>.
- [4] A. R. Backes. Implementação e comparação de métodos de estimativa da dimensão fractal e sua aplicação à análise e processamento de imagens. Dissertação eletrônica, Biblioteca Digital de Teses e Dissertações da USP, 2006.
- [5] A. R. Backes and O. M. Bruno. Segmentação de texturas por análise de complexidade. *Journal of Computer Science*, 5(1):87–95, 2006.
- [6] A. R. Backes, D. Casanova, and O. M. Bruno. Método de aproximação poligonal de contornos utilizando redes complexas. *Journal of Computer Science*, 6(2):71–80, 2007.
- [7] A. R. Backes, D. Casanova, and O. M. Bruno. Plant leaf identification based on volumetric fractal dimension. *International Journal of Pattern Recognition and Artificial Intelligence*, 2008 (Aceito).
- [8] A. R. Backes, D. Casanova, and O. M. Bruno. A complex network-based approach for boundary shape analysis. *Pattern Recognition*, 2008 (Aceito).
- [9] A. R. Backes, D. Casanova, and O. M. Bruno. Contour polygonal approximation using complex networks. *International Journal of Computer Vision*, 2008 (Submetido).

- [10] A. R. Backes, D. Casanova, and O. M. Bruno. A complex network-based approach for texture analysis. *International Journal of Computer Vision*, 2008 (Submetido).
- [11] V. Barnett and T. Lewis. *Outliers in statistical data*. Wiley, 1984.
- [12] P. N. Belhumeur, J. P. Hespanha, and D. J. Kriegman. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(7):711–720, 1997.
- [13] A. C. Bovik, M. Clark, and W. S. Geisler. Multichannel texture analysis using localized spatial filters. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 12(1): 55–73, 1990.
- [14] A. P. Braga, A. P. de L. F. de Carvalho, and T. B. Ludermir. *Redes Neurais Artificiais - Teoria e Aplicações*. LTC, 2000.
- [15] L. Breiman. Bagging predictors. *Machine Learning*, 24(2):123–140, 1996.
- [16] P. Brodatz. *Textures: A photographic album for artists and designers*. Dover Publications, 1966.
- [17] T. M. Caelli and D. Reye. On the classification of image regions by colour, texture, and shape. *Pattern Recognition*, 26(4):461–470, 1993.
- [18] M. Carlin. Measuring the complexity of non-fractal shapes by a fractal method. *Pattern Recognition Letters*, 21(11):1013–1017, 2000.
- [19] D. Casanova, J. J. M. S. Junior, and O. M. Bruno. Plant leaf identification using gabor wavelets. *International Journal of Imaging Systems and Technology*, 2007 (Submetido).
- [20] D. Casanova, A. R. Backes, and O. M. Bruno. Measurements of color texture on plant leaf identification. *International Symposium on Mathematical and Computational Biology*, 2008 (Resumo Aceito).
- [21] D. Casanova, A. R. Backes, and O. M. Bruno. Multispectral volumetric minkowski fractal dimension. *Pattern Recognition*, 2008 (Submetido).
- [22] B. B. Chaudhuri and N. Sarkar. Texture segmentation using fractal dimension. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17(1):72–77, 1995.
- [23] R. Chellappa and S. Chatterjee. Classification of textures using gaussian markov random fields. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 33(4):959–963, 1985.
- [24] Y. Chen and E. Dougherty. Gray-scale morphological granulometric texture classification. *Optical Engineering*, 33(8):2713–2722, 1994.

- [25] Y. Q. Chen, M. S. Nixon, and D. W. Thomas. Statistical geometrical features for texture classification. *Pattern Recognition*, 28(4):537–552, 1995.
- [26] P. Cohen, C. T. LeDinh, and V. Lacasse. Classification of natural textures by means of two-dimensional orthogonal masks. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 37(1):125, 1989.
- [27] R. G. Congalton. A review of assessing the accuracy of classification or remotely sensed data. *Remote Sensing of Environment*, 37(1):35–45,, 1991.
- [28] L. F. Costa and R. M. Cesar, Jr. *Shape Analysis and Classification: Theory and Practice*. CRC Press, 2000.
- [29] G. Cross and A. K. Jain. Markov random field texture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 5(1):25–39, 1983.
- [30] J. Daugman and C. Downing. Gabor wavelets for statistical pattern recognition. In *The Handbook of Brain Theory and Neural Networks*, pages 414–419. MIT Press, 1995.
- [31] J. G. Daugman. Uncertainty relation for resolution in space, spatial frequency and orientation optimized by two-dimensional visual cortical filters. *Journal of the Optical Society of America*, 2(7):1160–1169, 1985.
- [32] C. Domeniconi and B. Yan. Nearest neighbor ensemble. In *International Conference on Pattern Recognition*, pages I:228–231, 2004.
- [33] C. W. Emerson, N. N. Lam, and D. A. Quattrochi. Multi-scale fractal analysis of image texture and patterns. *Photogrammetric Engineering and Remote Sensing*, 65(1):51–62, 1999.
- [34] M. Falvo. Identificação de espécies vegetais por meio da análise do contorno foliar - uma abordagem bio-inspirada. Dissertacao eletronica, Biblioteca Digital de Teses e Dissertações da USP, 2005.
- [35] K. Fukunaga. *Introduction to Statistical Pattern Recognition*. Academic Press, 2nd edition, 1990.
- [36] D. Gabor. Theory of communication. *Journal of the Institute for Electrical Engineers*, 93(3):429–439, 1946.
- [37] J. J. Gangepain and C. Roques-Carmes. Fractal approach to two dimensional and three dimensional surface roughness. *Wear*, 2(109):119–126, 1986.
- [38] J. M. Geusebroek, R. van den Boomgaard, A. W. M. Smeulders, and A. Dev. Color and scale: The spatial structure of color images. In *European Conference on Computer Vision*, pages I: 331–341, 2000.

- [39] R. C. Gonzalez and R. E. Woods. *Digital Image Processing*. Addison-Wesley, 3rd edition, 1992.
- [40] I. A. Guimarães and A. C. Neto. Reconhecimento de padrões: Comparação de métodos multivariados e redes neurais. *Revista Negócios e Tecnologia da Informação*, 1(1):40–64, 2006.
- [41] J. F. Hair, R. E. Anderson, R. L. Tatham, and Black. *Multivariate Data Analysis*. Prentice Hall College Div, 1998.
- [42] L. K. Hansen and P. Salamon. Neural network ensembles. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(10):993–1001, 1990.
- [43] R. M. Haralick. Statistical and structural approaches to texture. *Proceedings IEEE*, 67(5):786–804, 1979.
- [44] S. Haykin. *Neural Networks: A Comprehensive Foundation*. Prentice Hall, 2nd edition, 1999.
- [45] L. R. Hickey. Classification of architecture of dicotyledonous leaves. *American Journal of Botany*, 60(1):17–33, 1973.
- [46] M. A. Hoang and J. M. Geusebroek. Measurement of color texture. In *Workshop on Texture Analysis in Machine Vision*, pages 73–76, 2002.
- [47] H. Hotelling. Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 24(1):417–441, 1933.
- [48] M. Idrissa and M. Acheroy. Texture classification using gabor filters. *Pattern Recognition Letters*, 23(9):1095–1102, 2002.
- [49] A. Jain and G. Healey. A multiscale representation including opponent-color features for texture recognition. *IEEE Trans. Image Processing*, 7(1):124–128, 1998.
- [50] A. K. Jain and F. Farrokhnia. Unsupervised texture segmentation using Gabor filters. *Pattern Recognition*, 24(12):1167–1186, 1991.
- [51] A. K. Jain and D. Zongker. Feature selection: Evaluation, application and a small sample performance. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(2): 153–158, 1997.
- [52] R. Johnson and D. Wichern. *Applied Multivariate Statistical Analysis*. Prentice-Hall, 1982.
- [53] W. Judd, C. Campbell, E. A. Kellog, and P. Stevens. *Plant Systematics: A Phylogenetic Approach*. Sinauer Associates, 1999.

- [54] B. Julesz. Experiments in the visual perception of texture. *Scientific American*, 232(4): 34–43, 1975.
- [55] L. M. Kaplan. Extended fractal analysis for texture classification and segmentation. *IEEE Transactions on Image Processing*, 8(11):1572–1585, 1999.
- [56] T. Kasparis, D. Charalampidis, M. Georgiopoulos, and J. P. Rolland. Segmentation of textured images based on fractals and image filtering. *Pattern Recognition*, 34(10):1963–1973, 2001.
- [57] H. Kong, X. Li, J. G. Wang, and C. Kambhamettu. Ensemble lda for face recognition. In *Biometric Authentication*, pages 166–172, 2006.
- [58] M. H. Kurmann and A. R. Hemsley. *The Evolution of Plant Architecture*. Royal Botanic Gardens, Kew, 1999.
- [59] C.-J. Lee and S.-D. Wang. Fingerprint feature reduction by principal gabor basis function. *Pattern Recognition*, 34(11):2245–2248, 2001.
- [60] C. L. Lee and S. Y. Chen. Classification of leaf images. *International Journal of Imaging Systems and Technology*, 16(1):15–23, 2006.
- [61] M. Levine. *Vision in Man and Machine*. McGraw Hill, 1985.
- [62] C. S. Lu, P. C. Chung, and C. F. Chen. Unsupervised texture segmentation via wavelet transform. *Pattern Recognition*, 30(5):729–742, 1997.
- [63] J. Lu, K. N. Plataniotis, and A. N. Venetsanopoulos. Boosting linear discriminant analysis for face recognition. In *International Conference on Image Processing*, pages I: 657–660, 2003.
- [64] J. Malik and P. Perona. Preattentive texture discrimination with early vision mechanism. *Journal of the Optical Society of America*, 7(5):923–932, 1990.
- [65] S. G. Mallat. Multifrequency channel decompositions of images and wavelet models. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 37(12):2091–2110, 1989.
- [66] B. S. Manjunath and W.-Y. Ma. Texture features for browsing and retrieval of image data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(8):837–842, 1996.
- [67] E. T. M. Manoel, L. F. Costa, J. Streicher, and G. B. Müller. Multiscale fractal characterization of three-dimensional gene expression data. In *SIBGRAPI*, pages 269–274. IEEE Computer Society, 2002.

- [68] A. Materka and M. Strzelecki. Texture analysis methods, a review. Technical report, University of Lodz, Institute of Electronics, Brussels, 1998.
- [69] M. Møller. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, 6(4):525–533, 1993.
- [70] G. Neil and K. M. Curtis. Shape recognition using fractal geometry. *Pattern Recognition*, 30(12):1957–1969, 1997.
- [71] Niemann. *Pattern Analysis*. Springer, 1981.
- [72] N. Otsu. A threshold selection method from gray level histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1):62–66, 1979.
- [73] G. Paschos. Chromatic correlation features for texture recognition. *Pattern Recognition Letters*, 19(8):643–650, 1998.
- [74] G. Paschos. Fast color texture recognition using chromaticity moments. *Pattern Recognition Letters*, 21(9):837–841, 2000.
- [75] S. Peleg, J. Naor, R. L. Hartley, and D. Avnir. Multiple resolution texture analysis and classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6(4):518–523, 1984.
- [76] A. P. Pentland. Fractal-based description of natural scenes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6(6):661–674, 1984.
- [77] R. O. Plotze. Identificação de espécies vegetais através da análise da forma interna de órgãos foliares. Dissertacao electronica, Biblioteca Digital de Teses e Dissertações da USP, 2004.
- [78] R. O. Plotze and O. M. Bruno. Dimensão fractal multiescala e suas aplicações na taxonomia de espécies vegetais. In *I Workshop de Visão Computacional*, pages 1–4, 2005.
- [79] R. O. Plotze and O. M. Bruno. Identificação de espécies vegetais através da análise da forma interna de Órgãos foliares. In *XVIII Brazilian Symposium on Computer Graphics and Image Processing*, 2005.
- [80] R. O. Plotze, M. Falvo, and O. M. Bruno. Identificação de espécies arbóreas através da dimensão fractal. In *I Workshop de Tecnologia da Informação aplicada ao Meio Ambiente*, pages 1–9, 2003.
- [81] R. O. Plotze, M. Falvo, J. G. Pádua, L. C. Bernacci, M. L. C. Vieira, G. C. X. Oliveira, and O. M. Bruno. Leaf shape analysis using the multiscale minkowski fractal dimension, a new morphometric method: a study with passiflora (passifloraceae). *Canadian Journal of Botany*, 83(3):287–301, 2005.

- [82] H. Potlapalli and R. C. Luo. Fractal based classification of natural textures. In *Image Understanding Workshop*, pages II:1595–1606, 1994.
- [83] W. K. Pratt. *Digital Image Processing*. Wiley Interscience, 2nd edition, 1991.
- [84] J. A. R. Recio, L. A. R. Fernández, and A. Fernandez-Sarriá. Use of gabor filters for texture classification of digital images. *Física de la Tierra*, 17(1):47–59, 2005.
- [85] A. Rosenfeld and Kak. *Digital Picture Processing*, volume 2. Academic Press, 1982.
- [86] D. Rumelhart and J. McClelland. *Parallel Distributed Processing*, volume 1 & 2. MIT Press, 1986.
- [87] D. E. Rumelhart, G. E. Hinton, and R. J. Williams. Learning representations by back-propagating errors. *Nature*, 323:533–536, 1986.
- [88] M. Sakane. *Técnicas de coleta, preservação e herborização de material botânico*. Instituto Botânico, 1984.
- [89] N. Sarkar and B. B. Chaudhuri. An efficient differential box-counting approach to compute fractal dimension of image. *IEEE Transactions on Systems, Man and Cybernetics*, 24(1):115–120, 1994.
- [90] N. Sarkar and B. B. Chaudhuri. An efficient approach to estimate fractal dimension of textural images. *Pattern Recognition*, 25(9):1035–1041, 1992.
- [91] R. Schapire. The strength of weak learnability. *Machine Learning*, 5(2):197–227, 1990.
- [92] M. W. Schwarz, W. B. Cowan, and J. C. Beatty. An experimental comparison of RGB, YIQ, LAB, HSV, and opponent color models. *ACM Transactions on Graphics*, 6(2):123–158, 1987.
- [93] J. Serra. *Image Analysis and Mathematical Morphology*. Academic Press, 1982.
- [94] A. C. She and T. S. Huang. Segmentation of road scenes using color and fractal-based texture classification. In *International Conference on Image Processing*, pages III:1026–1030, 1994.
- [95] L. Shen and L. Bai. A review on gabor wavelets for face recognition. *Pattern Analysis and Applications*, 9(2-3):273–292, 2006.
- [96] K. R. Stern. *Introductory Plant Biology*. WCB, 1993.
- [97] D. L. Swets and J. Weng. Using discriminant eigenfeatures for image retrieval. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(8):831–836, 1996.

- [98] A. Teuner, O. Pichler, and B. J. Hosticka. Unsupervised texture segmentation of images using tuned matched gabor filters. *IEEE Transactions on Image Processing*, 4(6):863–870, 1995.
- [99] B. Thai and G. Healey. Modeling and classifying symmetries using a multiscale opponent color representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(11):1224–1235, 1998.
- [100] C. Tricot. *Curves and Fractal Dimension*. Springer-Verlag, 1995.
- [101] A. Turiel and N. Parga. The multifractal structure of contrast changes in natural images: From sharp edges to textures. *Neural Computation*, 12(4):763–793, 2000.
- [102] P. Tzionas, S. Papadakis, and D. Manolakis. Plant leaves classification based on morphological features and a fuzzy surface selection technique. In *5th International Conference on Technology and Automation*, pages 365–370, 2005.
- [103] K. Valkealahti and E. Oja. Reduced multidimensional co-occurrence histograms in texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(1):90–94, 1998.
- [104] J. L. Vehel, P. Mignot, and J. P. Berroir. Multifractals, texture, and image analysis. In *IEEE Computer Vision and Pattern Recognition*, pages 661–664, 1992.
- [105] A. C. A. Vicente, E. G. Macedo, J. U. M. dos Santos, R. C. de V. Potiguara, and M. N. do C. Bastos. Flórlula fanerogâmica das restingas do estado do pará, ilha do algodoal. *Boletim do Museu Paraense Emílio Goeldi*, 15:173–198, 1999.
- [106] F. M. Vilnrotter, R. Nevatia, and K. E. Price. Structural analysis of natural textures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(1):76–89, 1986.
- [107] B. Waggoner. Carl linnaeus, 2000. URL <http://www.ucmp.berkeley.edu/history/linnaeus.html>.
- [108] Z. Wang, Z. Chi, and D. D. Feng. Shape based leaf image retrieval. *IEEE Proceedings on Vision Image and Signal Processing*, 150(1):34–43, 2003.
- [109] J. S. Weszka, C. R. Dyer, and A. Rosenfeld. A comparative study of texture measures for terrain classification. *IEEE Transactions on Systems, Man and Cybernetics*, 6(4):269–285, 1976.
- [110] G. Wyszecki and W. S. Stiles. *Color Science: Concepts and Methods, Quantitative Data and Formulas*. Wiley, 1982.