SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito: 17.06.2005

Assinatura:

Ana Paula Lampaio Freire

**Identificação de espécies vegetais por meio
da análise do contorno foliar - uma
abordagem bio-inspirada**

Maurício Falvo

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 da Computação e Matemática Computacional.

USP – São Carlos
Junho/2005

Aluno: Mauricio Falvo

A Comissão Julgadora:

Prof. Dr. Odemir Martinez Bruno

Prof. Dr. João do Espírito Santo Batista Neto

João do Espírito Santo Batista Neto

Prof. Dr. Giancarlo Conde Xavier Oliveira

Giancarlo Conde Xavier Oliveira

*À minha esposa Silvia e
aos meus filhos Carolina e Eduardo.*

Agradecimentos

À Deus, pela oportunidade oferecida por meio das “coincidências” que surgiram nos caminhos que escolhi, permitindo a realização de um sonho quase esquecido...

À minha amada esposa Silvia, por ter menos juízo do que eu me incentivando na decisão de fazer mestrado, e ter agüentado e continuar agüentando firme todas as conseqüências que esta decisão deflagrou, e o mais importante, por ser simplesmente minha esposa.

Aos meus filhos, pela beleza e ingenuidade de seus sorrisos - me dando forças para continuar sorrindo não importando qual situação me encontre.

Aos meus pais Vincenzo e Nair, pelo exemplo de vida, pela minha educação, por tudo que sou como pessoa e por tudo que fizeram por mim e continuam fazendo.

Aos meus irmãos Flávio e Marcio, por estarem sempre disponíveis a me ajudarem - grandes irmãos.

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

À Profa. Dra. Roseli Aparecida Francelin Romero pela ajuda dada no assunto de redes neurais.

Aos amigos que fiz neste período: Mário, Menotti, Rogério (obrigado pelas dicas), Vanderlei, Rodrigo, Júlio, Christian e outros mais que agora me fogem à memória.

Ao Prof. Dr. Giancarlo e Dr. Juliano de Pádua - ESALQ/USP, pelas imagens de passifloras cedidas e pelos trabalhos desenvolvidos em conjunto.

À Elizabeth, Laura e Ana Paula da seção de pós-graduação, por serem sempre prestativas e atenciosas.

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

À Capes pelo apoio financeiro de parte deste trabalho.

*“Todos têm o direito de sonhar,
e cada um o de ser dono do próprio sonho...”*
(Fernando Sabino)

Resumo

A identificação de uma planta exige, pelos padrões de taxionomia vegetal, a análise de folhas, flores e frutos. O projeto TreeVis surge com uma proposta de auxiliar na identificação de espécies vegetais, por meio do uso de métodos biométricos, a partir da análise de alguns atributos de uma folha. A contribuição inicial deste trabalho de mestrado, para o projeto TreeVis, está obtenção de classificadores por meio do uso de assinaturas de contorno, sob o domínio da frequência, possibilitando a composição de diversos tipos de assinaturas e classificadores para uma mesma espécie. Devido à baixa eficiência obtida por métodos de classificação como distância mínima, optou-se pelo uso de redes neurais. Essa abordagem evidenciou a necessidade de solução de dois problemas: o grande número de possibilidades de composição de sinais - o que ocasionaria um grande esforço computacional para a obtenção de todas respectivas redes neurais; e o reduzido número das amostras utilizadas no trabalho - o qual comprometeria as etapas de treinamento e teste de uma rede neural. Para a solução desses problemas, foram desenvolvidos dois métodos: o primeiro método identifica e seleciona as assinaturas que apresentam um maior potencial de sucesso em obter um classificador por meio de redes neurais, solucionando o problema e desperdício de esforço computacional; o segundo método possibilita a geração de amostras artificiais de folhas através da combinação dos espectros de frequência do contorno das amostras reais por meio operadores genéticos de cross-over e mutação. Solucionadas as duas questões, foram obtidas diversas redes neurais, através da indicação das assinaturas de melhor potencial e treinadas com amostras artificiais. Do total de 31 classes, 7 foram descartadas da tentativa de obtenção de classificadores por não apresentarem nenhuma assinatura com potencial de classificação - conforme indicação do método desenvolvido. Das 24 espécies restantes, foram obtidos classificadores para 18 espécies (75%) com taxas médias de 85% de acerto. A execução deste trabalho necessitou do desenvolvimento de um arcabouço para a automatização da geração, treinamento e teste das redes neurais.

Palavras chaves: Visão computacional, biometria, Fourier, análise de contorno, redes neurais e algoritmos genéticos.

Abstract

The vegetable identification is done, in vegetal taxonomy standards, by flower, fruits and leaves analyses. The TreeVis project proposes to identify vegetal specimens by biometric methods using only same leaf features. The contribution of this work for to TreeVis project is the generation of classifiers by the contour signatures, under frequency domain, making be able the composition of several types of signatures and classifiers for the same specimen. Because of poor efficiency results from methods like minimal distance, was chosen to use neural networks. This approach showed the need to solve two problems: the numerous composition possibilities of signatures – that would be need a big computational effort to obtained all possible neural networks; and the small number of specimen samples – that would compromise the training and test of neural networks. To solve these two problems was developed two methods: The first identify and select the signatures that have a good pattern recognition potential, before of the network will be done, solving the waste unneeded effort problem. The second method proposed produces artificial leaf shapes by combination of contour spectrum frequency specimens of real leaves, using genetic operators like cross-over and mutation. Solved these problems several networks was obtained by appointed potential signature methods and trained and tested with artificial leaves. From 31 specimens class, 07 were discarded because they had not signatures with classification potential - indicated by developed method. From 24 classes remaining were obtained classifiers for 18 classes (75%) with medium rates 85% of set right. The execution of this work demanded the construction of a framework to automatize the generation, training and test of the neural networks.

Keywords: Computer vision, biometry, Fourier, shape analysis, neural networks and genetics algorithms.

Sumário

Lista de Figuras	10
Lista de Tabelas	13
1 Introdução	16
1.1 Justificativa e Motivação	16
1.2 Objetivos	17
1.3 Organização	17
2 Análise de vegetais	18
2.1 O Projeto TreeVis e Biometria Foliar	18
2.2 Projeto TreeVis	18
2.2.1 Fundamentos e Descrição do Sistema	19
2.2.2 Atual situação do protótipo e os métodos de análise estudados	20
2.3 Biometria Foliar	21
2.3.1 Introdução	21
2.3.2 Forma Laminar	21
2.3.3 Ângulos Basal e Apical	22
2.3.4 Forma basal e apical	24
2.3.5 Endentação de contorno e lobação	26
2.4 Considerações Finais	26
3 Descrição, análise e classificação de contornos	27
3.1 Métodos para descrição de contornos	27
3.1.1 Assinatura por Coordenadas Paramétricas	28
3.1.2 Assinatura : Ângulo x Distância	29
3.1.3 Assinatura: Passos x Distância	30
3.1.4 Assinatura pelo ângulo-de-visão	31
3.1.5 Curvatura	32
3.2 Métodos de análise de assinaturas de contorno	35
3.2.1 Descritores de Fourier	35
3.2.2 Espectro de Potencia	36
3.3 Métodos de Classificação	37
3.3.1 Redes Neurais	37
3.3.2 Classificação Teórica	47
3.3.3 Algoritmos Genéticos	48
3.4 Considerações Finais	51

4	Procedimentos experimentais	53
4.1	Uma visão geral do problema	53
4.2	Sobre as amostras	54
4.3	Pré-processamento e obtenção dos sinais	55
4.4	Filtragem pelo método <i>leave-one-out</i>	59
4.4.1	A configuração de rede adotada	60
4.4.2	Aplicando o método <i>leave-one-out</i> como um filtro	60
4.5	Geração das amostras artificiais	62
4.5.1	Divisão das Amostras em duas famílias	63
4.5.2	Cruzamentos e Mutações	61
4.5.3	Seleção dos contornos artificiais	65
4.5.4	Geração das imagens	65
4.6	Geração, treinamento e teste das redes neurais	67
4.7	Validação das redes geradas com amostras reais	67
4.8	Considerações Finais	67
5	Resultados	69
5.1	Resultados do método de filtragem <i>leave-one-out</i>	69
5.2	Resultados da geração das amostras artificiais	70
5.3	Resultados das RNs geradas e testadas por amostras artificiais	71
5.4	Resultados das RNs aplicadas na classificação de amostras reais	73
5.5	Considerações finais	74
6	Conclusão	79
6.1	Contribuições geradas pelo trabalho	81
6.2	Trabalhos Futuros	81
A	Potencial de classificação por classe	83
B	Folhas artificialmente geradas	99
C	Resultados da classificação de amostras artificiais por redes geradas com amostras artificiais	115
D	Resultados da classificação de amostras reais por redes geradas com amostras artificiais	121
	Referências	130

Lista de Figuras

2.1	Representação dos módulos do sistema TreeVis e suas interações (Bruno, 2000).	20
2.2	Uma Folha e suas estruturas básicas (Ash <i>et al.</i> , 1999).	22
2.3	Principais formas foliares: Elíptica (a); Obovata (b); Ovata (c), Oblonga (d) e um outro exemplo de folha elíptica apesar de lobada (e). Figura reusada de (Ash <i>et al.</i> , 1999).	23
2.4	Formas básicas de folhas e os respectivos parâmetros de medida: L , l_m , l_a e l_b (Ash <i>et al.</i> , 1999).	23
2.5	Exemplos de folhas e seus tipos de ângulos apicais (a1-a5) e basais (b1-b3) (Ash <i>et al.</i> , 1999).	24
2.6	Formas basais: cuneiforme (a), convexa (b), ovalada (c), truncada (d), côncava (e), côncava-convexa (f), decurrent (g), complexa (h) cordata (i), lobata (j), saginata (k) e hastata (l). adaptado de (Ash <i>et al.</i> , 1999).	25
2.7	Formas apicais: lisa (a), convexa (b), arredondada (c), truncada (d), acuminada (e), complexa (f), retusa (g), emarginada (h) e lobada (i). figura adaptada de (Ash <i>et al.</i> , 1999).	25
2.8	Tipos de Folhas com endentação: dentada (a), serrilhada (b) e crenada (c). Tipos de folhas sem endentação: inteira (d), revoluta (e) e erodida (f) (Ash <i>et al.</i> , 1999).	26
3.1	Um vaso ou um rosto (Keller, 2003) ?	27
3.2	Imagem do vaso (esq.), e as respectivas assinaturas $x(n)$ e $y(n)$ em (dir.).	28
3.3	Método de obtenção das assinaturas de contorno apical e basal, a partir do centróide.	29
3.4	Circunferência irregular (dir.) e sua assinatura em função de ângulo x distância centróide-borda (esq.).	29
3.5	Um exemplo de uma imagem e sua respectiva assinatura: <i>passos versus distância</i> .	30
3.6	Obtenção da assinatura pelo método ângulo-de-visão (Tchoukanov <i>et al.</i> , 1991).	31
3.7	Exemplo de uma assinatura de ângulo aplicada à <i>P. caerulea</i> .	31
3.8	Curvatura determinada a partir de vetores no ponto $c(n_0)$.	32
3.9	Exemplo de reconstrução de sinal pelos descritores de Fourier utilizando : (a) 300 descritores, (b) 120 descritores, (c) 60 descritores, (d) 30 descritores, (e) 20 descritores e (f) 10 descritores.	36

3.10	Contorno foliar da <i>P. caerulea</i> (a) e seus respectivos gráficos: espectro de Fourier (b), espectro da potência (c) e ângulo de fase (d).	38
3.11	Ilustração de um neurônio (a); e de um modelo perceptron (b).	39
3.12	Efeito do parâmetro Bias em v_k (Haykin, 1999).	40
3.13	Gráficos das funções de ativação: Limiar (a); Pricewise (b); Sigmoidal (c); Tangente hiperbólica (d).	41
3.14	Exemplo de caso em que uma rede perceptron (c) consegue separar duas classes (a) e, o caso em que a determinação de uma fronteira de separação não pode ser obtida (b).	42
3.15	Exemplos de configuração de redes neurais e as respectivas regiões de classificação (Gonzalez e Woods, 2000).	43
3.16	Tipos de arquiteturas de redes neurais (Braga & al., 2000).	44
3.17	Fluxos de algoritmo back-propagation: fase de propagação (feedforward) (a) e fase de retropropagação (feedback) (b) (Haykin, 1999).	45
3.18	Método multifold cross-validation	46
3.19	Exemplo de duas nuvens de classes distintas e os respectivos centróides (Banks, 1990).	48
3.20	Processo simplificado da aplicação de um algoritmo genético.	50
3.21	Crossover de N pontos.(Reproduzido com alterações de (Lacerda e Carvalho, 1999))	50
3.22	Crossover Uniforme.(Reproduzido com alterações de (Lacerda e Carvalho, 1999))	51
3.23	Aplicação do operador de mutação.(Reproduzido com alterações de (Lacerda e Carvalho, 1999))	51
4.1	Diagrama do processo de obtenção das redes de classificação, por sinais de contorno.	55
4.2	Amostras das classes utilizadas no experimento: <i>Passiflora amethystina</i> (01); <i>Passiflora caerulea</i> (02); <i>Passiflora coriacea</i> (03); <i>Passiflora foetida</i> (04); <i>Passiflora gibertii</i> (05) <i>Passiflora maliformis</i> (06); <i>Passiflora micrsii</i> (07); <i>Passiflora organensis</i> (08); <i>Passiflora pohlii</i> (09); <i>Passiflora suberosa</i> (10); <i>Miroxylon peruiiferum</i> (cabreúva - 10) (11); <i>Rauwolfia sellowii</i> (casca d'anta - 08) (12); <i>Pseudobombax grandiflorum</i> (imbiruçu - 07) (13); <i>Tabebuia impetiginosa</i> (ipê-roxo - 12) (14); <i>Syzygium jambolandum</i> (jambolão - 10) (15); <i>Hymenaea courbaril</i> (jatobá - 10) (16); <i>Cariniana estrellensis</i> (jequitibá - 09) (17); (lima - 10) (18); (limão - 10) (19); <i>Cordia trichotoma</i> (louro-pardo - 09) (20); <i>Eriotheca candoleana</i> (paina-da-mata - 10) (21); <i>Caesalpinia echinata</i> (pau-brasil - 25) (22); <i>Platycianus regnelli</i> (pau-pereira - 10) (23) <i>Eugenia uniflora</i> (pitanga - 13) (24); <i>Tapirira guianensis</i> (peito-de-pomba - 10) (25); (coqueiro de jardim - 20) (26); (desconhecida01 - 14) (27);(desconhecida02 - 10) (28); (desconhecida03 - 09) (29); (desconhecida04 - 15) (30); (desconhecida05 - 12) (31);	56
4.3	Programa Delphi de processamento em lote.	57
4.4	Esquematização da geração das assinaturas principais, a partir das assinaturas primárias.	58
4.5	Representação gráfica da interação entre os módulos	61
4.6	As etapas do processo de geração de amostras artificiais.	63
4.7	Processo de cross-over e mutação	64

4.8	Representação de um espectro de Fourier por uma gama de cores(a); espectro de Fourier de pais 1 (b); espectro de Fourier de pais 2 (c); espectro de Fourier de filhos resultantes do cruzamento de pais 1 e pais 2 (c).	65
4.9	Interfaces de seleção: conjunto de imagens sem seleção (a) e o mesmo conjunto após seleção (b).	66
4.10	Fechamento das curvas das amostras artificiais.	67
4.11	Geração dos classificadores.	68
B.1	Amostras geradas artificialmente da classe <i>Passiflora amethystina</i> (<i>amethystina</i>).	99
B.2	Amostras geradas artificialmente da classe <i>Passiflora caerulea</i> (<i>caerulea</i>).	100
B.3	Amostras geradas artificialmente da classe <i>Passiflora coriacea</i> (<i>coriacea</i>).	100
B.4	Amostras geradas artificialmente da classe <i>Passiflora foetida</i> (<i>foetida</i>).	101
B.5	Amostras geradas artificialmente da classe <i>Passiflora gibertii</i> (<i>gibertii</i>).	101
B.6	Amostras geradas artificialmente da classe <i>Passiflora maliformis</i> (<i>maliformis</i>).	102
B.7	Amostras geradas artificialmente da classe <i>Passiflora miersii</i> (<i>miersii</i>).	102
B.8	Amostras geradas artificialmente da classe <i>Passiflora organensis</i> (<i>organensis</i>).	103
B.9	Amostras geradas artificialmente da classe <i>Passiflora pohlii</i> (<i>pohlii</i>).	103
B.10	Amostras geradas artificialmente da classe <i>Passiflora suberosa</i> (<i>suberosa</i>).	104
B.11	Amostras geradas artificialmente da classe <i>Miroxylon peruiiferum</i> (<i>cabreúva</i>).	104
B.12	Amostras geradas artificialmente da classe <i>Rauwolfia sellowii</i> (<i>casca d'anta</i>).	105
B.13	Amostras geradas artificialmente da classe <i>Pseudobombax grandiflorum</i> (<i>im-biruçu</i>).	105
B.14	Amostras geradas artificialmente da classe <i>Tabebuia impetiginosa</i> (<i>ipê-roxo</i>).	106
B.15	Amostras geradas artificialmente da classe <i>Syzygium jambolanum</i> (<i>jambolão</i>).	106
B.16	Amostras geradas artificialmente da classe <i>Hymenaea courbaril</i> (<i>jatobá</i>).	107
B.17	Amostras geradas artificialmente da classe <i>Cariniana estrellensis</i> (<i>jequitibá</i>).	107
B.18	Amostras geradas artificialmente da classe <i>Cordia trichotoma</i> (<i>louro-pardo</i>).	108
B.19	Amostras geradas artificialmente da classe <i>Eriotheca candoleana</i> (<i>paina da mata</i>).	108
B.20	Amostras geradas artificialmente da classe <i>Caesalpinia echinata</i> (<i>pau-Brasil</i>).	109
B.21	Amostras geradas artificialmente da classe <i>Platycianus regnelli</i> (<i>pau-pereira</i>).	109
B.22	Amostras geradas artificialmente da classe <i>Eugenia Uniflora</i> (<i>pitanga</i>).	110
B.23	Amostras geradas artificialmente da classe <i>Tapirira guianensis</i> (<i>peito de pomba</i>).	110
B.24	Amostras geradas artificialmente da classe <i>coqueiro de jardim</i>	111
B.25	Amostras geradas artificialmente da classe <i>desconhecida 01</i> (<i>descon01</i>).	111
B.26	Amostras geradas artificialmente da classe <i>desconhecida 02</i> (<i>descon02</i>).	112
B.27	Amostras geradas artificialmente da classe <i>desconhecida 03</i> (<i>descon03</i>).	112
B.28	Amostras geradas artificialmente da classe <i>desconhecida 04</i> (<i>descon04</i>).	113
B.29	Amostras geradas artificialmente da classe <i>desconhecida 05</i> (<i>descon05</i>).	113
B.30	Amostras geradas artificialmente da classe <i>lima</i>	114
B.31	Amostras geradas artificialmente da classe <i>limao</i>	114

Lista de Tabelas

4.1	Acrônimos utilizados para composição dos nomes dos arquivos de assinaturas.	57
4.2	Exemplo das oito assinaturas primárias geradas de uma imagem.	57
4.3	Acrônimos utilizados para nomeação dos arquivos de sinais no domínio da frequência.	59
4.4	Exemplo das oito assinaturas secundárias geradas de uma imagem.	59
5.1	Aproveitamento das amostras artificiais geradas, em valores percentuais. .	71
5.2	Classes com os máximos percentuais obtidos por um classificador - por tipo de assinatura. Os tipos de marcadores que antecedem cada nome de classe significam: classificador previsto e obtido (+) , classificador não previsto (-) e classificador previsto e não obtido (!).	75
5.3	Distribuição de classificadores por tipo de assinaturas. Os tipos de marcadores que antecedem cada nome de classe significam: classificador previsto e obtido (+) , classificador não previsto (-) e classificador previsto e não obtido (!).	76
5.4	Distribuição de classificadores por variação do domínio. Os tipos de marcadores que antecedem cada nome de classe significam: classificador previsto e obtido (+) , classificador não previsto (-) e classificador previsto e não obtido (!).	77
5.5	Distribuição de classificadores por tipo intervalo de frequência. Os tipos de marcadores que antecedem cada nome de classe significam: classificador previsto e obtido (+) , classificador não previsto (-) e classificador previsto e não obtido (!).	78
A.1	Potencial de classificação para a classe <i>P. amethystina</i>	83
A.2	Potencial de classificação para a classe <i>P. caerulea</i>	84
A.3	Potencial de classificação para a classe <i>P. coriacea</i>	84
A.4	Potencial de classificação para a classe <i>P. foetida</i>	85
A.5	Potencial de classificação para a classe <i>P. gibertii</i>	85
A.6	Potencial de classificação para a classe <i>P. maliformis</i>	86
A.7	Potencial de classificação para a classe <i>P. miersii</i>	86
A.8	Potencial de classificação para a classe <i>P. organensis</i>	87
A.9	Potencial de classificação para a classe <i>P. pohlii</i>	87
A.10	Potencial de classificação para a classe <i>P. suberosa</i>	88
A.11	Potencial de classificação para a classe <i>Miroxylon peruiferum</i> (Cabreúva) . .	88
A.12	Potencial de classificação para a classe <i>Rauwolfia sellowii</i> (Casca d'anta) .	89

A.13	Potencial de classificação para a classe <i>Pseudobombax grandiflorum</i> (Imbiruçu)	89
A.14	Potencial de classificação para a classe <i>Tabebuia impetiginosa</i> (Ipê-Roxo)	90
A.15	Potencial de classificação para a classe <i>Syzygium jambolanum</i> (Jambolão)	90
A.16	Potencial de classificação para a classe <i>Hymenea courbaril</i> (Jatobá)	91
A.17	Potencial de classificação para a classe <i>Cariniana estrellensis</i> (Jequitibá)	91
A.18	Potencial de classificação para a classe <i>Cordia trichotoma</i> (Louro-pardo)	92
A.19	Potencial de classificação para a classe <i>Eriotheca candolleana</i> (Paina da mata)	92
A.20	Potencial de classificação para a classe <i>Caesalpinia echinata</i> (Pau-Brasil)	93
A.21	Potencial de classificação para a classe <i>Platycianus regnelli</i> (Pau-Pereira)	93
A.22	Potencial de classificação para a classe <i>Eugenia Uniflora</i> (Pitanga)	94
A.23	Potencial de classificação para a classe <i>Tapirira guianensis</i> (Peito de Pomba)	94
A.24	Potencial de classificação para a classe Coqueiro de Jardim	95
A.25	Potencial de classificação para a classe Descon01	95
A.26	Potencial de classificação para a classe Descon02	96
A.27	Potencial de classificação para a classe Descon03	96
A.28	Potencial de classificação para a classe Descon04	97
A.29	Potencial de classificação para a classe Descon05	97
A.30	Potencial de classificação para a classe Lima	98
A.31	Potencial de classificação para a classe Limão	98
C.1	Resultados da classificação do conjunto de amostras artificiais através da assinatura de contorno angular (aang), considerando-se as variações do intervalo de frequência e do domínio da frequência.	115
C.2	Resultados da classificação do conjunto de amostras artificiais através da assinatura de ângulo de visão (angv), considerando-se as variações do intervalo de frequência e do domínio da frequência.	116
C.3	Resultados da classificação do conjunto de amostras artificiais através da assinatura de contorno global (cntgb), considerando-se as variações do intervalo de frequência e do domínio da frequência.	116
C.4	Resultados da classificação do conjunto de amostras artificiais através da assinatura de contorno apical (cntap), considerando-se as variações do intervalo de frequência e do domínio da frequência.	117
C.5	Resultados da classificação do conjunto de amostras artificiais através da assinatura de contorno basal (cntba), considerando-se as variações do intervalo de frequência e do domínio da frequência.	118
C.6	Resultados da classificação do conjunto de amostras artificiais através da assinatura de curvatura global (crvgb), considerando-se as variações do intervalo de frequência e do domínio da frequência.	118
C.7	Resultados da classificação do conjunto de amostras artificiais através da assinatura de curvatura apical (crvap), considerando-se as variações do intervalo de frequência e do domínio da frequência.	119
C.8	Resultados da classificação do conjunto de amostras artificiais através da assinatura de curvatura basal (crvba), considerando-se as variações do intervalo de frequência e do domínio da frequência.	120
D.1	Resultados da classificação do conjunto de amostras reais através da assinatura de contorno angular (aang), considerando-se as variações do intervalo de frequência e do domínio da frequência.	121

D.2	Resultados da classificação do conjunto de amostras reais através da assinatura de ângulo de visão (angv), considerando-se as variações do intervalo de frequência e do domínio da frequência.	122
D.3	Resultados da classificação do conjunto de amostras reais através da assinatura de contorno global (cntgb), considerando-se as variações do intervalo de frequência e do domínio da frequência.	122
D.4	Resultados da classificação do conjunto de amostras reais através da assinatura de contorno apical (cntap), considerando-se as variações do intervalo de frequência e do domínio da frequência.	123
D.5	Resultados da classificação do conjunto de amostras reais através da assinatura de contorno basal (cntba), considerando-se as variações do intervalo de frequência e do domínio da frequência.	124
D.6	Resultados da classificação do conjunto de amostras reais através da assinatura de curvatura global (crvgb), considerando-se as variações do intervalo de frequência e do domínio da frequência.	124
D.7	Resultados da classificação do conjunto de amostras reais através da assinatura de curvatura apical (crvap), considerando-se as variações do intervalo de frequência e do domínio da frequência.	125
D.8	Resultados da classificação do conjunto de amostras reais através da assinatura de curvatura basal (crvba), considerando-se as variações do intervalo de frequência e do domínio da frequência.	126

Introdução

1.1 Justificativa e Motivação

No ambiente terrestre, os vegetais são os únicos seres vivos capazes de retirar energia do sol, através do processo da fotossíntese, transformando gás carbônico, água e luz, em glicose. Esse processo ocorre em toda a superfície da planta onde clorofila está presente. Entretanto, foram as folhas os órgãos que se especializaram nesta tarefa. Esta especialização refletiu-se por meio de modificações na forma das folhas e no respectivo sistema de venação (nervura), buscando uma maior eficiência na captação de luz e melhor circulação da seiva bruta/eleborada, a medida que as espécies vegetais foram se adaptando às variações ambientais.

Através da observação de uma folha, pode-se ter uma idéia da vitalidade da planta e sua possível espécie, mas fazendo-se uso de medidas biométricas, nesses órgãos (Eames e Macdaniels, 1947) (Gola, 1965) (Ilichev, 1973) (Lima, 1995) (Lopes, 1999) (Germano Filho, 1999), é possível obter informações mais objetivas e precisas, as quais são freqüentemente utilizadas na botânica e na fisiologia vegetal, fornecendo bases para diversos estudos tais como:

- taxonomia; para a identificação de espécies;
- comportamento do vegetal mediante variações ambientais
- alterações da forma da folhas ou alterações da configuração das nervuras;
- análise de falta ou excesso de nutrientes no solo - o pode influir na configuração da forma da folha e sistema de venação, entre outras.

Atualmente a aquisição de informações biométricas é realizada manualmente (Vicente *et al.*, 1999), requerendo treinamento técnico e um grande esforço na realização das medidas, caracterizando-o com um trabalho massivo e prolongado. Além disso, as medidas obtidas dessa maneira, não são tão precisas e podem conter erros causados pela manipulação humana. Quando se trata da identificação de espécies, há o fator de erro causado pela subjetividade, pois a identificação se procede comparando-se a suposta nova espécie com espécies já catalogadas em herbários - dessa forma a classificação fica por conta do “olho” do executor da tarefa, o que demanda também um longo tempo.

1.2 Objetivos

Visando minimizar os problemas de classificação acima citados, o objetivo deste trabalho é o de selecionar, implementar e testar alguns métodos biométricos para a realização da identificação de espécies arbóreas através da análise do contorno foliar.

1.3 Organização

Esta dissertação é composta por mais seis capítulos. No segundo capítulo, o qual trata sobre biometria vegetal, é feita uma breve apresentação do projeto TreeVis e também são abordadas técnicas biométricas para identificação de vegetais, através da análise da arquitetura foliar. Uma breve introdução à morfologia foliar é feita e paralelamente são apontadas as características biométricas exploradas na execução do trabalho e quais os métodos que foram utilizados.

O terceiro capítulo apresenta os conceitos e métodos envolvidos na descrição, análise e classificação de contornos. Na Seção 3.1, de descrição de contornos, são apresentadas as seguintes assinaturas: assinaturas por coordenadas paramétricas, assinatura de ângulo $\times$ distância, passos $\times$ distância, assinatura de ângulo de visão e curvatura. Na Seção 3.2, métodos de análise de assinaturas de contornos são apresentados, tais como: a transformada de Fourier e o espectro da potência, enfocando a obtenção de descritores a partir dos sinais obtidos das assinaturas citadas da primeira Seção. Na terceira e última seção (Seção 3.3) são apresentados dois tipos de classificadores: redes neurais e classificador por distância mínima. Este último apesar de ser registrado neste capítulo apresentou um péssimo desempenho para a classificação das 31 espécies de folhas. Essa seção é encerrada tratando sobre o conceito de algoritmos genéticos e suas aplicações, com um maior foco voltado para sobre os operadores genéticos de cross-over e mutação. Apesar de parecer deslocado do contexto, este último assunto teve extrema importância com relação à preparação de amostras para a geração de redes neurais.

O quarto capítulo descreve todo o procedimento experimental, desde o tratamento das amostras de folhas até a obtenção dos classificadores por redes neurais. O processo experimental para ser melhor acompanhado foi dividido em sete seções: a Seção 4.1 traz uma visão geral do problema: classificação de 31 espécies de folhas com uma baixa quantidade de amostras e alta quantidade de parâmetros para serem avaliados; as Seções 4.2 e 4.3 tratam respectivamente das características das amostras e do pré-processamento para a obtenção dos sinais (assinaturas); a Seção 4.4 apresenta o método leave-one-out utilizado para a seleção dos parâmetros (tipos de assinaturas e intervalos de frequência) que serão considerados para a construção dos classificadores utilizando-se de redes neurais; a Seção 4.5 apresenta um método desenvolvido pelo autor para a obtenção de amostras artificiais através do uso de operadores genéticos, a partir dos sinais de contorno no domínio da frequência; a Seção 4.6 apresenta o ambiente utilizado para criação, treinamento e teste de redes neurais de forma automática e última seção (4.7) refere-se à validação das redes geradas por meio de amostras artificiais, aplicando-as na classificação de amostras reais. O capítulo é encerrado com as considerações finais.

No Capítulo 5 são apresentados e discutidos os resultados obtidos por cada etapa do procedimento experimental, conforme dividido em Seções, no Capítulo 4. O Capítulo 5 é finalizado com alguns comentários e observações, analisando o desempenho da solução proposta.

O Capítulo 6 apresenta a conclusão do trabalho, as respectivas contribuições geradas e os possíveis trabalhos futuros.

Análise de vegetais

2.1 O Projeto TreeVis e Biometria Foliar

Na primeira seção deste capítulo é apresentado o projeto TreeVis onde abordado-se: a motivação da criação do projeto, os fundamentos de funcionamento e descrição do sistema. Neste último tópico, são apresentados os módulos que o compõem e as possibilidades de evolução do projeto, com relação à análise do contorno foliar. Na segunda seção, são vistos alguns métodos biométricos para a caracterização de vegetais através da arquitetura foliar, definidos em (Ash & al., 1999) e paralelamente são apresentados os métodos de análise de contorno que foram aplicados, para a execução do trabalho, justificados os métodos que foram descartados. Esta segunda parte tem por objetivo, traçar uma correspondência com os métodos apresentados em (Ash & al., 1999), com métodos de análise de contorno que são apresentados em um capítulo posterior.

2.2 Projeto TreeVis

Nome derivado da junção das palavras (Tree Vision System), o projeto TreeVis é um sistema projetado e desenvolvido para se tornar um herbário eletrônico e também uma ferramenta para biomorfometria de folhas. Este sistema é o resultado de um projeto de pesquisa de doutorado (Bruno, 2000).

A motivação para o desenvolvimento desse sistema foi a necessidade de um método mais eficaz e menos trabalhoso de classificação de plantas, através das informações contidas em uma folha. Mas por que através de folhas? Para melhor entender sua importância e os motivos envolvidos na utilização de folhas como identificação de espécies, primeiramente devemos descrever rapidamente o processo de coleta e identificação de uma espécie, e as dificuldades envolvidas. A coleta por si só, já apresenta um grande inconveniente no processo convencional. Para uma coleta visando à identificação da espécie, necessita-se coletar de um espécime adulto, ramos que possuam flores, folhas e frutos. Ora se pensarmos na grande diversidade de espécies contidas em nosso país, sua extensão territorial e lembrarmos que, cada espécie tem sua época própria de floração e frutificação, tem-se aí um cenário bastante complexo para ser resolvido, podendo ser considerado impossível quando lembramos que, atualmente órgãos do governo como IBAMA e outros, possuem um quadro de pessoal para atividades básicas como o de fiscalização, insuficiente para o

nosso território.

O processo de identificação elaborado por Linnaeus (Ash *et al.*, 1999) (Waggoner, 2003) baseado na comparação de folhas, flores e frutos é um trabalho muito moroso necessitando de um botânico experiente em taxionomia vegetal. O especialista de posse da amostra a ser identificada, faz uma análise comparativa com outras espécies semelhantes, armazenadas em herbários. Este tipo de trabalho além de muito cansativo depende totalmente de quão treinado está o olho do botânico. Outro inconveniente neste processo, é que a classificação somente pode ocorrer nos herbários, pois é inviável o transporte de pranchas de plantas secas, a campo.

No sentido de propiciar um processo mais ágil, eficiente e confiável, surge a proposta do TreeVis, que possui outras vantagens tais como:

- Possibilidade de classificação em campo. Bastando para isto, apenas um laptop e um scanner;
- Possibilidade de intercâmbio de dados. Órgãos como IBAMA, universidades e ONGS interessadas em mapeamento e classificação de espécies, podem promover um intercâmbio de dados para que todas as bases sejam consistentes, e que não sejam desperdiçados recursos para catalogação de espécies já presentes em outras bases.
- Sem limitação de expansão da coleção do herbário digital (a não ser pela mídia que o armazenará), enquanto que herbários convencionais necessitam de espaço físico e ambiente adequado para a conservação das pranchas com os espécimes prensados;
- Baixo risco de perda da coleção. Enquanto um herbário está sujeito a danos por ataque de fungos, umidade ou incêndio; um herbário digital por se encontrar sob a forma de arquivo de dados, pode ser copiado, mantendo-se diversas cópias de segurança.

2.2.1 Fundamentos e Descrição do Sistema

O bom funcionamento do TreeVis tem como base a aplicação de quatro fundamentos:

i) Exploração sistemática das características das folhas por meio de um vasto número de atributos obtidos de folhas: Isto é, são utilizados 165 elementos de medidas para compor um vetor de característica, sendo que estes elementos estão distribuídos nas seguintes categorias: níveis de cinza, cor, forma, textura/complexidade e histograma;

ii) Sinergismo: Obtido da combinação dos atributos que compõem um vetor de característica, o que resulta em um potencial de classificação muito maior do que a soma dos potenciais individuais de cada método.

iii) Análise estatística: Na qual se baseia a classificação e o reconhecimento. A análise estatística também definirá a metodologia de comparação e identificação de espécies.

iv) Metodologia de utilização: Este é o ponto chave onde o especialista do domínio, o botânico, terá a preocupação de aplicar seu conhecimento para garantir a consistência das informações que serão adquiridas pelo sistema TreeVis. Pois compete a ele, a obtenção de amostras representativas de uma espécie, sabendo se as folhas obtidas são de um espécime adulto, se a variabilidade de formatos de folhas do mesmo indivíduo está dentro do esperado, ou se este está sofrendo algum tipo de anomalia de formação. Vale a pena ressaltar que, o esforço empregado agora pelo especialista é efetivamente direcionado para a descoberta e identificação de novas espécies, não havendo perda de tempo em atividades secundárias, ou de traslado para herbários convencionais.

Para que estes fundamentos sejam operantes, o sistema TreeVis foi implementado basicamente em cinco módulos conforme é apresentado na Figura 2.1. Objetivando apresentar melhor a dinâmica do sistema, cada módulo será brevemente descrito, seguindo-se o fluxo do processo de identificação de uma amostra.

Figura 2.1: Representação dos módulos do sistema TreeVis e suas interações (Bruno, 2000).

O processo de reconhecimento inicia-se com a aquisição de imagens de uma folha. Para cada amostra, são obtidas três imagens: uma imagem da folha do lado do sol, outra do lado da sombra e a terceira imagem, é um detalhe ampliado de uma determinada região da folha para análise de textura. Este conjunto de imagens é denominado de Estrutura de Amostragem. A partir desta Estrutura de Amostragem, o Controle Central é responsável por enviar cada um dos 3 tipos de imagens para o módulo de Extração de Características, selecionando os respectivos sub-módulos (Níveis de Cinza, Cor, Forma, Textura-Complexidade e Histograma) adequados ao tipo de imagem. Após a extração dos vetores de características estes são encaminhados (pelo Controle Central), para o módulo de Treinamento e Identificação que através de busca e comparação na Base de Dados e pela atuação conjunta com módulo de Análise Estatística, realizam a identificação da amostra, selecionando a lista de espécies mais prováveis à qual a amostra pode pertencer. Caso seja constatado que a amostra se trata de uma nova espécie, esta será adicionada à base de dados, através de uma seqüência de procedimentos que deverá ser executada pelo botânico.

Apesar de ter sido uma apresentação seqüencial, cabe aqui ressaltar que o sistema TreeVis foi projetado e implementado para ser um sistema paralelo, e que esta dissertação não entrará em detalhes por não pertencer ao escopo do trabalho.

2.2.2 Atual situação do protótipo e os métodos de análise estudados

Um dos pontos fundamentais de qualquer sistema de visão computacional é a obtenção de vetores característicos representativos, isto é, que melhor diferencie os objetos a serem reconhecidos. No sistema TreeVis, uma folha para ser reconhecida atualmente, necessita

ser representada por um vetor de características de 165 elementos, dentre os quais apenas 15 desses (9%) são referentes à forma da folha: 3 baseados na energia de dobramento multi-escala (Cesar, 1997) e 12 em descritores de Fourier baseado no contorno (Gonzalez e Woods, 2000). É neste sub-módulo que este trabalho de mestrado se encaixou, pois estudou e implementou outros métodos de análise baseados no contorno foliar, com o intuito de que fossem suficientes para a identificação de espécies. O conjunto de assinaturas exploradas foi composto pelos seguintes tipos: contorno global da folha, contorno apical da folha, contorno basal, curvatura global da folha, curvatura apical da folha, curvatura basal da folha, assinatura angular e assinatura de ângulo de visão. As quais foram analisadas no domínio da frequência (Fourier e Power Spectrum).

Basicamente as assinaturas de contorno global, apical e basal são vetores do contorno paramétrico da folha toda(global), e das regiões apicais e basais. Os tipos de assinaturas utilizadas serão apresentadas no Capítulo 3. A ideia de subdivisão da área de uma folha em regiões apical e basal e outros conceitos de caracterização de folhas utilizadas por Ash *et al.* (1999) são descritos na Seção 2.3.

Embora o método de dimensão fractal desenvolvido em (Plotze *et al.*, 2003) tenha apresentado excelentes resultados para a caracterização de espécies vegetais, este foi insuficiente quando aplicado apenas no contorno foliar.

2.3 Biometria Foliar

2.3.1 Introdução

A classificação de vegetais através da análise da arquitetura foliar, já possui algumas décadas de existência. A ideia surgiu com a necessidade de classificação de espécies vegetais fósseis que, como era de se esperar, não eram encontrados com seus respectivos frutos e flores; necessários para a classificação taxionômica, iniciada por Karl Linnaeus (Ash *et al.*, 1999). Na segunda metade do século XX, surgiram duas abordagens para taxionomia vegetal. A primeira, baseada na classificação através do estudo de múltiplos órgãos (incluindo folhas), e a segunda cuja classificação é apoiada na identificação sistemática de informações de características das folhas, o que permitiu que espécies fossem reconhecidas (Hikey e Taylor, 1991; Hikey e Wolfe, 1975) apud (Ash *et al.*, 1999). Mas foi em (Hickey, 1973) que o processo descritivo quanto à forma da folha e seu sistema de venação é melhor definido. A Figura 2.2, apresenta uma folha e sua estrutura básica.

A seguir, são apresentados os atributos e suas respectivas classificações, considerados por (Ash *et al.*, 1999), de interesse para a identificação de espécies, por meio da análise da arquitetura foliar. Atributos que não estão relacionados diretamente com o contorno foliar, não são comentados, por não pertencerem ao escopo do trabalho. Os atributos apresentados são: forma laminar, ângulos basal e apical, forma basal e apical da folha, tipos de endentação de contorno e tipos de lobos.

2.3.2 Forma Laminar

Basicamente são definidos quatro tipos de formas de folhas, conforme é apresentado na Figura 2.3: (a) Elíptica; (b) Obovata; (c) Ovata e (d) Oblonga. Estas classificações são obtidas em função da posição da maior perpendicular ao eixo principal, que pode ser inscrita dentro dos limites da folha. Observe que na folha da Figura 2.3 (a), a maior perpendicular inscrita, passa quase pelo centro da folha. Considerando a disposição dos dois eixos pode-se quase ver a configuração de uma elipse, motivo pelo qual, a folha é classificada como elíptica. Dessa forma temos as variações: obovata: quando a maior

Figura 2.2: Uma Folha e suas estruturas básicas (Ash & al., 1999).

perpendicular se localizar mais próxima a área apical; ovata: quando maior perpendicular estiver localizada mais próxima a área basal da folha e; a oblonga: quando temos uma faixa central na folha onde as bordas opostas são praticamente paralelas.

2.3.2.1 Possibilidades Biométricas exploradas

Para a forma laminar, foi utilizado o contorno paramétrico global, analisado no domínio da frequência (Fourier e Power Spectrum).

2.3.3 Ângulos Basal e Apical

A medida do ângulo apical e basal é classificada em (Ash & al., 1999) como : agudo, obtuso e intensamente obtuso. Estas medidas são definidas em função das extremidades inferior(basal) e superior(apical) do eixo central sendo l_m o comprimento da nervura central. A Figura 2.4 apresenta alguns formatos de folhas e o referido atributo de medida l_m , além de outros tais como: l_a - extensão apical e; l_b - extensão basal. Sendo que o comprimento foliar é definido por $L = l_m + l_a + l_b$.

Dessa forma, a medida do ângulo apical é definida pelo ângulo formado entre dois segmentos de reta, que partem da extremidade superior do eixo central da folha, e se estendem até aos pontos da borda, definidos pela intersecção da perpendicular que está a uma distância de $0,75l_m$ (Figura 2.5(a1-a5)). Similarmente, o ângulo basal é definido pelo ângulo formado entre dois segmentos de reta, que partem da extremidade inferior do eixo central da folha, e se estendem até aos pontos de borda, definidos pela perpendicular, que está a uma distância de $0,25l_m$ (Figura 2.5(b1-b3)). Casos de folhas com número de lobos ímpar, $l_a > 0$ (extensão apical) ou com $l_{b1-b3} > 0$ (extensão basal), possuem um método específico de cálculo (Ash & al., 1999).

Figura 2.3: Principais formas foliares: Elíptica (a); Obovata (b); Ovata (c), Oblonga (d) e um outro exemplo de folha elíptica apesar de lobada (e). Figura reusada de (Ash *et al.*, 1999).

2.3.3.1 Possibilidades Biométricas exploradas

A análise dos ângulos da região apical e basal foi feita através da obtenção do sinal de curvatura de cada região, as quais foram analisadas sob o domínio da frequência (Fourier e Power Spectrum). Esta abordagem também foi feita de modo global, isto é, considerou-se além da curvatura apical e basal, a curvatura da folha como um todo.

Figura 2.4: Forma básicas de folhas e os respectivos parâmetros de medida: L , l_m , l_a e l_b (Ash *et al.*, 1999).

Figura 2.5: Exemplos de folhas e seus tipos de ângulos apicais (a1-a5) e basais (b1-b3) (Ash *et al.*, 1999).

2.3.4 Forma basal e apical

Em (Ash *et al.*, 1999) as formas das regiões apical e basal são utilizadas para a identificação de uma espécie. As regiões analisadas são as áreas compreendidas entre a base da folha e a distância de $0,25L$ - no caso da região basal; e do ápice à distância $0,75L$ no caso da região apical.

Referente à classificação da forma da região basal, esta pode ser dividida em dois grupos: os de $l_b = 0$ classificados em cuneiforme, convexa, ovalada, truncada, côncava, côncava-convexa, decurrent e complexa; e os de $l_b \neq 0$ classificadas em cordata, lobata e saginata, para $l_b > 0$ e classifiado como astato com $l_b \sim 0$ (ver Figura 2.6). No caso da região apical, tem-se a seguinte classificação: lisa, convexa arredondada, truncada acuminada e complexa - todas estas com $l_a = 0$. Quando $l_a > 0$ então a região apical pode ser classificada em : retusa (retuse), emarginata (emarginate) ou lobada (lobed) (ver a Figura 2.7).

Figura 2.6: Formas basais: cuneiforme (a), convexa (b), ovalada (c), truncada (d), concava (e), côncava-convexa (f), decurrent (g), complexa (h) cordata (i), lobata (j), saginata (k) e astato (l). adaptado de (Ash *et al.*, 1999).

Figura 2.7: Formas apicais: lisa (a), convexa (b), arredondada (c), truncada (d), acuminada (e), complexa (f), retusa (g), emarginata (h) e lobada (i). figura adaptada de (Ash *et al.*, 1999).

2.3.4.1 Possibilidades Biométricas exploradas

Apesar de induzir a uma análise de curvatura no experimento (já abordada anteriormente), a descrição da forma das regiões apical e basal, foram representadas através da assinatura de contorno paramétrico, analisadas também no domínio da frequência.

2.3.5 Endentação de contorno e lobação

Outra análise feita para a caracterização de uma folha, apresentada por (Ash *et al.*, 1999), é o tipo de endentação que cada espécie possui em sua borda. Uma folha, quando apresenta endentação é classificada como um dos seguintes tipos: dentada, serrilhada ou crenada; conforme é mostrado na Figura 2.8(a-c). Quando não há a presença de endentação no contorno da folha, esta pode ser: inteira, revoluta ou erodida, conforme é mostrado na Figura 2.8(d-f).

Figura 2.8: Tipos de Folhas com endentação: dentada (a), serrilhada (b) e crenada(c). Tipos de folhas sem endentação: inteira (d), revoluta (e) e erodida (f) (Ash *et al.*, 1999).

2.3.5.1 Possibilidades Biométricas exploradas

Neste tipo de atributo pensou-se em aplicar a determinação da dimensão fractal (Plotze *et al.*, 2003) de uma área padrão de borda, entretando conforme motivo mencionado na Seção 2.2.2, optou-se em explorar as altas frequências do espectro de Fourier das respectivas assinaturas de contorno paramétrico global, apical e basal. Sendo que a respeito da caracterização de lobação de uma folha também fica contemplada pelas assinaturas citadas.

2.4 Considerações Finais

Na primeira seção deste capítulo, foi descrito o projeto TreeVis, e apresentada a atual situação do protótipo, quanto à extração de características; o que permitiu ter uma visão das possibilidades de evolução deste, e de situar em qual ponto (do protótipo), este trabalho de mestrado contribuiu. Na segunda seção foram apresentados os métodos de caracterização de uma folha quanto à sua estrutura externa, sugerida por (Ash *et al.*, 1999), nos quais este trabalho se baseou. Paralelamente foram explicitadas as alternativas para a extração de características quantitativas, aplicando-se os métodos de análise de contorno que são apresentados no Capítulo 3.

Descrição, análise e classificação de contornos

O objetivo deste capítulo é o de apresentar o embasamento teórico dos métodos utilizados na descrição, análise e classificação das espécies vegetais, exclusivamente através do uso do contorno foliar. Dessa maneira, este capítulo foi dividido em três seções, tratando respectivamente de: i) métodos de descrição: onde serão apresentadas as assinaturas utilizadas para a caracterização das formas das folhas; ii) métodos de análises: trata do uso da transformada de Fourier e do espectro de potência como um meio para a análise das assinaturas obtidas; iii) métodos de classificação: este último aborda os métodos de classificação estudados e utilizados no experimento, incluindo algoritmos genéticos.

3.1 Métodos para descrição de contornos

Quando observamos um objeto novo, normalmente o primeiro reflexo de qualquer pessoa, é o de tentar identificá-lo, comparando sua forma (contorno) com formas já conhecidas e guardadas em nossa memória. Este processo intuitivo de reconhecimento, muitas vezes pode ser enganado. Veja a Figura 3.1. Observe que a mesma figura pode transmitir informações diferentes, dependendo do foco de atenção. Se a atenção for focada somente nos contornos laterais, dois rostos são vistos. Caso todo o contorno seja considerado, um vaso é visto. Este é um exemplo de como a visão humana pode ser enganada.

Figura 3.1: Um vaso ou um rosto (Keller, 2003) ?

O reconhecimento de objetos, sob a perspectiva da visão computacional, envolve métodos objetivos e quantitativos, permitindo que a forma de um objeto seja descrita em função de valores numéricos, para que posteriormente sejam processados e comparados com padrões, na tentativa de um reconhecimento. Nas subseções seguintes, alguns desses métodos são apresentados.

3.1.1 Assinatura por Coordenadas Paramétricas

Um dos mais simples métodos de assinaturas é baseada na separação das componentes das coordenadas de pontos (x,y) (Costa e Cesar, 2001). Esta decomposição transforma o contorno de uma forma, em dois sinais de 1D que ficam em função do número de passos do contorno, assim um objeto é expresso por dois sinais, conforme é apresentado na Figura 3.2. Uma característica desta assinatura é sua variância quanto à translação, rotação e escala da forma.

Figura 3.2: Imagem do vaso (esq.), e as respectivas assinaturas $x(n)$ e $y(n)$ em (dir.).

3.1.1.1 Assinatura Apical e Basal de uma folha

Derivada da metodologia de classificação descrita em (Ash et al., 1999) as assinaturas de contorno apical e basal necessitam que a imagem da folha esteja corretamente orientada para que os contornos apicais e basais sejam extraídos. Em virtude da grande variabilidade de tipos de folhas existentes na natureza, a automatização da orientação de uma imagem de folha possui uma considerável complexidade, em função da dificuldade do reconhecimento automático das respectivas regiões.

Partindo-se de uma imagem de folha já orientada, ficando a região apical posicionada na parte superior e conseqüentemente a região basal ficando localizada na parte inferior da imagem, a obtenção das respectivas assinaturas pode ser feita aplicando-se um algoritmo de extração de contorno (Pavlidis, 1982), que retorne as assinaturas da parte superior (apical) e parte inferior (basal), separadas. Este “corte” do contorno em dois sinais independentes, pode ser obtido utilizando-se, como base, uma linha horizontal que divida a forma em duas partes e passe pelo respectivo centróide (Figura 3.3).

Figura 3.3: Método de obtenção das assinaturas de contorno apical e basal, a partir do centróide.

3.1.2 Assinatura : Ângulo x Distância

O conceito envolvido na assinatura de uma imagem é o de representar a forma em estudo, através de um sinal unidimensional tal que este possa ser analisado e processado através de técnicas de processamento de sinal. Em (Gonzalez e Woods, 2000) há um exemplo de um tipo de assinatura, que é apresentada na Figura 3.4. O método se baseia no levantamento da distância do centróide à borda, em função da variação do ângulo de varredura do raio, que parte do centróide em intervalos de θ constante.

Figura 3.4: Circunferência irregular (dir.) e sua assinatura em função de ângulo x distância centróide-borda (esq.).

Uma desvantagem desse método é que se pode ter mais de um ponto do contorno sob o mesmo ângulo (caso a forma da figura analisada apresente muitas reentrâncias), tornando necessário uma regra de escolha do ponto que será considerado. Algumas opções seriam a seleção do ponto mais distante ou do ponto mais próximo do centróide, ou então de um valor médio dos pontos onde o raio cruzar (Costa e Cesar, 2001).

3.1.3 Assinatura: Passos x Distância

Uma outra maneira de se obter a assinatura de um objeto e que contorne o problema de reentrâncias, é compor a assinatura utilizando a distância centróide-borda pelo número de passos do contorno da figura. Isto é feito, a partir de um algoritmo de obtenção de contorno que percorre toda a borda do objeto e, cuja condição de parada é definida pelo retorno, ao ponto de partida (Pavlidis, 1982). São obtidos a distância centróide-borda e o respectivo passo dado no percorrimeto do contorno. Isto é, cada ponto da borda é contado sequencialmente, e um gráfico de *número de passos versus distância* é construído. Observe a Figura 3.5 na qual é apresentada uma forma e seu respectivo gráfico de assinatura.

Figura 3.5: Um exemplo de uma imagem e sua respectiva assinatura: *passos versus distância*.

Este método de assinatura, baseado na distância centróide-borda, não apresenta variação quando o objeto é transladado, entretanto para os casos de rotação e variação de escala, algumas providências devem ser tomadas para se garantir a consistência do método.

Uma maneira de se contornar o problema de rotação é a seleção do ponto inicial do gráfico tendo como critério aquele que apresentar maior distância. Este tipo de abordagem irá garantir que para objetos de formas iguais, tenhamos sempre o mesmo ponto de início da assinatura, tornando possível uma normalização e viabilizando a realização de análises comparativas. Uma inconveniência desta estratégia é que não surtirá um resultado efetivo, caso exista mais de uma distância máxima. Uma alternativa apresentada por (Gonzalez e Woods, 2000) é a seleção do ponto sobre o maior auto-vetor que esteja mais distante do centróide, infelizmente este recurso tem alto custo computacional, devido à necessidade do cálculo da matriz de covariância de todos os pontos do contorno.

Outro problema a ser enfrentado, é referente à variação de escala. Para isto, pode-se aplicar uma normalização, restringindo a variação do domínio dentro de um intervalo conhecido, como por exemplo, $[0,1]$. Infelizmente este tipo de solução, trás um sério inconveniente. Se o contorno for muito ruidoso, a normalização da escala da assinatura estará comprometida. Uma solução apresentada por (Gonzalez e Woods, 2000) é a adoção de um sistema de normalização, que ao contrário de se utilizar de valores de máximo e mínimo, faz uso da variância como um fator de divisão dos valores amostrados. O preço a ser pago por este sistema é um alto custo computacional.

3.1.4 Assinatura pelo ângulo-de-visão

Em (Tchoukanov *et al.*, 1991) é apresentado um método de assinatura denominado de Ângulo-de-Visão. Este método constrói a assinatura de um objeto, a partir da inscrição de um triângulo no interior da forma. Um exemplo é apresentado na Figura 3.6, tendo como parâmetros: $\overline{AB}$ - denominado de corda-de-visão (COS); α - ângulo de visão; C - ponto de varredura do contorno e l - comprimento do arco. Segundo a Figura 3.6 (a), o valor de α pode ser obtido pela equação :

$$f(l) = \arccos \left(\frac{d_1^2(l) + d_2^2(l) - d^2}{2d_1(l)d_2(l)} \right), f(l) \subseteq (0, \pi) \quad (3.1)$$

Figura 3.6: Obtenção da assinatura pelo método ângulo-de-visão (Tchoukanov *et al.*, 1991).

Figura 3.7: Exemplo de uma assinatura de ângulo aplicada à *P. caerulea*.

As características apresentadas por este tipo de assinatura são: (i) periódico se o contorno é fechado; (ii) invariante à transformações; (iii) variante quanto ao ponto inicial e; (iv) computacionalmente barato. Sua aplicação tem como ponto chave, para que haja

consistência¹, a determinação da corda-de-visão (cord-of-sight - COS) definido pelo segmento $\overline{AB}$ do triângulo. Veja exemplo da assinatura aplicada em uma folha na Figura 3.7

3.1.5 Curvatura

Considerada uma das mais importantes características para a análise de uma forma, sua importância foi evidenciada pelo trabalho de Fred Attenave (Attenave, 1954). Em seu experimento, ele propunha que alguns voluntários tentassem adivinhar cenas, por dedução, tendo como referência apenas partes destas. Por este experimento, ficou demonstrado que regiões com poucas variações de contorno (curvatura), apresentaram baixas taxas de erro na dedução, enquanto que as altas taxas de erros eram identificadas em áreas de quinas e grandes curvaturas (Costa e Cesar, 2001). Para a visão computacional é necessário que a análise de curvatura seja feita de modo objetivo e quantitativo, dessa forma alguns métodos de cálculo e análise de curvatura serão a apresentados a seguir.

Primeiramente, define-se curvatura como sendo a taxa de variação de inclinação de um segmento. O método de cálculo pode variar de acordo com a forma com que o contorno é matematicamente definido. Como foi visto na Seção 3.1.1, pode-se representar um contorno por equações paramétricas, isto é:

$$x = x(t) \quad e \quad y = y(t) \quad (3.2)$$

sendo o contorno definido por $c(t) = (x(t), y(t))$. Desse modo, a curvatura de uma curva paramétrica pode ser calculada por (Simmons, 1987):

$$k(t) = \frac{\dot{x}(t)\ddot{y}(t) - \ddot{x}(t)\dot{y}(t)}{(\dot{x}^2 + \dot{y}^2)^{\frac{3}{2}}} \quad (3.3)$$

Entretanto, quando se analisa uma forma cuja informação está discretizada por meio de pixels, alguns problemas começam a surgir. Neste caso não há equações paramétricas que representem o segmento, do qual deseja-se calcular a curvatura. Assim há dois tipos de abordagens, a serem utilizadas: (i) Calcular a curvatura, baseada nos ângulos entre os vetores definidos em termos dos pixels; (ii) ou calcular a curvatura através da interpolação de $x(t)$ e $y(t)$ e de suas respectivas derivadas (Costa e Cesar, 2001) (Jain et al., 1995).

A primeira abordagem basicamente parte do princípio da representação por vetor, dada uma sequência de pontos. A curvatura do conjunto de pontos é determinada pelo ângulo formado entre os vetores representativos do conjunto em análise.

Figura 3.8: Curvatura determinada a partir de vetores no ponto $c(n_0)$.

¹A consistência do método é apoiada na condição de que o mesmo par de pontos, que determinam $\overline{AB}$, sejam encontrados sem que haja ambigüidade, independente da posição, orientação e escala da forma.

Tomando-se a Figura 3.8 como exemplo, o cálculo de curvatura no ponto $c(n_0)$, será determinado pelo ângulo entre os vetores u e v , que são definidos por:

$$u(n) = (x(n) - x(n-i), y(n) - y(n-i)) \quad (3.4)$$

$$v(n) = (x(n) - x(n+i), y(n) - y(n+i)) \quad (3.5)$$

Onde $\{x(n), y(n)\}$ é a coordenada do ponto corrente $c(n_0)$ e $\{x(n-i), y(n-i)\}$ e $\{x(n+i), y(n+i)\}$ são respectivamente as coordenadas dos vizinhos anteriores e posteriores que estão a uma distância de i pontos de $c(n_0)$. O cálculo do ângulo formado entre os dois vetores pode ser obtido por:

$$r(n) = \frac{u(n) \cdot v(n)}{\|u(n)\| \|v(n)\|} \quad (3.6)$$

O valor obtido de $r(n)$ corresponde ao co-seno do ângulo formado entre os vetores, sendo possível a determinação da curvatura no ponto $c(n_0)$.

Pela segunda abordagem, o cálculo de curvatura fica condicionado à interpolação das equações paramétricas $x(t)$ e $y(t)$ do contorno, e ao cálculo de suas respectivas derivadas.

$$x(t) = a_1 t^3 + b_1 t^2 + c_1 t + d_1 \quad (3.7)$$

$$y(t) = a_2 t^3 + b_2 t^2 + c_2 t + d_2 \quad (3.8)$$

A partir da forma analítica do sinal, como por exemplo, na forma cúbica (equações 3.7 e 3.8), e estando determinados os valores dos coeficientes, a curvatura pode ser obtida através da substituição das derivadas destas na equação 3.3.

3.1.5.1 Curvatura por Fourier

Uma solução muito utilizada em processamento de imagens e vantajosa a ser aplicada, é a transformada de Fourier com sua propriedade derivativa (Papoulis, 1962). Para ilustrar o uso desta propriedade, no caso do cálculo da curvatura, será retomada a equação 3.3 abaixo apresentada:

$$k(t) = \frac{\dot{x}(t)\ddot{y}(t) - \ddot{x}(t)\dot{y}(t)}{(\dot{x}^2 + \dot{y}^2)^{\frac{3}{2}}}$$

com $x = x(t)$ e $y = y(t)$ e aplicando-se a transformada de Fourier com sua propriedade derivativa, será obtido:

$$\dot{X} = j2\pi f X(f) \quad \text{e} \quad \ddot{X} = -(2\pi f)^2 X(f) \quad (3.9)$$

$$\dot{Y} = j2\pi f Y(f) \quad \text{e} \quad \ddot{Y} = -(2\pi f)^2 Y(f) \quad (3.10)$$

onde $X(f)$ e $Y(f)$, são respectivamente a transformada de Fourier de $x(t)$ e $y(t)$. Para obter as respectivas derivadas $\dot{x}(t)$, $\dot{y}(t)$, $\ddot{x}(t)$ e $\ddot{y}(t)$, faz-se necessário aplicar a transformada inversa de Fourier:

$$\dot{x}(t) = \mathcal{F}^{-1}\{\dot{X}(f)\} \quad e \quad \ddot{x}(t) = \mathcal{F}^{-1}\{\ddot{X}(f)\} \quad (3.11)$$

$$\dot{y}(t) = \mathcal{F}^{-1}\{\dot{Y}(f)\} \quad e \quad \ddot{y}(t) = \mathcal{F}^{-1}\{\ddot{Y}(f)\} \quad (3.12)$$

Aplicando as definições acima na equação 3.3, e fazendo as devidas simplificações, a curvatura pode ser definida por:

$$k(t) = \frac{\mathcal{F}^{-1}\{fX(f)\}(t)\mathcal{F}^{-1}\{f^2Y(f)\}(t) - \mathcal{F}^{-1}\{f^2X(f)\}(t)\mathcal{F}^{-1}\{fY(f)\}(t)}{[(\mathcal{F}^{-1}\{fX(f)\}(t))^2 + (\mathcal{F}^{-1}\{fY(f)\}(t))^2]^{3/2}} \quad (3.13)$$

Como pode-se observar, o cálculo da curvatura através das equações parametrizadas do contorno, acaba fazendo uso intenso da transformada de Fourier. Um artifício utilizado, é trabalhar com as funções $x(t)$ e $y(t)$, no domínio dos números complexos, assim pode-se definir a a função de contorno da seguinte forma:

$$u(t) = x(t) + jy(t)$$

A grande vantagem desta representação (equação 3.14), é que através de uma única transformada de Fourier de $u(t)$, obtém-se simultaneamente a transformada de $x(t)$ e $y(t)$; em uma única operação. Dessa forma o processo de obtenção da curvatura pela propriedade derivativa da transformada de Fourier, no domínio dos números complexos fica:

$$\dot{u}(t) = \dot{x}(t) + j\dot{y}(t) \quad (3.14)$$

$$\ddot{u}(t) = \ddot{x}(t) + j\ddot{y}(t) \quad (3.15)$$

sendo que $\dot{u}(t)$ e $\ddot{u}(t)$ são definidos em função da transformada de Fourier $U(f)$:

$$\dot{U}(f) = j2\pi fU(f) \quad e \quad \ddot{U}(f) = -(2\pi f)^2U(f) \quad (3.16)$$

que podem ser obtidos através da inversa de Fourier:

$$\dot{u}(t) = \mathcal{F}^{-1}\{\dot{U}(f)\} \quad e \quad \ddot{u}(t) = \mathcal{F}^{-1}\{\ddot{U}(f)\} \quad (3.17)$$

Considerando a equação 3.3, o dividendo desta será o coeficiente da parte imaginária da multiplicação de $\dot{u}(t)$ pelo conjugado de $\ddot{u}(t)$, conforme é apresentado na equação 3.18:

$$\dot{u}(t)\overline{\ddot{u}(t)} = (\dot{x}(t)\ddot{x}(t) + \dot{y}(t)\ddot{y}(t)) - j(\dot{x}(t)\ddot{y}(t) - \dot{y}(t)\ddot{x}(t)) \quad (3.18)$$

Enquanto o respectivo divisor da equação é obtido pelo módulo de $\dot{u}(t)$ elevado ao cubo:

$$|\dot{u}(t)|^3 = (\sqrt{\dot{x}(t)^2 + \dot{y}(t)^2})^3 \quad (3.19)$$

assim, a curvatura pode ser calculada por:

$$k(t) = \frac{-Im(\dot{u}(t) \cdot \overline{\ddot{u}(t)})}{|\dot{u}(t)|^3} \quad (3.20)$$

Cabe novamente aqui lembrar, que a obtenção da curvatura através da transformada de Fourier, foi apresentada considerando-se funções contínuas, entretanto quando tem-se o processamento de sinais discretos - no caso de processamento de imagens, basta utilizar a transformada discreta de Fourier (FDT) (Jain & al., 1995) (Levine, 1985) e principalmente por motivos de custo computacional, a Fast Fourier Transform (FFT) (Parker, 1997) (Gonzalez e Woods, 2000) (Peters e Bates, 1998).

3.2 Métodos de análise de assinaturas de contorno

3.2.1 Descritores de Fourier

Na Subseção 3.1.5, *Curvatura*, foi abordada a utilidade da transformada de Fourier através de sua propriedade derivativa. Aqui será apresentada uma outra aplicação desta transformada para descrever um sinal e dessa forma caracterizá-lo.

A definição e aplicação de descritores de Fourier pode ser encontrada em (Jain & al., 1995), (Sonka & al., 1998) e (Gonzalez e Woods, 2000). Neste último é apresentada uma abordagem orientada pela representação de um contorno no domínio dos complexos - cuja vantagem de se trabalhar, já foi apresentada em subseção mencionada.

A abordagem proposta por (Granlund, 1972) apud (Costa e Cesar, 2001) parte da transformada discreta de Fourier (DFT) de uma representação complexa de um conjunto $c(k)$ de coordenadas $\{(x_0, y_0), (x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ definida por:

$$d(u) = \frac{1}{N} \sum_{k=0}^{N-1} c(k) e^{[-j2\pi uk/N]} \quad (3.21)$$

para $u = 0, 1, 2, \dots, N-1$, o que nos fornece um conjunto de valores complexos representados por $d(u)$, cujos respectivos coeficientes complexos são denominados de *Descritores de Fourier*. Se aplicarmos a função inversa (equação 3.22), torna-se possível a reconstrução do conjunto original.

$$c(k) = \sum_{u=0}^{N-1} d(u) e^{[j2\pi uk/N]} \quad (3.22)$$

Entretanto, se durante o processo de reconstrução do sinal original, utilizarmos apenas um subconjunto das primeiras frequências, o resultado da reconstrução mostrará que com apenas alguns descritores, é possível caracterizar a forma geral de um contorno. Esta propriedade, faz com que os descritores de Fourier sejam largamente utilizados para a

diferenciação e caracterização de fronteiras (Bandera & al., 1999), (Burdin & al., 1992) (Fonga, 1996). A Figura 3.9, traz um exemplo onde pode-se observar que a medida que mais frequências participam da reconstrução, mais detalhes vão se tornando nítidos.

Figura 3.9: Exemplo de reconstrução de sinal pelos descritores de Fourier utilizando : (a) 300 descritores, (b) 120 descritores, (c) 60 descritores, (d) 30 descritores, (e) 20 descritores e (f) 10 descritores.

3.2.2 Espectro de Potência

Quando aplicamos a transformada de Fourier em uma função $f(x)$, que pertence ao domínio dos números reais, o resultado obtido de $F(u)$, na maioria das vezes, está no domínio dos números complexos. Composto por uma parte real e outra imaginária, este conjunto de valores, pode ser representado de uma maneira alternativa. A equação 3.23 reescreve a transformada de Fourier, através do módulo de $|F(u)|$ e do respectivo ângulo de fase.

$$F(u) = |F(u)|e^{j\theta(u)} \quad (3.23)$$

Os valores de $|F(u)|$ e $\theta(u)$ são dados pelas respectivas equações 3.24 e 3.25 (Gonzalez e Woods, 2000).

$$|F(u)| = \sqrt{R(u)^2 + I(u)^2} \quad (3.24)$$

A função 3.24 é conhecida como espectro de Fourier e o quadrado desta; é denominada de espectro de potência (*power spectrum*). O ângulo de fase $\phi(u)$ é fornecida por 3.25.

$$\theta(u) = \arctan \left[\frac{I(u)}{R(u)} \right] \quad (3.25)$$

Uma característica importante do espectro de potência é que este não muda quando a função original, é transladada ao longo do seu domínio - característica muito explorada pelos descritores de Fourier.

O somatório dos módulos das frequências ao quadrado (Costa e Cesar, 2001), fornece um outro descritor, conhecido como *função de energia acumulada*, é dado por:

$$E(s) = \sum_{i=0}^{N-1} |FD(i)|^2 \quad (3.26)$$

Uma característica da *função energia acumulada* é a distribuição da energia acumulada ao longo da variação da frequência, sendo que a maior variação ocorre na faixa das frequências mais baixas e se estabiliza em um patamar ao atingir frequências mais altas, sinalizando uma variação de energia mínima.

Na figura 3.10 estão exemplificados algumas dessas funções, tomando como sinal $u(t)$ o contorno da Figura 3.10-a.

3.3 Métodos de Classificação

Após a descrição de um objeto por meio de um vetor de características, o próximo passo é sua identificação, através de classificadores. Nesta seção são apresentados dois tipos de classificadores: redes neurais, e classificador por distância mínima - embora este último tenha sido abandonado devido péssimo desempenho como classificador. Papel este, que foi desempenhado por um conjunto de redes neurais MLP (multi-layer-perceptron), obtidas nos procedimentos experimentais. Também, nesta seção, é abordado sobre algoritmos genéticos, o qual foi aqui agrupado, por ter auxiliado no treinamento de redes neurais, através da geração de amostras artificiais - durante os procedimentos experimentais.

3.3.1 Redes Neurais

A área de Redes neurais teve seu início por volta de 1940 por Cullock e Pitts (McCullock e Pitts, 1943) apud (Braga *et al.*, 2000), (Gonzalez e Woods, 2000) que desenvolveram modelos de neurônios na forma de dispositivos de limiarização binária e algoritmos estocásticos. Hebb (Hebb, 1949) apud (Braga *et al.*, 2000) em 1945 apresentou um enfoque matemático para representar o conceito de aprendizado por esforço ou associação. Entre os anos de 50 e 60 Rosenblatt (Rosenblatt, 1958) apud (Braga *et al.*, 2000) (Valença e Ludermir, 1999) causou grande excitação na área de reconhecimento de padrões, com a publicação de um trabalho onde provava matematicamente que uma rede simples de uma camada, denominada de perceptron, convergia para uma solução após um número finito de interações - quando este era treinado por um conjunto de treinamento linear-

Figura 3.10: Contorno foliar da *P. caerulea* (a) e seus respectivos gráficos: espectro de Fourier (b), espectro da potência (c) e ângulo de fase (d).

mente separável. Entretanto, a euforia inicial foi logo seguida por uma frustração ao se constatar que o modelo perceptron e suas generalizações eram inadequados para o reconhecimento de padrões de forma prática. Esta frustração foi acentuada com a publicação de uma análise negativa das máquinas perceptron, por Missk e Papert (Missk e Papert, 1969) apud (Valença e Ludermir, 1999) em 1969. O quadro negativo na área de redes neurais começou a se reverter, a partir de 1982, graças ao trabalho de John Hopfield (Hopfield, 1982), seguido pelo trabalho de Rumelhart, Hilton e Williams (Rumelhart *et al.*, 1986) que desenvolveram um método chamado de regra generalizada delta para aprendizado por retro-propagação. Este método de treinamento, tornou as redes perceptron multicamadas um dos principais modelos de redes atualmente em uso, apesar de não se poder provar matematicamente sua convergência, como no caso da perceptron simples (Gonzalez e Woods, 2000). Para o melhor entendimento do funcionamento de uma rede neural, o modelo perceptron será tomado como um exemplo ilustrativo.

3.3.1.1 O modelo Perceptron

Permitindo-se fazer uma rústica analogia; uma rede neural estaria para o cérebro, assim como um neurônio estaria para um dos nós de uma rede neural. Este último assim como o neurônio, apresenta diversas entradas e uma única saída (Dendritos e Axônio no neurônio -Figura 3.11) . No caso do modelo perceptron, este pode aprender a separar em dois

grupos, um conjunto de elementos linearmente separáveis (Valença e Ludermir, 1999).

Figura 3.11: Ilustração de um neurônio (a); e de um modelo perceptron (b).

O princípio de funcionamento deste, é definido por um conjunto de entradas $\{x_1, x_2, \dots, x_n\}$ tal que, para cada elemento deste conjunto é atribuído um elemento do conjunto de pesos $\{w_1, w_2, \dots, w_n\}$. A resposta deste "neurônio", se baseia na soma ponderada de sua entrada sendo que a função que mapeia a saída (função ϕ), é chamada de função de ativação (equação (Valença e Ludermir, 1999) (Braga & al., 2000).

Assim a separação de um conjunto de dados, em duas classes ω_1 e ω_2 pode ser realizada. Entretanto, há situações em que a função de decisão pode assumir uma condição de fronteira, isto é, os valores de entrada não são suficientes para definirem, à qual conjunto pertence o elemento analisado. Este tipo de situação é mapeado com o valor zero para y_j .

Na Figura 3.11 é mostrado uma representação do modelo perceptron para separação de duas classes e o respectivos componentes conforme definidos por (Haykin, 1999).

- **Entradas (sinapses ou links de conexão):** é representado pelo conjunto de elementos $\{x_1, x_2, \dots, x_n\}$ do vetor de características do conjunto de amostras.
- **Pesos sinápticos:** vetor composto pelo conjunto de valores $\{w_1, w_2, \dots, w_n\}$ que atuam como coeficientes de multiplicação para obtenção da soma ponderada do conjunto de elementos de entrada.
- **Função soma:** realiza o somatório da dos elementos de entradas multiplicados pelos respectivos pesos sinápticos (eq.3.27).

$$u_k = \sum_{j=0}^m w_{kj} x_j \quad (3.27)$$

- **Bias:** este componente tem por objetivo realizar um ajuste fino na combinação linear resultante entre as entradas e os pesos sinápticos, através do incremento ou decremento do valor resultante da função soma. O resultado obtido é aplicado na função de ativação representado por v_k (equação 3.28), onde k é o índice do neurônio. Geometricamente o efeito da ação deste componente pode ser mostrado na Figura (3.12)

$$v_k = (u_k + b_k) \quad (3.28)$$

 Figura 3.12: Efeito do parâmetro Bias em v_k (Haykin, 1999).

- **Função ativação:** utilizando como entrada v_k , este componente tem por objetivo limitar a saída do neurônio, geralmente entre os intervalos $[0,1]$ ou $[-1,1]$ conforme a função selecionada (Figura 3.13) : linear (eq. 3.29), piecewise-linear (eq. 3.30), sigmoideal (eq. 3.31) e tangente hiperbólica (eq. 3.32).

$$\varphi(v) = \begin{cases} +1 & \text{se } v > 0 \\ 0 & \text{se } v < 0 \end{cases} \quad (3.29)$$

$$\varphi(v) = \begin{cases} +1 & \text{se } v \geq \frac{1}{2} \\ v & \text{se } -\frac{1}{2} < v < \frac{1}{2} \\ 0 & \text{se } v \leq -\frac{1}{2} \end{cases} \quad (3.30)$$

onde a é o parâmetro de inclinação da curva.

$$\varphi(v) = \frac{1}{1 + \exp(a - v)} \quad (3.31)$$

$$\varphi(v) = \tanh(v) \quad (3.32)$$

Figura 3.13: Gráficos das funções de ativação: Limiar (a); Pricewise (b); Sigmoidal (c); Tangente hiperbólica (d).

Em uma rede Peceptron de multicamadas (MLP), o processo de treinamento geralmente é mais rápido quando a função de ativação sigmoide é antisimétrica (eq. 3.33).

$$\varphi(-v) = -\varphi(v) \quad (3.33)$$

3.3.1.2 Redes MLP- Número de camadas e neurônios

Referente ao número de camadas e nós em uma rede, é importante ressaltar os reflexos com relação à definição das fronteiras de decisão para a separação de classes.

Tomando-se um espaço bidimensional, uma rede perceptron de uma única camada consegue apenas definir uma única linha de fronteira, o que é insuficiente para a obtenção de um classificador, na grande maioria dos problemas, mesmo para a separação de duas classes (Figura 3.14).

Dessa forma, torna-se necessário um aumento no número de camadas e de neurônios, para que as regiões de classificação pertinentes às classes, possam ser melhor delimitadas

Figura 3.14: Exemplo de caso em que uma rede perceptron (c) consegue separar duas classes (a) e, o caso em que a determinação de uma fronteira de separação não pode ser obtida (b).

pelas fronteiras de decisão. Entretanto, raramente uma MLP possui mais do que 3 camadas de neurônios.

Segundo Gonzalez e Woods (2000), o número de nós da primeira camada, implementa o número de linhas (ou hiperplanos) que definem as fronteiras de decisão; o número de nós da segunda camada estabelecem as relações de intersecção (operação E) entre as linhas (ou hiperplanos) definindo assim as regiões; e a terceira camada define a associação das regiões delimitadas às classes classificadas pela rede neural(Figura 3.15).

3.3.1.3 Métodos de Aprendizagem de uma Rede

O processo de determinação dos valores do conjunto de pesos é denominado de treinamento ou aprendizado da rede neural. Este processo pode ser realizado por uma infinidade de algoritmos, mas basicamente qualquer um que seja escolhido, será classificado como um dos três tipos: Aprendizagem supervisionada, não-supervisionada e aprendizagem por reforço. Abaixo segue uma breve descrição de cada um dos tipos:

Método de Aprendizagem Supervisionado: a entrada e a saída da rede é fornecida por um supervisor, o qual é responsável por garantir a correta classificação da rede e pelos ajustes necessários dos pesos - quando a classificação não é feita corretamente. Exemplo: Regra delta para rede perceptron, ou a regra delta generalizada para rede perceptron multicamadas (MLP). GMDH e SSBN (Valença e Ludermir, 1999) (Braga *et al.*, 2000).

Aprendizado Não-Supervisionado: ao contrário do aprendizado supervisionado, neste não há um supervisor que balize o processo de aprendizagem. Este método é apoiado na existência de redundância nos dados de entrada, dos quais é possível identificar padrões através de regularidades estatísticas (Braga *et al.*, 2000).

Aprendizado por Reforço: neste processo de aprendizagem, não é fornecido o conjunto de respostas para o conjunto de estímulos, entretanto é informado à rede se a resposta

Estrutura de rede	Tipo de região	Solução do problema OU-Exclusivo	Classes com regiões entrelaçadas
Único Hiperplano

Regiões convexas abertas ou fechadas

Arbitrária: Complexidade dependente do número de nós

Figura 3.15: Exemplos de configuração de redes neurais e as respectivas regiões de classificação (Gonzalez e Woods, 2000).

obtida por ela está ou não correta (Braga *et al.*, 2000).

Além do processo de aprendizagem, outro fator que caracteriza uma rede é o seu tipo de arquitetura.

3.3.1.4 Principais Arquiteturas de Redes Neurais

A importância da arquitetura está diretamente relacionada com a complexidade do problema a ser solucionado. E a caracterização desta é definida pelo: número de camadas, número de nós em cada camada, tipo de conexão entre os nodos e sua topologia (Braga *et al.*, 2000) (Nelson e Illingworth, 1991). A Figura 3.16 ilustra as principais classificações:

- Quando ao Número de Camadas: única(a,c) Multicamadas (b,d,e);
- Quando ao Tipo de Conexões: feedforward ou acíclicas (a,b,d) ou cíclicas (feedback) (c,e);
- Quando ao Tipo de Conectividade: fraca (b,d,e) ou completamente conectada (a,c).

3.3.1.5 O Algoritmo de treinamento Back-propagation

O processo de aprendizagem de uma rede, cosiste basicamente em ajustar os parâmetros livres (pesos sinápticos e bias) de uma RN, tal que o valor de saída (resultado da classificação) da RN, corresponda ao valor esperado, para classe à qual a rede foi treinada.

Figura 3.16: Tipos de arquiteturas de redes neurais (Braga & al., 2000).

Um parâmetro de medida utilizado para avaliar o andamento do processo de treinamento é a energia do erro quadrático médio, (E_{av}) definido por (eq. 3.34):

$$E_{av} = \frac{1}{N} \sum_{n=1}^N E(n) \quad (3.34)$$

onde $E(n)$ é determinado por (eq. 3.35):

$$E(n) = \frac{1}{2} \sum_{j \in C} (d_j(n) - y_j(n))^2 \quad (3.35)$$

Sendo $d_j(n)$ o valor desejado; $y_j(n)$ o valor obtido do respectivo neurônio j ; e n o número da respectiva interação.

Com base no erro calculado para cada amostra utilizada na fase de treinamento, o algoritmo back-propagation minimiza a energia do erro quadrático médio, atuando na propagação recursiva de erros, durante o processo de treinamento. Essa atuação se dá em duas fases: momento de propagação (feedforward ou forward computation) e de retropropagação (feedback ou back propagation).

A fase de propagação se inicia quando um vetor de características é aplicado na rede neural e os resultados obtidos dos neurônios são propagados de camada a camada, até que seja obtido o resultado da última camada (camada de saída) e os respectivos erros de cada neurônio durante as n interações calculadas por (eq. 3.36)

$$e_j(n) = d_j(n) - y_j(L) \quad (3.36)$$

onde y_L representa valor obtido da camada de saída.

Na etapa de retropropagação, os pesos sinápticos são reajustados com (base nos gra-

dientes locais da rede) (pela regra delta generalizada eq. 3.37) recursivamente (eq.3.38), e uma nova interação de treinamento é reiniciada. A Figura 3.17 ilustra estes dois momentos (Haykin, 1999).

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha[w_{ji}^{(l)}(n-1)] + \eta\delta_j^{(l)}(n)y_i^{(l-1)}(n) \quad (3.37)$$

$$\delta_j^l = \begin{cases} e_j^l(n)\varphi'(v_j^l(n)) & \text{para neurônio } j \text{ na camada de saída } L. \\ \varphi'(v_j^l(n))\sum_k \delta_k^{(l+1)}(n)w_{kj}^{(l+1)}(n) & \text{para neurônio } j \text{ na camada interna } l. \end{cases} \quad (3.38)$$

onde w representa um peso sináptico, L indica a camada externa, l índice da camada interna, j o índice do neurônio em uma camada; i o índice de uma entrada de um neurônio; η a taxa de crescimento, α a constante de momentum e ϕ' representa a diferenciação com relação ao argumento.

Figura 3.17: Fluxos de algoritmo back-propagation: fase de propagação (feedforward) (a) e fase de retropropagação (feedback) (b) (Haykin, 1999).

3.3.1.6 Métodos de avaliação de uma rede neural

Para que uma rede seja treinada e testada é necessário que se tenha um número de amostras, o qual é dividido três conjuntos: treinamento, validação e teste.

O papel do conjunto de treinamento é o de ajustar os valores dos pesos sinápticos para que um classificador seja obtido durante o processo de treinamento, o qual simultaneamente tem seu desempenho acompanhado através de testes realizados com o conjunto de validação. Terminado o treinamento, o classificador obtido é colocado à prova através do conjunto de teste.

Entretanto, antes de se iniciar o treinamento de uma rede, é necessário que esta seja desenhada. Por não haver uma regra ou método que especifique claramente os melhores parâmetros para o desenho de uma rede neural, algumas questões não podem ser respondidas, tais como: Qual o melhor número de camadas? Qual o melhor número de neurônios por camada? Qual o tipo de conectividade ou função de ativação pode trazer melhores resultados?

Uma caminho utilizado é o desenho de alguns modelos empíricos de redes neurais, os quais são colocados sob condições de teste. Neste momento, faz-se uso de uma ferramenta

estatística conhecida como *cross-validation* (Stone, 1974) apud (Haykin, 1999) e suas variações: hold-out, multifold e leave-one-out.

Multifold cross-validation: A partir de um conjunto de N elementos obtém-se K sub-conjuntos onde $K > 1$ K é divisor de N . O modelo de rede é testado por todos os $K - 1$ conjuntos e o erro de validação é obtido pelo conjunto que ficou de fora do treinamento. Repete-se este procedimento K vezes sempre alternando o conjunto de teste (Figura 3.18)

Figura 3.18: Método multifold cross-validation

Hold-out cross-validation: define um percentual da quantidade de amostras que participam do treinamento e teste, com base em regras de estatística (Haykin, 1999)

Leave-one-out: este método é uma variação do método multifold onde o conjunto de treinamento é composto por $N-1$ elementos, sendo N o número de amostras. O único elemento deixado fora do conjunto de treinamento (leave-one-out) é utilizado para o teste da rede. Este procedimento é repetido N vezes, sempre variando o elemento de teste.

3.3.1.7 Redes Neurais em Visão Computacional

Em (Egmont-Petersen *et al.*, 2001) é apresentado um panorama geral da aplicação de rede neurais. O autor baseou o artigo na análise de aproximadamente duzentas aplicações. Neste artigo é apresentada a utilização de redes neurais desde a fase de pré-processamento até a etapa de reconhecimento. No caso do reconhecimento de objetos representados através de vetores característicos, os tipos de redes apontadas como as mais empregadas são: feedforward, SOM, Hopfield e fuzzy. Sendo a feedforward a mais citada. No artigo (Osowski e Nghia, 2001) três tipos de redes neurais foram utilizadas para o reconhecimento de formas 2D: Uma rede MLP (Multilayer Perceptron), Kohonen (rede auto-organizativa) e uma rede híbrida composta por uma camada auto-organizativa e uma rede MLP. Estas redes tinham por objetivo identificar 16 formas de aeroplanos. Foram testados vetores característicos de 20 elementos, gerados de duas maneiras, através de descritores de Fourier e wavelets. O tipo de associação rede-descritor que obteve melhor desempenho, foi o que utilizou o descritor de wavelet conjuntamente com uma rede híbrida.

3.3.2 Classificação Teórica

O princípio desta abordagem de classificação, se apóia na aplicação de regras de decisão, no vetor o qual deseja-se classificar. Estas regras de decisão, ou funções de decisão, são obtidas a partir do particionamento do espaço de padrões, separando-os em regiões correspondentes a cada classe. A dimensionalidade da fronteira é sempre uma dimensão menor que a do espaço de vetores a serem classificados, e a determinação desta, é o resultado de um processo de treinamento (por isso é considerado um classificador supervisionado). Isto implica na existência de pelo menos duas classes no espaço de padrões (Banks, 1990).

Vejamos um exemplo: Seja $x = (x_1, x_2, \dots, x_k)$ um vetor k-dimensional. A classificação teórica para M classes de padrões $\omega_1, \omega_2, \dots, \omega_n$ implica em encontrar M funções de decisão $d_1(x), d_2(x), \dots, d_M(x)$ tal que :

$$d_i(x) > d_j(x) \quad j = 1, 2, \dots, M; \quad j \neq i. \quad (3.39)$$

isto é, quando $d_i(x)$ tem o maior valor numérico, implica que x pertence à classe ω_i . Caso haja empate entre duas classes, ($d_i(x) - d_j(x) = 0$) é dito que o vetor se encontra na fronteira de decisão, e sua classificação é feita de modo arbitrário (Gonzalez e Woods, 2000).

3.3.2.1 Classificador de Distância Mínima

Em (Banks, 1990) é apresentado um algoritmo para função de decisão baseada na distância mínima entre o vetor de padrão desconhecido x e os demais vetores de outras classes. Assim o vetor x será classificado como sendo pertencente a mesma classe à qual pertence o elemento de menor distância de x . A função de decisão, adequada à escolha em função do maior valor numérico, conforme 3.39 é apresentada em 3.40 e 3.41

$$c(x) = i \text{ se } \theta_i(x) > \theta_j \text{ para } i \neq j \quad (3.40)$$

$$\theta_i(x) = -\min\{d(x, x^{i,j})\} \quad (3.41)$$

onde $x^{i,j}$ representa todas as j amostras de vetores x pertencentes à classe i . Um meio mais prático, também citado por (Banks, 1990) e (Gonzalez e Woods, 2000) é de se trabalhar com o vetor médio de cada classe (em (Banks, 1990) o termo utilizado é vetor protótipo), ou centróide (Figura 3.19) das respectivas nuvens de classes, que é obtido pela equação 3.42.

$$m_j = \frac{1}{N_j} \sum_{x \in \omega_j} x \quad j = 1, 2, \dots, M \quad (3.42)$$

onde N_j corresponde ao número de vetores padrões da classe ω_j . Utilizando-se da distância euclidiana, a distância do vetor x ao vetor médio fica sendo:

$$D_j(x) = \|x - m_j\| \quad j = 1, 2, \dots, M \quad (3.43)$$

que simplificando pela norma euclidiana $\|a\| = (a^T a)^{1/2}$ temos:

$$\theta_j = x^T m_j - \frac{1}{2} m_j^T m_j \quad j=1,2,\dots,M \quad (3.44)$$

Este método apresenta um bom desempenho, quando a distância entre os centróides das nuvens forem maiores - quando comparadas com a dispersão dos elementos de cada classe - e uma “ótima performance quando a distribuição de cada classe, em torno de sua origem, for na forma de uma *hiper-nuvem* esférica no espaço n-dimensional de padrões” (Gonzalez e Woods, 2000).

Figura 3.19: Exemplo de duas nuvens de classes distintas e os respectivos centróides (Banks, 1990).

3.3.3 Algoritmos Genéticos

Esta seção apresenta os conceitos básicos a respeito de algoritmos genéticos, tendo um enfoque maior nos respectivos operadores de *crossover* e mutação. Estes operadores foram utilizados para a geração de amostras artificiais de contornos de folhas, os quais foram aplicados no treinamento de redes neurais.

3.3.3.1 Origem e conceitos

Conceito criado por John Holland (Holland, 1975) e muito utilizado como método de otimização e busca, os algoritmos genéticos são inspirados nos princípios de evolução de população e na lei de seleção natural, descrita por Charles Darwin, no livro “A Origem das espécies”. Entretanto, foi David Goldenberg, aluno de John Holland, o maior divulgador do uso de AGs para a solução de problemas práticos. Em (Goldberg, 1989) ele define AGs como “...algoritmos de busca baseados em mecanismos de seleção natural e genética” e continua “...não é simplesmente uma busca randômica. Eles exploram eficientemente informações históricas para pesquisar novos pontos de busca com uma expectativa de melhora de desempenho”.

Os algoritmos genéticos tem sido aplicados em substituição a uma grande quantidade de técnicas de otimização que não são capazes de localizar o ponto de máximo/mínimo global de uma função, quando esta apresenta diversos pontos de máximo/mínimos locais. Áreas como engenharia e de sistemas de manufatura, por apresentarem problemas de

grande complexidade, tem buscado por soluções através de simulações de processos evolucionistas, aplicando conceitos de algoritmos genéticos, programação e estratégia evolucionárias (Gin e Chieng, 1997).

Em relação aos métodos comumente utilizados para otimização, as principais diferenças com algoritmos genéticos (AGs) segundo (Gin e Chieng, 1997) são:

1. AGs trabalham com o conjunto de parâmetros codificados;
2. AGs fazem a busca a partir de uma população de pontos, não a partir de um ponto;
3. AGs fazem uso do retorno da informação (através da função objetiva) e não de outros conhecimentos derivados e
4. AGs fazem uso de regras de transição probabilística, não de regras determinísticas.

A utilização de algoritmos genéticos na otimização de um problema envolve primeiramente, a codificação dos parâmetros a serem pesquisados (como pode ser observado mais adiante na Figura 3.20). Isto é, representar os possíveis valores de um espaço de solução do problema (gerados randomicamente) em um código (não necessariamente binário, apesar disso ser muito comum). Este conjunto finito de parâmetros codificados é denominado de população inicial.

Definida a população inicial, cada elemento que a compõem passa por um processo de seleção, tendo sua aptidão avaliada através de uma função objetiva. A partir do resultado dessa avaliação cada indivíduo é descartado ou selecionado para a “reprodução”. Na etapa de reprodução os elementos que foram descartados, são substituídos por novos indivíduos.

O processo de reprodução, segue os princípios biológicos de recombinação e alteração do código genético. Novos indivíduos são gerados ou por meio recombinação de código (*crossover*) de outros dois indivíduos, ou pela alteração do código de um indivíduo existente (mutação). A nova população obtida também passa por uma seleção, reiniciando o ciclo até que esta convirja para um indivíduo ou grupo de indivíduos, que satisfaça a necessidade do problema. A Figura 3.20 ilustra todo o processo de atuação de um algoritmo genético.

3.3.3.2 O operador de crossover

Considerado o principal responsável na imitação do processo de hereditariedade, o operador de *crossover* atua simultaneamente em dois cromossomos gerando dois novos descendentes. A intensidade de seu uso é medido pelo parâmetro taxa de *crossover*. Esta é definida pela razão entre o número de descendentes gerados pelo operador e pelo número total de indivíduos que compõem a população. Uma taxa muito baixa de *crossover* pode induzir o algoritmo genético a encontrar um falso máximo local de uma função entretanto, se esta taxa for muito alta, o algoritmo pode consumir muito tempo de processamento, investigando regiões do espaço de soluções não relevantes (Gin e Chieng, 1997) (Lacerda e Carvalho, 1999).

O tipo mais comum de *crossover* (também ilustrado na Figura 3.20) utiliza o código (cromossomo) de dois indivíduos, nos quais seleciona aleatoriamente um ponto de corte. A partir deste ponto, os segmentos de código são permutados, dando origem a dois novos indivíduos. Outros tipos de operadores de *crossover* que podem ser encontrados na literatura são: o *crossover* de N pontos e o *crossover* uniforme (Lacerda e Carvalho, 1999).

O *crossover* de N pontos recebe esta denominação por N representar o número de cortes que o operador realiza nos cromossomos. Dessa forma pode-se dizer que o primeiro

Figura 3.20: Processo simplificado da aplicaçao de um algoritmo genético.

tipo de *crossover* anteriormente apresentado, seria denominado de *crossover* de 1 ponto. A Figura 3.21 ilustra o *crossover* de 2 e 3 pontos.

Figura 3.21: *Crossover* de N pontos.(Reproduzido com alteraçoes de (Lacerda e Carvalho, 1999))

Denominado de *crossover* uniforme, este operador além de dois cromossomos iniciais (*pai1* e *pai2*) também utiliza uma máscara de bits gerada aleatoriamente, de mesmo tamanho dos cromossomos pais. A geração do *filho1* é determinada pela combinação de bits do *Pai1* com *Pai2*, seguindo o seguinte método: lê-se sequencialmente os bits da máscara gerada, para cada bit de valor 1, o bit correspondente de mesma posição no cromossomo *filho1* terá o valor do bit correspondente do *pai1*, caso o valor do bit da máscara for 0, então o bit do cromossomo do *filho1* assumirá o valor do bit correspondente do *pai2* (Figura 3.22 a). A geração do *filho2* segue o mesmo princípio, sendo que a única diferença é a inversão dos pais para quando o bit da máscara for 1 ou 0 (Figura 3.22 b).

Figura 3.22: *Crossover* Uniforme.(Reproduzido com alterações de (Lacerda e Carvalho, 1999))

3.3.3.3 O operador de mutação

Aplicado nos filhos resultantes da ação do operador de *crossover*, o operador de mutação altera, em função de uma dada probabilidade, os genes de um cromossomo. No caso de um cromossomo codificado na forma binária, implicaria na inversão dos bits selecionados(Figura 3.23).

A importância deste operador está em garantir uma variabilidade, através do fornecimento de genes não presentes na população, e na recuperação de genes que podem contribuir na solução do problema - mas que desapareceram devido ao descarte de indivíduos(Lacerda e Carvalho, 1999).

Definido como a razão entre o número total de genes alterados pelo número total de genes de uma população, a taxa de mutação tem como função equilibrar os efeitos deste operador em cada nova geração.

Quando se faz uso de uma taxa de mutação muito baixa, perde-se a possibilidade de encontrar genes que poderiam contribuir na solução de um problema. Por outro lado, ter uma taxa de mutação muito elevada, traria sérios prejuízos para as novas gerações, acarretando a perda da semelhança dos filhos com os pais, e a incapacidade do algoritmo em manter o histórico de busca (Giu e Chieng, 1997).

Figura 3.23: Aplicação do operador de mutação.(Reproduzido com alterações de (Lacerda e Carvalho, 1999))

3.4 Considerações Finais

Este capítulo, dividido em três subseções, apresentou os conceitos teóricos que nortearam a execução dos procedimentos experimentais. A primeira seção discorreu sobre os tipos de assinaturas de contornos utilizadas e suas respectivas características. A segunda seção,

apresentou a teoria e os conceitos que envolvem a transformada de Fourier e o espectro de potência - incluindo a obtenção da curvatura de um contorno paramétrico, através da propriedade derivativa da transformada de Fourier e, finalizando este capítulo, na terceira seção são apresentados os métodos de classificação utilizados e testados: redes neurais artificiais e classificação por distância mínima. Nesta mesma seção também foi incluído uma introdução à algoritmos genéticos com maior enfoque nos respectivos operadores genéticos: cross-over e mutação. Os quais foram responsáveis pela solução da falta de amostras para treinamento das redes neurais durante os procedimentos experimentais.

Procedimentos experimentais

Neste capítulo são apresentados os procedimentos envolvidos para a obtenção de classificadores de folhas por meio da análise do contorno foliar. A primeira seção fornece uma idéia geral dos problemas enfrentados e da metodologia adotada para resolvê-los. As demais seções justificam e descrevem com maiores detalhes cada etapa do processo, para a obtenção de um conjunto de redes neurais para a classificação.

4.1 Uma visão geral do problema

Para que o objetivo de classificação de vegetais por meio da análise do contorno foliar fosse atingido, alguns problemas tiveram que ser solucionados. Análises iniciais demonstraram que o desempenho de métodos como distância mínima e análise de cluster não fora satisfatório para classificação, em função do tipo de atributo selecionado (contorno). Dessa forma optou-se em utilizar redes neurais.

A obtenção de uma rede neural com uma capacidade de classificação confiável é determinada pelo grau de generalização desta, obtido durante o processo de treinamento. Este processo se dá por meio de vetores de características que são construídos com base em atributos discriminantes das classes, as quais são representadas pelas respectivas amostras. A quantidade e qualidade dos atributos que definem um vetor de características e a quantidade de amostras de uma classe são fundamentais para a obtenção de uma rede neural confiável no reconhecimento de padrões.

Dois fatores presentes complicaram a realização deste trabalho : a quantidade de amostras por classe e a dificuldade de seleção das variantes das assinaturas de contorno, utilizadas na composição dos vetores de características.

A quantidade de amostras das 31 classes utilizadas para a caracterização por contorno, era muito diversificada, não sendo maior do que cinco amostras por classe, no caso das passifloráceas, que participaram com um número de 10 dentre as 31 classes. As demais 21 classes, compostas por espécies do cerrado e algumas espécies domésticas (como: lima, limão, coqueiro de jardim e cinco espécies desconhecidas), com raras exceções, não ultrapassavam mais do que doze amostras por classe - quantidades essas insuficientes para a geração de redes neurais. A coleta de mais amostras para atingir um número razoável, seria inviável devido à necessidade de conhecimentos específicos para a seleção de folhas maduras, sem fungos e sem danos causados por insetos.

Quanto à dificuldade de seleção dos atributos, o problema foi definir quais os tipos de assinaturas e suas variantes eleger para a geração de classificadores por meio de redes neurais. Para a descrição dos contornos foram utilizados oito tipos de assinaturas, detalhadas no Capítulo 3: i) contorno global, ii) contorno apical, iii) contorno basal, iv) assinatura angular, v) ângulo de visão, vi) curvatura global, vii) curvatura apical e viii) curvatura basal. Por se optar em trabalhar no domínio da frequência, houve a preocupação de que um razoável conjunto de opções, quanto à normalização dos descritores de Fourier e do espectro da potência, fossem investigados, assim como as faixas de frequências dos respectivos sinais. Conseqüentemente, cada uma das oito assinaturas, deriva outras vinte, resultantes da combinação de: 4 tipos de abordagem no domínio da frequência (Fourier normalizado, Fourier com centróide zerado, espectro da potência normalizado e espectro da potência com centróide zerado), e de cinco faixas¹ de frequências investigadas (30, 60, 90, 120 e 150). A utilização desse conjunto de possibilidades para a geração de classificadores com redes neurais, para as 31 classes, tornaria o experimento inviável pelo alto custo computacional (tempo e memória), pois seria necessário investigar a geração de: $8 \times 20 \times 31 = 4.960$ redes.

As soluções utilizadas para contornar estes dois problemas foram: a utilização de operadores genéticos para a geração de imagens artificiais – com base em imagens reais; e na utilização do método *leave-one-out* (ver Seção 4.4.2), como um filtro para a seleção dos tipos de assinaturas que apresentassem uma maior probabilidade de sucesso de se obter um classificador.

Na Figura 4.1 é apresentada uma visão geral de cada etapa do experimento. As seções seguintes descrevem com maiores detalhes os procedimentos de cada uma.

4.2 Sobre as amostras

As imagens de folhas utilizadas fazem parte da base de imagens do grupo do projeto Tree-Vis, e foram fornecidas por: Juliano de Pádua : Departamento de Genética - ESALQ - USP (imagens das *Passifloras*), Eduardo Amiaral Batista: Estação Ecológica de Mogi-Guaçu do Instituto Florestal dos Estado de São Paulo (plantas do cerrado). Além dessas plantas fornecidas, a base de imagens do TreeVis possui imagens de plantas coletadas sem procedimentos científicos, que também foram utilizadas no experimento (6 classes).

Para a execução do experimento fez-se uso de trinta e uma classes distintas de folhas. Algumas dessas tiveram o respectivo conjunto de amostras digitalizado em uma única imagem, o que demandou um trabalho de separação, a fim de que cada folha fosse uma única imagem. Outro procedimento executado foi o de normalização de resolução de imagem. Algumas classes foram digitalizadas em resoluções distintas (100 e 200 pontos por polegada), e o padrão de normalização adotado foi o de 300 pontos por polegadas. Imagens que sofreram expansão de resolução, quando necessário, foram tratadas com um filtro gaussiano a fim de reduzir possíveis ruídos introduzidos pelos ajustes.

Para cada imagem de folha foi definido um padrão para a construção do nome do respectivo arquivo de imagem, começando sempre com o nome principal da espécie, seguido por um caracter separador “_” e por um numerador fXX, sendo XX composto por dois dígitos, como por exemplo, *amethystina_f05.bmp*.

As imagens, na grande maioria, foram armazenadas no padrão BMP, entretanto, algumas espécies foram armazenadas no padrão JPG por serem muitos grandes (em tamanho de arquivo). Outro cuidado tomado durante essa fase de preparação das amostras foi o

¹As faixas apresentadas indicam o número de frequências negativas e positivas do espectro de Fourier, assim um vetor que utiliza uma faixa de 30 frequências é composto na verdade, por 60 elementos.

Figura 4.1: Diagrama do processo de obtenção das redes de classificação, por sinais de contorno.

de manter uma orientação única (com relação ao eixo apical-basal) para todos os tipos de folhas. Esse procedimento visou obter as assinaturas apicais e basais sugeridas por (Ash & al., 1999). Imagens das classes e os respectivos dados, como nome científico, nome popular e quantidades de amostras por classe, são apresentados na Figura 4.2.

4.3 Pré-processamento e obtenção dos sinais

Após a preparação inicial das amostras, todas passaram por um pré-processamento para que fossem obtidas as respectivas assinaturas: contorno global da folha, contorno apical, contorno basal, contorno angular e assinatura por ângulo de visão.

O procedimento foi executado por um sistema desenvolvido em Delphi, que permite a execução, em lote, de funções de processamento de imagens (Figura 4.3).

O pré-processamento aplicado envolve basicamente a binarização das imagens e a remoção de possíveis ruídos. Para isso, duas opções de algoritmos foram utilizados: o método de binarização por limiarização média (Sonka & al., 1998) e outro por limiarização iterativa (Sezgin e Sankur, 2004). Operadores morfológicos de erosão, dilatação, abertura e fechamento (Serra, 1982) foram aplicados para a eliminação de ruídos nas imagens binárias obtidas.

As assinaturas de contorno global, apical e basal foram obtidas do algoritmo traçador de contornos de (Pavlidis, 1982), sendo que as duas últimas foram obtidas de duas variações do respectivo algoritmo citado.

As assinaturas angular e de ângulo-de-visão foram obtidas a partir da assinatura global por meio dos métodos descritos nas respectivas seções 3.1.2 e 3.1.4. Respectivamente, no

Figura 4.2: Amostras das classes utilizadas no experimento: *Passiflora amethystina* (01); *Passiflora caerulea* (02); *Passiflora coriacea* (03); *Passiflora foetida* (04); *Passiflora gibertii* (05); *Passiflora maliformis* (06); *Passiflora miersii* (07); *Passiflora organensis* (08); *Passiflora pohlii* (09); *Passiflora suberosa* (10); *Moroxyon peruiiferum* (cabreúva - 10) (11); *Rauwolfia sellowii* (casca d'anta - 08) (12); *Pseudobombax grandiflorum* (imbituba - 07) (13); *Tabebuia impetiginosa* (ipê-roxo - 12) (14); *Syzygium jambolandum* (jambolão - 10) (15); *Hymenaea courbaril* (jatobá - 10) (16); *Cariniana estrellensis* (jequitibá - 09) (17); (lima - 10) (18); (limão - 10) (19); *Cordia trichotoma* (louro-pardo - 09) (20); *Eriotheca candoleana* (paina-da-mata - 10) (21); *Cuculpsina echinata* (pau-brasil - 25) (22); *Platycianus regnelli* (pau-pereira - 10) (23); *Eugenia uniflora* (pitanga - 13) (24); *Tapirira guianensis* (peito-de-pomba - 10) (25); (coqueiro de jardim - 20) (26); (desconhecida01 - 14) (27); (desconhecida02 - 10) (28); (desconhecida03 - 09) (29); (desconhecida04 - 15) (30); (desconhecida05 - 12) (31);

caso da assinatura de ângulo de visão, o processo de obtenção da corda AB, responsável pela consistência da assinatura, foi realizado selecionando-se o ponto mais distante do centróide e o seu diametralmente oposto (referente ao centróide).

As assinaturas de curvatura global, apical e basal foram geradas por um "script" em MatLab, com a aplicação dos princípios descritos na Subseção 3.1.5, a partir dos arquivos de contornos correspondentes. Todas as oito assinaturas citadas foram armazenadas em arquivos no formato ASCII para que, posteriormente, fossem lidas e processadas. Também foi definido um padrão para a formação dos nomes dos arquivos que contém os dados de cada tipo de assinatura: **Ass_Class_Num.vet**, sendo:

Ass: corresponde aos acrônimos referentes aos tipos de assinaturas (Tabela 4.1).

Classe: corresponde ao principal nome da classe à qual pertence a amostra.

Num: corresponde ao numerador da amostra, composto pela letra **f** e por mais dois dígitos, ex: f05.

Figura 4.3: Programa Delphi de processamento em lote.

Acrônimos	Significados
<i>aaug</i>	assinatura angular
<i>angv</i>	assinatura de ângulo-de-visão
<i>cntgb</i>	assinatura de contorno global
<i>cntap</i>	assinatura de contorno apical
<i>cntba</i>	assinatura de contorno basal
<i>crvgb</i>	assinatura de curvatura global
<i>crvap</i>	assinatura de curvatura apical
<i>crvba</i>	assinatura de curvatura basal

Tabela 4.1: Acrônimos utilizados para composição dos nomes dos arquivos de assinaturas.

Retomando como exemplo o arquivo de imagem citado anteriormente (*amethystina_f05.bmp*), a Tabela 4.2 apresenta os arquivos de assinaturas obtidos.

<i>aaug_amethystina_f05.vet</i>
<i>angv_amethystina_f05.vet</i>
<i>cntgb_amethystina_f05.vet</i>
<i>cntap_amethystina_f05.vet</i>
<i>cntba_amethystina_f05.vet</i>
<i>crvgb_amethystina_f05.vet</i>
<i>crvap_amethystina_f05.vet</i>
<i>crvba_amethystina_f05.vet</i>

Tabela 4.2: Exemplo das oito assinaturas primárias geradas de uma imagem.

Pode-se notar que, para cada arquivo de imagem, oito tipos de arquivos de dados foram gerados. Essas assinaturas, denominadas neste trabalho de **assinaturas primárias**, servem para a obtenção das assinaturas que foram efetivamente utilizadas no processo de

reconhecimento de padrão, denominadas de **assinaturas secundárias**.

As **assinaturas secundárias** resultam do processamento das assinaturas primárias, as quais foram transformadas em sinais unidimensionais, sendo reescritas sob a forma de números complexos, e transpostas para o domínio da frequência com a aplicação da transformada de Fourier. De cada sinal obtido, quatro variações no domínio da frequência foram geradas e utilizadas no experimento: i) o espectro de Fourier com centróide zerado, ii) o espectro de Fourier normalizado, iii) o espectro da potência de Fourier com centróide zerado, iv) e o espectro da potência de Fourier normalizado. Na Figura 4.4 é apresentada de forma esquemática todo o processo de geração das assinaturas.

Figura 4.4: Esquemática da geração das assinaturas principais, a partir das assinaturas primárias.

Seguindo o mesmo padrão aplicado às assinaturas primárias, as assinaturas secundárias tiveram formatado o nome dos respectivos arquivos. A estrutura básica adotada foi baseada na expansão dos nomes das assinaturas primárias, acrescidas com acrônimos do tipo do sinal no domínio da frequência e o tipo de normalização aplicada. Assim o nome de um arquivo de assinatura secundária, teve sua estrutura definida por, **TSDFN-Ass_Class_Num.vet**, onde os possíveis valores para TSDFN são apresentados na Tabela

4.3. Novamente o exemplo da amostra (*amethystina_f05.bmp*) ilustra a geração dos arquivos de assinaturas, desta vez as assinaturas secundárias listadas na Tabela 4.4.

Acrônimos	Siginificados
VFFTCz	descritor de Fourier com centróide zerado.
VNFT	descritor de Fourier normalizado
VPwsCz	espectro da potência do descritor de Fourier com centróide zerado
VPwsNFT	espectro da potência do descritor de Fourier

Tabela 4.3: Acrônimos utilizados para nomeação dos arquivos de sinais no domínio da frequência.

VFFTCZ-aang_amethystina_f05.vet
VFFTCZ-angv_amethystina_f05.vet
VFFTCZ-cntgb_amethystina_f05.vet
VFFTCZ-cntap_amethystina_f05.vet
VFFTCZ-cntba_amethystina_f05.vet
VFFTCZ-crvgb_amethystina_f05.vet
VFFTCZ-crvap_amethystina_f05.vet
VFFTCZ-crvba_amethystina_f05.vet

Tabela 4.4: Exemplo das oito assinaturas secundárias geradas de uma imagem.

Uma vez definidos os tipos de assinaturas e as variantes do domínio da frequência, o último passo foi a seleção dos intervalos de frequência a serem considerados. Por meio de análises previamente realizadas, cinco comprimentos de intervalos foram identificados como de interesse para serem pesquisados: 30, 60, 90, 120 e 150.

Entretanto, para a seleção das faixas de frequências durante o processo de filtragem e geração dos classificadores, os intervalos de frequências eram obtidos durante a execução do sistema, não sendo necessário a criação de arquivos de assinatura para cada faixa de frequência selecionada.

A preocupação em se estabelecer um padrão de nomeação dos arquivos de assinaturas e imagens foi possibilitar a máxima automatização de todo o experimento, em virtude da grande quantidade de combinações de parâmetros investigados.

4.4 Filtragem pelo método leave-one-out

Conforme foi demonstrado na seção anterior, o esforço para a determinação de ao menos uma rede neural para a identificação de cada tipo de classe implicaria na investigação de 4960 tipos de redes, demandando um considerável custo computacional. Para que tal esforço desnecessário fosse evitado, uma pergunta teria que ser respondida: Qual o tipo de rede – isto é, composição de atributos para a construção de uma rede neural – possui a maior probabilidade de sucesso para o reconhecimento de uma classe? Antes que seja apresentado o método utilizado, que tenta responder essa pergunta, será visto o tipo e a topologia de rede neural adotada na execução deste projeto.

4.4.1 A configuração de rede adotada

Por ser muito utilizado no reconhecimento de padrões, principalmente na área de visão computacional (ver Subseção 3.3.1.7), o tipo de rede neural usado foi o *Multi-Layer-Perceptron*. A configuração de rede adotada teve os seguintes parâmetros fixos: o número de camadas(3), número de neurônios por camada (30, 25 e 1 – respectivamente camada de entrada, intermediária e saída), tipo de conexão entre os neurônios(feedforward), limiar da função de ativação (0,85 – neurônio de saída) e o algoritmo de treinamento *back-propagation*. A criação, treinamento e teste das redes foram realizados com a NNToolBox do ambiente MatLab.

A arquitetura da rede anteriormente citada foi definida empiricamente, por meio de testes. Pela presença do único neurônio de saída, a estratégia escolhida foi a de classificação individual por classe, isto é, uma rede reconhece ou não um determinado tipo, para a qual foi treinada. Essa abordagem traz algumas vantagens, frente a uma arquitetura que tentasse classificar simultaneamente as 31 classes:

- maior probabilidade de se obter uma rede com sucesso de classificação, sendo que a rede só deve separar dois conjuntos;
- menor tempo de treinamento;
- independência entre as classes quanto ao sucesso ou não de se obter uma rede que as classifique;
- possibilidade de se obter uma diversidade de tipos de redes para uma mesma classe, aumentando a confiabilidade do processo de classificação
- identificação de quais os tipos de assinaturas, variações do domínio da frequência e intervalos são os mais indicados para cada tipo de classe.

O único parâmetro variável da configuração da rede adotada foi o número de entradas da rede, decorrente da variação dos intervalos de frequências investigadas no experimento.

4.4.2 Aplicando o método leave-one-out como um filtro

Utilizado para a análise de desempenho de topologias de redes neurais, principalmente nos casos em que as classes são representadas por um número reduzido de amostras, o método *leave-one-out* foi aplicado neste trabalho como um filtro para a seleção das melhores assinaturas utilizadas em uma configuração de rede fixa.

Para a aplicação do método, cada classe foi representada por um conjunto de cinco amostras. De cada conjunto foram extraídas todos os tipos de assinaturas a serem testadas como possíveis classificadores (redes) das 31 classes, isto é, 4960. Entretanto, pela característica do método, cada uma das 4960 redes foram geradas, treinadas e testadas 5 vezes, para que a alternância entre as amostras na participação do conjunto de teste e de treinamento fosse respeitada, conforme especifica o método *leave-one-out* (Seção 3.3.1.6).

A avaliação do potencial de classificação de cada assinatura por classe foi medida pela média de acertos efetivos da classe para a qual a rede foi treinada, desde de que apresentasse um erro quadrático médio baixo. Esse critério foi adotado para que, ao contrário de se utilizar apenas a média dos erros quadráticos médios, não houvesse o risco de uma assinatura ser selecionada por apresentar um baixo erro e mesmo assim não reconhecer a classe para a qual foi treinada. Por exemplo: uma rede poderia apresentar 100% de acerto em classificar amostras não pertencentes à classe para a qual foi treinada, mas

não conseguir classificar corretamente nenhuma amostra que pertencesse ao conjunto da respectiva classe. Isso seria possível, visto que proporcionalmente, o número de amostras para representar quais elementos pertencem à classe de interesse era muito menor (5) que o número de amostras que representavam o conjunto não pertencente (150).

Para que todas as assinaturas tivessem seu potencial de classificação por classe calculado, foi necessário criar, treinar e testar 28400 redes (8 tipos de assinaturas x 4 variações no domínio da frequência x 5 intervalos de frequência x 5 amostras pelo método *leave-one-out* x 31 classes), durante o processo de filtragem.

O que parece ser uma incoerência em um primeiro momento, com relação ao custo computacional – pois tem-se um número muito maior de redes para a análise das assinaturas por classe, do que propriamente para o reconhecimento (4960) – não é. Devido ao reduzido número de amostras por classe envolvido no processo de treinamento (4) para a classe de interesse em função do número para as demais (120), a análise das assinaturas pelo método *leave-one-out* possui um custo computacional muito menor, comparado com custo computacional que seria dispendido na tentativa de gerar todas as 4960 redes para a classificação. Isso se justifica devido ao maior número de elementos utilizados no conjunto de treinamento quando uma rede foi gerada para classificação (200 para a classe de interesse e 6000 para as demais).

Figura 4.5: Representação gráfica da interação entre os módulos

Para a execução do processo de filtragem descrito acima, foi necessário a implementação de um conjunto de procedimentos que automatizasse:

- o carregamento dos tipos de assinaturas para a geração das matrizes de vetores de características para treinamento, validação e teste;
- a geração da matriz de rótulos (labels/target);
- a criação, treinamento, validação e teste das redes neurais, com o rodízio do sistema 1/N-1 amostras entre teste/treinamento e;
- a contabilização das médias de acertos de todos os tipos assinaturas para as 31 classes e o armazenamento dessa informações em uma estrutura que será lida para gerenciar o processo de geração das redes classificadoras

Na Figura 4.5 é mostrada uma representação gráfica da interação desses módulos, implementados em MatLab.

4.5 Geração das amostras artificiais

Para suprir a carência de amostras para a geração de classificadores, por meio de redes neurais, amostras artificiais foram geradas tendo como base amostras reais. A geração de amostras artificiais para a utilização no treinamento de redes neurais é registrada na literatura. Um exemplo de caso é o projeto ALVINN (Autonomous Land Vehicle In a Neural Network) (Pomeroy, 1991) em que uma van era dirigida por uma rede neural, treinada com imagens artificiais. Basicamente, o método de geração das imagens artificiais consistia em aplicar às imagens digitalizadas, de alguns trechos do trajeto, transformações geométricas de rotação e translação, além da aplicação de ruídos na imagem resultante.

Nesta dissertação, a técnica aplicada baseou-se na recombinação, por meio de operadores genéticos (Goldberg, 1989; Holland, 1975), dos descritores de Fourier da assinatura de contorno paramétrico. Esta técnica foi desenvolvida pelo autor desta dissertação. Publicações na área de processamento de imagens e de algoritmos genéticos foram consultadas, mas até o momento do término da escrita deste capítulo, nenhuma técnica semelhante foi encontrada.

O processo de geração de imagens artificiais é constituído pela recombinação de amostras reais, por meio dos respectivos descritores de Fourier, da assinatura do contorno paramétrico. Essa recombinação foi realizada por meio de operadores genéticos: *crossing-over* e mutação. Nos sinais filhos resultantes foi aplicada a inversa da transformada de Fourier, resultando nas imagens artificiais. Todo o processo foi dividido em quatro etapas (Figura 4.6) :

- Divisão das amostras em duas famílias;
- Cruzamentos e Mutações;
- Pré-Seleção;
- Geração das Imagens;

Cada uma é detalhada nas subseções seguintes.

Figura 4.6: As etapas do processo de geração de amostras artificiais.

4.5.1 Divisão das Amostras em duas famílias

Como as amostras artificiais fariam parte do conjunto de treinamento, validação e teste, tomou-se o cuidado de que não houvesse nenhum favorecimento para a obtenção de classificadores com relação a forma de geração das amostras artificiais. Para isso, o conjunto de imagens artificiais utilizadas no treinamento e validação das redes, não poderiam ser geradas do mesmo conjunto de imagens reais utilizadas para a geração de imagens artificiais aplicadas na fase de teste. Essa condição implicou na divisão do conjunto de amostras de cada classe. Essas foram divididas em dois subconjuntos os quais foram denominadas de famílias A e B. Amostras pertencentes à família A jamais poderiam ser utilizadas para “cruzamento” com integrantes de B, e vice-versa. Dessa forma, todas as imagens artificiais geradas pela família A foram utilizadas exclusivamente para teste e as pertencentes a família B exclusivamente para treinamento e validação.

Para a divisão do conjunto de amostras de cada classe, em duas famílias, um critério adotado foi o de que cada família resultante apresentasse uma heterogeneidade dentro da classe, quanto à forma e tamanho, afim de garantir uma boa variabilidade de amostras artificiais.

4.5.2 Cruzamentos e Mutações

Divididas as amostras de cada classe em duas famílias, foi iniciado o processo de cruzamento entre indivíduos distintos (sempre dentro da mesma família), escolhidos aleatoriamente. Aplicando-se operadores genéticos, os cruzamentos entre as amostras foram realizados por meio dos respectivos descritores de Fourier do contorno paramétrico. Aleatoriamente, os sinais de dois indivíduos distintos (pais) são selecionados. Com os operadores de *crossing-over*, segmentos de cada indivíduos são selecionados e trocados entre si, resultando em dois novos indivíduos – a posição do segmento a ser cruzado e seu respectivo tamanho são determinados aleatoriamente. Em um segundo momento os filhos obtidos sofrem a ação de um operador de mutação, que altera o valor de algumas frequências, também selecionadas aleatoriamente. O operador de mutação permite uma variação percentual de 0 a 100% do módulo da menor frequência do sinal, sobre a frequência selecionada (Figura 4.7).

Figura 4.7: Processo de cross-over e mutação

Foram utilizadas duas implementações de operadores de *cross-over*: *cross-over* de 1 e 2 pontos de corte (Lacerda e Carvalho, 1999). Na Figura 4.8 é mostrada uma representação gráfica dos sinais dos pais e de seus respectivos filhos, de uma geração de 100 elementos. Pode-se observar os trechos contínuos do espectro que indicam serem idênticos a um dos pais.

Todos os sinais obtidos (filhos) foram armazenados juntamente com os outros dois sinais que os originaram (pais), para que posteriormente fossem analisados visualmente, afim de validar as amostras artificiais produzidas, antes da geração das imagens, conforme descrito na seção seguinte.

Figura 4.8: Representação de um espectro de Fourier por uma gama de cores(a); espectro de Fourier de pais 1 (b); espectro de Fourier de pais 2 (c); espectro de Fourier de filhos resultantes do cruzamento de pais 1 e pais 2 (c).

4.5.3 Seleção dos contornos artificiais

Esta etapa do processo de geração de amostras artificiais, apesar de simples, não pode ser totalmente automatizada, pois há a necessidade de aferição dos sinais de contornos artificiais gerados. Com a recombinação dos descritores de Fourier, quando aplicada a inversa, nem todo contorno obtido corresponde, em forma, aos “pais”. Alguns contornos gerados eram aberrações devido à incompatibilidade de combinação de frequências. Em consequência, foi necessário assinalar qual o sinal resultante era ou não válido. Como referência, a interface de geração de contornos artificiais apresenta, em sua parte superior, o contorno das folhas reais que originaram os contornos artificiais, apresentadas logo abaixo. Somente os contornos de folhas consideradas semelhante aos “pais” foram escolhidos para compor o conjunto de amostras, do qual seriam gerados os respectivos arquivos de imagens. Vale destacar que as visualizações dos sinais de contorno das amostras artificiais foram obtidas por recursos gráficos do MatLab, portanto não são ainda imagens nas dimensões reais, como de uma imagem de folha real, mas são suficientes para uma validação visual (ver Figura 4.9).

4.5.4 Geração das imagens

Selecionados os sinais artificiais de contorno válidos, torna-se necessário a obtenção das respectivas imagens, as quais são geradas com a transformada inversa de Fourier, conforme

Figura 4.9: Interfaces de seleção: conjunto de imagens sem seleção (a) e o mesmo conjunto após seleção (b).

descrito na Seção 3.2.1. Entretanto, durante a execução desse processo, um problema foi detectado. Devido à recombinação das frequências, observou-se uma descontinuidade do contorno (ver Figura 4.10), comprometendo o preenchimento do interior da forma obtida e, impossibilitando o seu uso para a extração de todos os sinais de contorno.

Para que todos os pontos fossem conectados, uma alternativa estudada foi o uso de algoritmos de ajuste de curva, afim de fechar todo o contorno. Entretanto, esta solução demandaria um custo computacional considerável. Uma outra solução foi buscada em operadores morfológicos de dilatação e erosão (Serra, 1982). Devido à pequena distância entre os pontos do contorno, a aplicação de uma sequência de operações de dilatação seguida de erosões mostrou-se muito eficiente no fechamento da curva (Figura 4.10). Com o completo fechamento dos contornos artificiais das folhas, os respectivos interiores foram preenchidos e as imagens resultantes foram gravadas em arquivos. Para cada classe de folhas, foram geradas 50 amostras artificiais das famílias do tipo A e 200 amostras das famílias B.

No total foram geradas 250 imagens por classes totalizando 7.750 imagens, as quais sofreram o mesmo processamento de obtenção de assinaturas descrito na Seção 4.3 para a geração dos classificadores.

Figura 4.10: Fechamento das curvas das amostras artificiais.

4.6 Geração, treinamento e teste das redes neurais

A última etapa do processo, conforme indicado na Figura 4.1, é a obtenção dos classificadores, ou seja, as redes neurais. Foi possível iniciar o processo de geração de classificadores para cada classe de folhas, tendo como referência a lista de assinaturas selecionadas pelo método *leave-one-out* (representado na Figura 4.1 como "Relatório dos Melhores Sinais"), uma configuração de rede definida (ver Seção 4.4.1) e um conjunto de amostras com um número considerável para as fases de treinamento, validação e teste.

Afim de agilizar a obtenção dos classificadores, esta etapa do experimento também foi automatizada. A Figura 4.11 representa a comunicação entre os módulos desenvolvidos em MatLab. Observe que este é bastante semelhante ao processo automatizado de filtragem de assinaturas pelo método *leave-one-out* (ver Figura 4.5), diferindo apenas pela ausência do módulo do referido filtro.

4.7 Validação das redes geradas com amostras reais

Obtidos os classificadores pelo uso exclusivo de amostras artificiais, tornou-se necessário que cada rede tivesse confirmada a capacidade de classificação, por meio de amostras reais. Dessa forma, todas as amostras reais de cada classe foram utilizadas para que as referidas redes às classificassem. Os resultados obtidos são apresentados no Capítulo seguinte.

4.8 Considerações Finais

Neste capítulo foram apresentados todos os procedimentos e métodos utilizados para a obtenção de classificadores por redes neurais, por meio de dados obtidos do contorno

Figura 4.11: Geração dos classificadores.

foliar. Também foram descritos os dois principais problemas para a obtenção de tais classificadores: baixo número de amostras e um vasta gama de possibilidades de exploração de combinação de parâmetros quando considerado: oito tipos de assinaturas de contornos, quadro representações dessas assinaturas no domínio da frequência e variação no intervalo de frequências a serem pesquisadas. E como esses problemas foram solucionados: geração de amostras artificiais por algoritmos genéticos e; filtragem das combinações de parâmetros (assinaturas variantes) e finalmente as etapas de geração dos classificadores e validação desses, utilizando-os na classificação de amostras reais.

Resultados

Neste capítulo, seguindo a sequência das etapas da solução proposta, são apresentados e discutidos os resultados da: determinação do potencial de classificação de cada assinatura; obtenção das amostras artificiais; geração treinamento e teste das redes com amostras artificiais; e finalmente o uso destas na classificação de amostras reais. Dessa forma, as seções deste capítulo estão organizadas conforme a sequência do experimento descrito no Capítulo 4. A maioria das tabelas citada está disponível nos Apêndices A, B, C e D. O deslocamento das tabelas para os apêndices citados visa uma melhor continuidade do texto, aqui apresentado.

5.1 Resultados do método de filtragem leave-one-out

A determinação do potencial de classificação, de cada assinatura para cada classe, obtido por meio do método leave-one-out (ver Seção 3.3.1.6), resultou nas tabelas A.1 a A.31 disponíveis no apêndice A. Em cada tabela são mostrados os resultados obtidos por tipo de assinatura, para cada classe. Pode-se observar que a estrutura dessas tabelas foi elaborada considerando-se todas as possibilidades de combinações entre os parâmetros previamente definidos. Os valores potenciais são apresentados no formato percentual e os campos que não apresentam valor algum, são considerados nulos. Optou-se por não inserir o número zero em cada campo, a fim de facilitar a visualização da distribuição dos valores obtidos, para cada tipo de classe.

Das trinta e uma classes distintas de vegetais, sete não apresentaram nenhum tipo de assinatura com algum potencial de classificação: Desconhecida01, *Tabebuia impetiginosa* (ipê-roxo), *Syzygium jambolanum* (jambolão), *Passiflora maliformis*, *Platycianus-regnelli* (pau-pereira), *Cordia trichotoma* (louro-pardo) e Lima.

As demais classes (24 no total) apresentaram ao menos um tipo de assinatura com potencial de classificação. As classes que tiveram o menor número (1) de assinaturas potenciais foram: *Passiflora pohlii*, *Pseudobombax grandiflorum* (imbiruçu), *Tampira Guianensis* (peito-de-pomba) e Desconhecida02. Os maiores números de assinaturas potenciais foram obtidos pelas classes: *Passiflora caerulea* (16), Coqueiro de jardim (47) e *Cacsalpinia echinata* (pau-brasil) (49).

Algumas considerações interessantes que se pode fazer, se referem à distribuição das assinaturas potenciais. Por meio de uma análise mais atenta das tabelas obtidas, são

observadas três situações, presentes entre as 31 tabelas de classes:

- classes que possuem um baixo número de assinaturas potenciais, dispersas entre os diversos tipos de assinaturas (Tabelas A.1 e A.12);
- classes que possuem um baixo número de assinaturas potenciais, concentradas em um determinado tipo de assinatura (Tabelas A.11, A.16 e A.29), e;
- classes que possuem um grande número de assinaturas potenciais, em cujas tabelas pode-se constatar a presença dos dois tipos de agrupamentos, citados nas situações anteriores: alta concentração em determinados tipos de assinaturas (ou intervalos de frequência), e regiões da tabela onde há uma dispersão de algumas assinaturas potenciais (Tabelas A.2 A.5, A.19 e A.24).

Analisando-se os três padrões presentes nas tabelas, o autor acredita que haja uma estreita relação entre as três configurações anteriormente descritas, e o índice de potencial de classificação de cada assinatura. No primeiro grupo, observou-se a predominância de um baixo índice de potencial de classificação (20%), enquanto que, uma situação oposta pode ser evidenciada no segundo grupo, no qual se constata um agrupamento dos potenciais de classificação em um determinado tipo de assinatura, associado a valores percentuais maiores – valores de 40% e 60% são encontrados. O terceiro grupo vem a confirmar o comportamento constatado nas duas primeiras situações, verificando-se a presença de altos percentuais de classificação (40%, 60% e 80%) quando estes estão concentrados em um tipo de assinatura, e baixos índices de potencial de classificação (20%) quando estão mais dispersos entre os tipos de assinaturas.

5.2 Resultados da geração das amostras artificiais

Conforme descrito no processo de obtenção de amostras artificiais (Seção 4.5), a técnica desenvolvida permite a geração imediata de um conjunto de contornos semelhantes, por meio da aplicação de operadores genéticos (cross-over e mutação) sobre os espectros de frequência dos contornos das amostras “pais”.

O tempo de processamento necessário para a geração dos conjuntos de amostras artificiais é irrelevante, em função da simplicidade do algoritmo. Entretanto, alguns contornos incompatíveis com os dos “pais” também são gerados, havendo a necessidade de seleção manual. Dessa forma, são descartadas as amostras geradas que não possuam similaridade com relação aos contornos das respectivas amostras “pais”.

Nas tabelas B.1 a B.31 do apêndice B são mostrados os conjuntos de folhas artificiais que já sofreram seleção. Os espaços contidos entre as imagens indicam um descarte de amostra. Deve-se observar que os contornos localizados na primeira linha de figuras, da parte superior, são os “pais” (amostras reais). Os contornos gerados possuem o interior preenchido (“filhos” – amostras artificiais). O número máximo de folhas artificiais, geradas por execução do programa desenvolvido é de 100 amostras.

Na tabela 5.1 é apresentado, por classe, o percentual de imagens restantes após o processo de seleção e descarte – obtidos na execução deste trabalho.

Pode-se notar que, mesmo havendo descarte, a média do percentual de aproveitamento das amostras artificiais geradas, fica em torno de 85%, o que na opinião do autor é um excelente índice de aproveitamento.

O potencial do método é evidenciado quando aplicado em um baixo número de amostras “pais”, não o impedindo de obter uma variedade de sinais, conforme é mostrado nas figuras B.1, B.2, B.4, B.6, B.8, B.9 e B.11. Observou-se também que, em classes onde há

Classes	%Aproveitamento das amostras geradas
<i>Passiflora amethystina</i>	87,75%
<i>Passiflora caerulea</i>	74,25%
<i>Passiflora coriacea</i>	84,20%
<i>Passiflora foetida</i>	75,20%
<i>Passiflora gibertii</i>	83,00%
<i>Passiflora maliformis</i>	87,50%
<i>Passiflora miersii</i>	99,00%
<i>Passiflora organensis</i>	95,75%
<i>Passiflora pohillii</i>	84,50%
<i>Passiflora suberosa</i>	93,75%
<i>Miroxylon peruvianum</i> (cabreúva)	99,50%
<i>Rauwolfia sellowii</i> (casca d'anta)	97,25%
<i>Pseudobombax grandiflorum</i> (imbiruçu)	96,00%
<i>Tabebuia impetiginosa</i> (ipê-roxo)	82,50%
<i>Syzygium jambolanum</i> (jambolão)	85,00%
<i>Hymenaea courbaril</i> (jatoba)	94,75%
<i>Cariniana estrellensis</i> (jequitibá)	97,50%
<i>Cordia trichotoma</i> (louro-pardo)	92,25%
<i>Eriotheca candolleana</i> (paina-da-mata)	71,67%
<i>Caesalpinia echinata</i> (pau-brasil)	95,00%
<i>Platycianus regnellii</i> (pau-pereira)	90,00%
<i>Eugenia uniflora</i> (pitanga)	100,00%
<i>Tapirira guianensis</i> (peito de pombo)	86,17%
coqueiro jardim	80,17%
descon01	91,00%
descon02	74,17%
descon03	78,25%
descon04	79,50%
descon05	80,50%
lima	96,00%
limao	85,50%

Tabela 5.1: Aproveitamento das amostras artificiais geradas, em valores percentuais.

uma maior variabilidade da forma dos “pais”, ou a presença de picos de curvatura, houve um maior percentual de descarte (Figuras B.1, B.5 e B.10), o que possivelmente está relacionado com a maior dificuldade de compatibilização entre os trechos dos espectros de frequências, trocados durante o processo de cruzamento entre os sinais “pais”.

Outra característica positiva do método, foi a possibilidade de obtenção de uma variabilidade não só da forma, mas também do tamanho das amostras artificiais, o que pode ser constatado nas imagens B.3, B.4, B.5 e B.9 do apêndice B. Convém mencionar que, todas as imagens estão sob um mesmo padrão de escala.

Notou-se também que, em algumas classes os contornos gerados são muito semelhantes a um dos pais, o que não significa uma falha do método de geração de amostras artificiais, pois embora deve-se ressaltar que, mesmo as formas (fenótipo) sendo muito semelhantes a um dos “pais”, os respectivos espectros de frequências (genótipos) são diferentes. O autor acredita que o sucesso da combinação entre a transformada de Fourier e os operadores genéticos, para produção de contornos artificiais, se deve principalmente às características da transformada de Fourier, isto é, possibilidade de reconstrução do sinal original (através de sua inversa) e a representação, de forma uniforme, de qualquer sinal (contornos) dentro de intervalos de frequências.

5.3 Resultados das RNs geradas e testadas por amostras artificiais

Utilizando as assinaturas que apresentaram um potencial de classificação (por meio do método de filtragem *leave-one-out*), e os conjuntos de amostras de contornos de folhas

(gerados artificialmente) foi possível direcionar o esforço computacional para a obtenção de classificadores baseados em redes neurais.

No apêndice C, as tabelas C.1 a C.8 trazem os resultados da classificação de amostras artificiais, obtidas por redes neurais, listadas por tipo de assinatura. Estas tabelas estão estruturadas da seguinte forma: as quatro primeiras colunas caracterizam o tipo da rede neural identificando a Classe Assinalada (classe para qual a rede foi treinada para classificar), Assinatura, Domínio (variação de domínio de frequências) e Intervalo intervalo de frequências consideradas); as demais sete colunas referem-se aos resultados de classificação do total de amostras testes (50 amostras por classe) – CACC (Classe Assinalada Corretamente Classificada), CAIC (Classe Assinalada Incorretamente Classificada), CDCC (Classe Desconhecida Corretamente Classificada), CDIC (Classe Desconhecida Incorretamente Classificada). Também são apresentados os respectivos campos (em valores percentuais) %CACC, %CDCC e %GeralAcertos (este último representa o percentual total de acertos de classificação entre a classe assinalada e a classe desconhecida para cada rede neural).

Convém mencionar que os índices de potenciais de classificação (Tabelas do apêndice A), atuam como meros indicadores, não havendo uma relação direta com os percentuais de classificação obtidos pelas RNs. Além disso, todas as RNs obtidas apresentadas no apêndice B, atingiram no mínimo um percentual de 85% no requisito CACC%, caso contrário eram descartadas. A seguir, são listadas as classes que tiveram RNs descartadas com os seus respectivos tipos de assinaturas:

Cariniana estrellensis (Jequitibá – Tabela A.17) : NFT crvap 2x120.

Eriotheca candolcana (Paina-da-mata – Tabela A.19) : FFTCz aang 2x90 e 2x120; NFT aang 2x120; PwsNFT aang 2x30 e 2x150; NFT angv 2x30 e 2x60; PwsNFT angv 2x30; PwsCz crvba 2x30 e 2x120.

Hymenea courbaril (Jatobá – Tabela A.16) : NFT crvap 2x30, 2x60, 2x90, 2x120 e 2x150.

Passiflora caerulea (Maracujá – Tabela A.2) : PwsNFT angv 2x60; FFTCz crvap 2x30.

Rauwolfia sellowii (Casca d'anta – Tabela A.12) : NFT crvba 2x120.

Tapirira guianensis (Peito-de-pomba – Tabela A.23) : FFTCz crvba 2x60 e 2x120.

Coqueiro de jardim (Tabela A.24) : PwsCz cntgb 2x150; NFT angv 2x30.

Desconhecida 02 (Tabela A.26) : NFT cntgb 2x90.

Desconhecida 03 (Tabela A.27) : NFT crvba 2x90 e 2x120.

Limão (Tabela A.31) : NFT crvap 2x120.

Desconhecida 05 (Tabela A.29) : NFT crvba 2x30, 2x60, 2x90 e 2x120.

Algumas considerações importantes que devem ser levantadas com base nos resultados obtidos desta etapa do experimento, são as seguintes:

i) durante a obtenção das redes neurais, pôde-se confirmar a capacidade de indicação do potencial de classificação apresentada nas tabelas obtidas pelo método de filtragem *leave-one-out*. Bastando para isto, verificar que dos 308 tipos de assinaturas indicados para a geração de um classificador, apenas 31(10%) assinaturas não derivaram classificadores, dos quais 25 tinham um potencial de classificação de 20% contra 6 com potencial de 40%;

ii) todos os demais tipos de assinaturas, com um potencial maior que 40%, derivaram em classificadores.

Outro fato que chamou a atenção do autor, foi o alto número de tipos de assinaturas descartadas das classes *Hymenea courbaril* e Desconhecida05, que coincidentemente eram do tipo NFT crvba. Tentou-se levantar algumas hipóteses, mas nada pode ser concluído.

5.4 Resultados das RNs aplicadas na classificação de amostras reais

Com a finalidade de comprovar a capacidade de classificação das redes geradas e testadas, por meio do uso de amostras exclusivamente artificiais (tanto na fase de treinamento quanto na de teste), e por conseguinte verificar a validade de toda a metodologia desenvolvida; as redes obtidas foram utilizadas para a classificação de conjuntos de amostras reais. Os resultados obtidos estão disponíveis no apêndice D, nas tabelas D.1 a D.8.

O que se observa, é que na grande maioria das redes, o valor percentual de classificação de um conjunto de amostras reais está muito próximo do resultado de classificação do conjunto de amostras artificiais correspondente. Algumas exceções são encontradas, mas sem comprometer o resultado global. Estas, a seguir, são listadas por tipo de assinatura:

Contorno angular : das 32 redes (Tabela D.1), 01 teve um percentual de 60.00% (*P. amethystina*) e as 5 demais 71.43% (*P. gibertii*).

Ângulo de visão : este conjunto de redes apresentou 2 redes com a taxa abaixo do limiar adotado, uma com 71.43% (*P. gibertii*) e outra com 57.14% (*P. gibertii*) - de um conjunto de 20 redes (Tabela D.2).

Contorno global : com um número de 30 redes este conjunto apresentou 2 com as respectivas taxas de classificação - uma com 57.14% (*P. gibertii*) e outra com 60.00% (*P. amethystina*) (Tabela D.3).

Contorno apical : De um conjunto total de 50 redes, 02 apresentam as respectivas taxas 62.00% (*P. coriacea*) e 75.00% (*P. coriacea*) (Tabela D.4).

Curvatura global : de um conjunto de 24 redes, 10 apresentaram as seguintes taxas - 9 com 71.43% (*P. gibertii*) e 1 com 77.78% (*C. estrellensis* - jequitibá) (Tabela D.6).

Curvatura apical : de um conjunto de 31 redes geradas, 4 ficaram com uma taxa percentual de classificação baixo dos 80.00% - 2 com 70.00% (*P. organensis* e *E. candoleana* - paina-da-mata), 1 com 60.00% (*E. candoleana* - paina-da-mata) e 1 com 42.00% (*P. suberosa*) (Tabela D.6).

Curvatura basal : das 50 redes geradas, 5 apresentaram as seguintes taxas - 1 com taxa de 70.00% (*Miroryon peruiferum* - cabreúva) , 2 com 60.00% (*M. peruiferum* - cabreúva e *C. estrellensis* - jequitiba), 1 com 55.00% (*C. estrellensis* - jequitiba) e 1 com 30.00% (*E. candoleana* - paina-da-mata).

Para o autor, os valores considerados exceções são aqueles inferiores a 80% - a definição deste percentual se justifica pela predominância do baixo número de amostras reais (em média de 5), que compõem cada conjunto de classe.

Com os resultados apresentados nesta seção, acredita-se ter validado todas as redes (com exceção das redes anteriormente citadas) obtidas com a metodologia desenvolvida. Apesar de alguns classificadores terem obtidos resultados abaixo do limiar esperado (80%), durante a etapa de validação com amostras reais, apenas duas classes deixaram de ser

classificáveis: *Passiflora coriacea* e *Passiflora organensis*, devido às respectivas redes neurais terem obtido no máximo uma taxa de acerto de 75% e 71% respectivamente. Mesmo assim, pode-se observar pelos próprios valores, que há uma grande possibilidade que estas taxas subam para 80%, que segundo o autor poderia ser feito caso os respectivos conjuntos de amostras reais fossem ampliadas ao menos para 12 amostras por classe, contra os atuais números de 8 e 7 amostras.

Com relação ao número de redes obtidas, das 4960 possibilidades resultantes da combinação dos parâmetros considerados no experimento (ver Seção 4.1), graças ao método de filtragem aplicado (ver Seção 4.4.2), este número foi reduzido para 308 possíveis redes, das quais somente 277 foram obtidas. Após a etapa de validação com as amostras reais, esse número reduziu-se para 246 redes, o qual representa 80% do número total de classificadores previstos. O que pode ser considerado na opinião do autor, um bom desempenho do método utilizado. As Tabelas 5.3, 5.4 e 5.5 trazem de forma sumária a distribuição das redes (previstas e validadas), por: tipo de assinatura, variação do domínio da frequência e intervalo de frequências.

De uma forma geral, o trabalho desenvolvido obteve bons resultados. Das 31 classes, o método indicou a possibilidade de classificação de 21 – indicado pelo método de filtragem (leave-one-out). Devido a um exigente critério, somente 20 das 24 classes, obtiveram redes neurais, geradas a partir de amostras artificiais (ver Seção 4.5). Dessas, após o processo de teste com amostras reais, 18 classes tiveram seus classificadores aprovados. Este número representa uma eficiência do processo de 75% – considerando-se que o número previsto de classes que teriam ao menos um classificador era de 24 classes. Além disso, esta eficiência poderia ser facilmente elevada para 83%, com o já citado aumento de amostras para as classes *Passiflora coriacea* e *Passiflora organensis*. A Tabela A.9 apresenta de forma resumida as classes que obtiveram classificadores entre os oito tipos de assinaturas e os valores percentuais máximos obtidos na validação por amostras reais.

5.5 Considerações finais

Este capítulo apresentou os resultados obtidos em cada fase da execução dos procedimentos experimentais, referentes à : i) determinação do potencial de classificação de cada tipo de assinatura; ii) geração de amostras artificiais, com dados estatísticos de aproveitamento das amostras geradas por classe, bem como os contornos obtidos (Apendice B); iii) geração e teste das redes neurais, utilizando-se de amostras artificiais e; iv) validação das redes neurais obtidas por meio de testes utilizando-se de amostras reais. Por final, são apresentados alguns resultados referentes à distribuição das redes obtidas através do tipo de assinatura, variação do domínio da frequência e variação do intervalo de frequências.

Com os resultados obtidos no processo de determinação do potencial de cada tipo de assinatura foi, possível observar uma considerável coerência com relação às redes neurais obtidas por meio do uso de amostras artificiais, pois do total de redes previstas, 90% foram obtidas e após a validação com amostras reais, esse taxa foi reduzida somente para 80%. Este valor percentual de redes validadas também atesta a qualidade do processo de geração de amostras artificiais. De forma geral, os bons resultados obtidos em cada etapa do processo indicam o potencial da metodologia adotada que, embora partindo de um considerável número de classes (31) representadas por um baixíssimo número de amostras (5 a 25), possibilitou a obtenção de classificadores para 58% do total geral de classes e 75% para o total de classes previstas a serem classificadas.

Classes	cntgb	cntap	cntba	aang	angv	crvgb	crvap	crvba
(+) <i>Passiflora amethystina</i>	60%	80%		60%		100%		
(+) <i>Passiflora caerulea</i>	100%	100%	100%	100%	0%		0%	80%
(+) <i>Passiflora coriacea</i>		75%						
(+) <i>Passiflora foetida</i>	100%	83%	100%	100%		83%		
(+) <i>Passiflora gibertii</i>	100%	100%		71%	0%	71%		
(-) <i>Passiflora maliformis</i>								
(+) <i>Passiflora miersii</i>						100%		
(+) <i>Passiflora organensis</i>						71%	71%	
(+) <i>Passiflora pohillii</i>		100%						
(+) <i>Passiflora suberosa</i>	85%	100%		85%		85%	85%	
(+) <i>Miroxylon peruiferum</i> (cabreuva)								100%
(+) <i>Rauwolfia sellowii</i> (casca d'anta)						100%		0%
(+) <i>Pseudobombax grandiflorum</i> (imbiruçu)						100%		
(-) <i>Tabebuia impetiginosa</i> (ipê-roxo)								
(-) <i>Syzygium jambolanum</i> (jambolão)								
(+) <i>Hymenaea courbaril</i> (jatobá)							0%	99%
(+) <i>Cariniana estrellensis</i> (jequitibá)						71%	0%	88%
(-) <i>Cordia trichotoma</i> (louro-pardo)								
(+) <i>Eriotheca candoleana</i> (paina-da-mata)			100%	100%	0%		80%	30%
(+) <i>Caesalpinia echinata</i> (pau-brasil)		100%	96%		100%	100%	100%	100%
(-) <i>Platycianus regnelli</i> (pau-pereira)								
(+) <i>Eugenia Uniflora</i> (pitanga)					100%		100%	100%
(!) <i>Tapirira guianensis</i> (peito de pombo)								0%
(+) <i>Coqueiro de jardim</i>	100%	100%	100%		0%	100%	100%	100%
(-) Desconhecida01								
(!) Desconhecida02	0%							
(!) Desconhecida03								0%
(+) Desconhecida04								98%
(+) Desconhecida05								99%
(-) <i>Líma</i>								
(!) <i>Límao</i>							0%	

Tabela 5.2: Classes com os máximos percentuais obtidos por um classificador – por tipo de assinatura. Os tipos de marcadores que antecedem cada nome de classe significam: classificador previsto e obtido (+) , classificador não previsto (-) e classificador previsto e não obtido (!).

Intervalos	cnlgb		cnlsp		cnlba		aang		angv		crvgb		crvap		crvba		Totais Classificadores		%
Classes	Previsto	Validado	Previsto	Validado	Previsto	Validado	Previsto	Validado	Previsto	Validado	Previsto	Validado	Previsto	Validado	Previsto	Validado	Previstos	Validados	Validados/Previsto
(+) Passiflora amethystina	-	0	1	1	-	-	1	0	-	-	1	1	-	-	-	-	4	2	50.00%
(+) Passiflora caerulea	9	9	14	14	6	6	13	13	1	0	-	-	1	0	2	2	46	44	95.65%
(+) Passiflora coriacea	-	-	2	0	-	-	-	-	-	-	-	-	-	-	-	-	2	0	0.00%
(+) Passiflora foetida	2	2	7	7	10	10	5	5	-	-	1	1	-	-	-	-	25	25	100.00%
(+) Passiflora gibertii	6	5	10	10	-	-	5	0	2	0	7	0	-	-	-	-	30	15	50.00%
(-) Passiflora maliformis	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
(+) Passiflora miersii	-	-	-	-	-	-	-	-	-	-	2	2	-	-	-	-	2	2	100.00%
(+) Passiflora orgahensis	-	-	-	-	-	-	-	-	-	-	1	0	1	0	-	-	2	0	0.00%
(-) Passiflora pohillii	-	-	1	1	-	-	-	-	-	-	-	-	-	-	-	-	1	1	100.00%
(+) Passiflora suberosa	1	1	7	7	-	-	5	5	-	-	2	1	2	1	-	-	17	15	88.24%
(+) Miconia peruviana (cabreúva)	-	-	-	-	-	-	-	-	-	-	-	-	-	-	12	10	12	10	83.33%
(+) Pouteria sellowii (casca d'anta)	-	-	-	-	-	-	-	-	-	-	1	1	-	-	1	0	2	1	50.00%
(+) Pseudobombax grandiflorum (imbirucu)	-	-	-	-	-	-	-	-	-	-	1	1	-	-	-	-	1	1	100.00%
(-) Tabebuia impetiginosa (ipê-roxo)	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
(-) Syzygium jambolanum (jambolão)	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
(+) Hymenaea courbaril (jatobá)	-	-	-	-	-	-	-	-	-	-	-	-	5	0	1	1	6	1	16.67%
(+) Cariniana estrellensis (jequitibá)	-	-	-	-	-	-	-	-	-	-	0	1	0	0	3	1	5	1	20.00%
(-) Cordia trichotoma (touro-perdido)	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
(-) Eriotheca candolleana (palma-de-mata)	-	-	-	-	3	3	8	3	3	0	-	-	3	-	3	0	20	7	35.00%
(+) Caesalpinia echinata (pau-brasil)	-	-	3	3	2	2	-	-	-	-	6	6	15	15	14	14	49	49	100.00%
(-) Platycianus regnellii (pau-pereira)	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
(+) Eugenia uniflora (pitanga)	-	-	-	-	-	-	-	-	9	9	-	-	7	7	8	8	24	24	100.00%
(!) Tapira guianensis (peito de pombo)	-	-	-	-	-	-	-	-	-	-	-	-	2	0	-	-	2	0	0.00%
(-) Coqueiro de Jardim	11	10	11	11	14	14	-	-	1	0	1	1	3	3	8	6	47	45	95.74%
(-) Desconhecida01	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
(!) Desconhecida02	1	0	-	-	-	-	-	-	-	-	-	-	-	-	-	-	1	0	0.00%
(-) Desconhecida03	-	-	-	-	-	-	-	-	-	-	-	-	-	-	2	0	2	0	0.00%
(+) Desconhecida04	-	-	-	-	-	-	-	-	-	-	-	-	-	-	2	2	2	2	100.00%
(+) Desconhecida05	-	-	-	-	-	-	-	-	-	-	-	-	-	-	5	1	5	1	20.00%
(-) Lima	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
(!) Lima	-	-	-	-	-	-	-	-	-	-	-	-	1	0	-	-	1	0	0.00%
Totais	31	27	56	54	35	35	37	26	25	18	24	14	39	27	61	45	308	246	79.87%
% de Validados/Previsto	87.10%		96.43%		100.00%		70.27%		72.00%		58.33%		69.23%		73.77%				
Classes Classificadas	5		8		5		4		2		8		5		9				

Tabela 5.3: Distribuição de classificadores por tipo de assinaturas. Os tipos de marcadores que antecedem cada nome de classe significam: classificador previsto e obtido (+) , classificador não previsto (-) e classificador previsto e não obtido (!).

Dominios	FFTCz		NFT		PwsCz		PwsNFT		Totais Classificadores		%
Classes	Previsto	Validado	Previsto	Validado	Previsto	Validado	Previsto	Validado	Previstos	Validados	Validados/Previsto
(+) <i>Passiflora amethystina</i>	1	1	2	0			1	1	4	2	50,00%
(+) <i>Passiflora caerulea</i>	7	6	18	18	6	6	15	14	46	44	95,65%
(+) <i>Passiflora coriacea</i>					1	0	1	0	2	0	0,00%
(+) <i>Passiflora foetida</i>	1	1	15	15			9	9	25	25	100,00%
(+) <i>Passiflora gibertii</i>	4	0	13	8	2	0	11	7	30	15	50,00%
(-) <i>Passiflora maliformis</i>											
(+) <i>Passiflora miersii</i>	2	2							2	2	100,00%
(+) <i>Passiflora organensis</i>	2	0							2	0	0,00%
(+) <i>Passiflora pohillii</i>			1	1					1	1	100,00%
(+) <i>Passiflora suberosa</i>	3	1	8	8			6	6	17	15	88,24%
(+) <i>Miroxylon peruvianum</i> (cabreuva)	3	2	5	5			4	3	12	10	83,33%
(+) <i>Rauwolfia sellowii</i> (casca d'anta)	1	1	1	0					2	1	50,00%
(+) <i>Pseudobombax grandiflorum</i> (imbiruçu)	1	1							1	1	100,00%
(-) <i>Tabebuia impetiginosa</i> (ipê-roxo)											
(-) <i>Syzygium jambolanum</i> (jambolão)											
(+) <i>Hymenaea courbaril</i> (jatobá)			5	0			1	1	6	1	16,67%
(+) <i>Cariniana estrellensis</i> (jequitibá)	4	1	1	0					5	1	20,00%
(-) <i>Cordia trichotoma</i> (louro-pardo)											
(+) <i>Eriotheca candoleana</i> (paina-da-mata)	3	0	11	6	3	1	3	0	20	7	35,00%
(+) <i>Caesalpinia echinata</i> (pau-brasil)	12	12	19	19	3	3	15	15	49	49	100,00%
(-) <i>Platycianus regnellii</i> (pau-pereira)											
(+) <i>Eugenia uniflora</i> (pitanga)	4	4	12	12	2	2	6	6	24	24	100,00%
(!) <i>Tapirira guianensis</i> (peito de pombo)	2	0							2	0	0,00%
(+) <i>Coqueiro de jardim</i>	9	9	20	19	2	1	16	16	47	45	95,74%
(-) Desconhecida01											
(!) Desconhecida02			1	0					1	0	0,00%
(!) Desconhecida03			2	0					2	0	0,00%
(+) Desconhecida04			1	1			1	1	2	2	100,00%
(+) Desconhecida05			5	1					5	1	20,00%
(-) Lima											
(!) Limão			1	0					1	0	0,00%
Totais	59	41	141	113	19	13	89	79	308	246	79,87%
% de Validado/Previsto	69,49%		80,14%		68,42%		88,76%				
Classes Classificadas	12		12		5		11				

Tabela 5.4: Distribuição de classificadores por variação do domínio. Os tipos de marcadores que antecedem cada nome de classe significam: classificador previsto e obtido (+) , classificador não previsto (-) e classificador previsto e não obtido (!).

Intervalos Classes	2x30		2x60		2x90		2x120		2x150		Totais de Classificadores		% de Classificadores Validados/Previstos
	Previsto	Validado	Previsto	Validado	Previsto	Validado	Previsto	Validado	Previsto	Validado	Previstos	Validados	
(+) Passiflora amethystina			2	0			2	2			4	2	50,00%
(+) Passiflora caerulea	9	8	9	8	10	10	8	8	10	10	46	44	95,65%
(+) Passiflora coriacea			1	0	1	0					2	0	0,00%
(+) Passiflora foetida	7	7	4	4	4	4	5	5	5	5	25	25	100,00%
(+) Passiflora gibertii	7	4	8	3	5	3	5	2	5	3	30	15	50,00%
(-) Passiflora maitformis													
(+) Passiflora miersii	1	1					1	1			2	2	100,00%
(+) Passiflora organensis			1	0	1	0					2	0	0,00%
(+) Passiflora pohillii	1	1									1	1	100,00%
(+) Passiflora suberosa	3	2	3	3	3	3	4	3	4	4	17	15	88,24%
(+) Miroxylon periferum (cabreuva)	3	3	3	3	1	1	2	1	3	2	12	10	83,33%
(+) Rauwolfia selfowii (casca d'anta)	1	1					1	0			2	1	50,00%
(+) Pseudobombax grandiflorum (imbiruçu)							1	1			1	1	100,00%
(-) Tabebuia impetiginosa (ipê-roxo)													
(-) Syzygium jambolanum (jambolão)													
(+) Hymenaea courbaril (jatobá)	1	0	2	1	1	0	1	0	1	0	6	1	16,67%
(+) Cariniana estrellensis (jequitibá)	2	1			1	0	2	0			5	1	20,00%
(-) Cordia trichotoma (louro-pardo)													
(+) Eriotheca candoleana (paina-da-mata)	8	3	4	2	2	1	4	0	2	1	20	7	35,00%
(+) Caesalpinia echinata (pau-brasil)	10	10	7	7	9	9	10	10	13	13	49	49	100,00%
(-) Platycianus regnellii (pau-pereira)													
(+) Eugenia Uniflora (pitanga)	4	4	4	4	5	5	6	6	5	5	24	24	100,00%
(!) Tapirira guianensis (peito de pomba)			1	0			1	0			2	0	0,00%
(+) Coqueiro de Jardim	10	9	11	11	8	8	9	9	9	8	47	45	95,74%
(-) Desconhecida01													
(!) Desconhecida02					1	0					1	0	0,00%
(!) Desconhecida03					1	0	1	0			2	0	0,00%
(+) Desconhecida04			1	1					1	1	2	2	100,00%
(+) Desconhecida05	1	0	1	0	1	0	1	0	1	1	5	1	20,00%
(-) Lima													
(!) Limão							1	0			1	0	0,00%
Totais	68	54	62	47	54	44	65	48	59	53	308	246	79,87%
% de Validado/Previsto	79,41%		75,81%		81,48%		73,85%		89,83%				
Classes Classificadas	13		11		9		11		11				

Tabela 5.5: Distribuição de classificadores por tipo intervalo de frequência. Os tipos de marcadores que antecedem cada nome de classe significam: classificador previsto e obtido (+) , classificador não previsto (-) e classificador previsto e não obtido (!).

Conclusão

Com o intuito de contribuir no desenvolvimento do projeto TreeVis, este trabalho se propôs obter classificadores de espécies vegetais por meio de assinaturas obtidas do contorno foliar. A assinatura do contorno foi escolhida como objeto de estudo com a finalidade de enriquecer a diversidade dos métodos biométricos implementados no projeto TreeVis.

O que se esperava obter era um classificador com base em algum tipo de assinatura (no espectro da frequência), utilizando apenas um determinado número de descritores de Fourier para todas as 31 classes de vegetais. Entretanto, o que se notou foi que, durante a tentativa de se utilizar a classificação por distância mínima entre vetores, algumas classes respondiam melhor, ou não à classificação, dependendo de como o vetor de característica fosse composto. Isto é influenciavam na classificação de uma espécie, o tipo de assinatura utilizada; se esta fosse ou não transposta para o espectro de frequência; ou espectro da potência; se fosse adotado, ou não, algum tipo de normalização; e o número de descritores que seriam considerados (faixas de frequências).

Apesar da preciosa informação obtida quanto a importância da variabilidade dos tipos de assinatura, para a classificação de uma diversidade de espécies, o método de classificação por distância mínima se mostrou uma opção muito pobre quanto à questão de resultados de classificação: além de exigir um enorme esforço empírico na composição dos vetores. Dessa forma, optou-se por trabalhar com redes neurais.

Definida a forma de obtenção de classificadores, por meio de redes neurais, dois problemas surgiram em função da adoção desta abordagem:

- a grande variabilidade de assinaturas a serem investigadas - devido as possíveis formas de construção do vetor de característica, implicaria na geração de muitos tipos de redes neurais consumindo um grande esforço computacional, e;
- o reduzido número de amostras por classes - deve-se lembrar que a obtenção de bons classificadores está estritamente ligada à quantidade e qualidade do conjunto de amostras, para o processo de treinamento de qualquer classificador. E infelizmente o autor contava com um pequeno acervo de amostras para a utilização de redes neurais como classificadores.

Para o primeiro problema, foi elaborado um sistema robusto para analisar a viabilidade de identificação de vegetais por meio de um conjunto de assinaturas de contorno. A

implementação desse sistema considerou, para a construção dos vetores de característica das amostras, a utilização de alguns tipos de assinaturas de contorno, transpostas para o domínio da frequência (espectro da frequência e espectro da potência), variando-se os tipos de normalizações e número de descritores (intervalos). Esta variabilidade de assinaturas na análise de contornos, possibilitou aumentar consideravelmente a investigação do espaço de soluções para a aquisição de classificadores (redes neurais). Assim, considerando-se a combinação de oito assinaturas de contorno, quatro variações do domínio da frequência, e cinco intervalos de frequências, para um o número de 31 classes de vegetais, deveriam ser gerados um total de 4960 classificadores. Entretanto, tentar gerar todos os possíveis classificadores, envolveria um grande risco de desperdício de esforço computacional e tempo. Assim, surge a necessidade de prever qual o potencial de classificação de cada combinação. Como resposta à essa necessidade, neste trabalho foi proposto um método de filtragem de assinaturas com base no método leave-one-out, o qual apresentou um considerável desempenho, pois das 4960 possibilidades de obtenção de classificadores, o método de filtragem reduziu este número para 308 (6% dos 4960), apontando-os como os que ofereceriam maior possibilidade de sucesso na obtenção de classificadores. O qual foi confirmado pois, do número apontado 90% desses, resultaram em classificadores com alto percentual de acerto.

Quanto ao problema do reduzido número de amostras por classe e, em virtude da impossibilidade de aquisição de mais exemplares de folhas, este trabalho apresentou um método para a geração de contornos artificiais de folhas, baseados na utilização do espectro da frequência do contorno paramétrico de amostras reais, associados à operadores genéticos. A idéia básica consistiu na recombinação do espectro da frequência do contorno paramétrico de duas amostras reais, através dos operadores genéticos de cross-over e de mutação, resultando em dois novos espectros. Aplicando-se a transformada inversa de Fourier, obtém-se dois novos indivíduos(contornos) que podem assumir a mesma aparência(fenótipo) dos pais, mas apresentarão espectros da frequência(genótipos) distintos. Através deste método foram geradas 250 novas amostras (imagens) por classe, as quais foram utilizadas para criação de redes neurais. Cabe aqui ressaltar que até o momento em que esta dissertação estava sendo escrita, o não foi encontrada na literatura da área de algoritmos genéticos, nenhum trabalho similar na geração de formas de contorno baseados em formas reais.

Utilizando-se dos tipos assinaturas de maior potencial de classificação (apontadas pelo método e filtragem) e das imagens artificiais de contornos de folhas, geradas pelo método descrito acima, foram obtidas as redes neurais para a classificação das espécies vegetais. A seguir, essas redes foram finalmente colocadas à prova sendo utilizadas na classificação de amostras reais, validando assim, todo o processo desenvolvido por este trabalho.

Os resultados obtidos indicam um considerável desempenho do sistema desenvolvido - com relação à quantidade de classes classificadas, das 31 classes, o processo de filtragem indicou a impossibilidade de classificação de 07 classes, reduzindo o número para 24 classes com potencial de classificação. Dessas, 18 classes (75%) obtiveram ao menos um classificador validado com amostras reais - este percentual foi obtido em função da quantidade de classes que o filtro apontou com potencial de classificação, isto é 24. Com reverência ao número de classificadores previstos (308) e os que foram aprovados na classificação de amostras reais (246), temos um percentual de 80%, que também pode ser considerado um bom resultado para o sistema desenvolvido. Além da grande quantidade de classificadores obtidos (pois a maioria das classes adquiriu mais de um tipo de classificador), este trabalho permite também a análise, através das Tabelas 5.3, 5.4 e 5.5 os tipos de

assinaturas, domínio de frequência e intervalo mais indicados para cada tipo e espécie.

A manipulação do grande volume de informações e operações referentes aos procedimentos experimentais, foi possível graças ao desenvolvimento de um sistema parte em Delphi e parte em MatLab. Referente ao sistema desenvolvido em Delphi, este foi responsável pelo pré-processamento das imagens de folhas e por extrair as assinaturas primárias. A parte do sistema desenvolvida em MatLab contém os módulos responsáveis por: i) gerar as assinaturas secundárias (no domínio da frequência); ii) determinar o potencial de classificação dos tipos de assinaturas e suas variações (filtro Leave-one-out); iii) gerar as amostras artificiais de folhas; iv) criar, treinar e testar automaticamente as redes neurais geradas com base nas assinaturas apontadas pelo método de filtragem utilizando-se das amostras artificiais. Com exceção do item i) os demais são realizados graças ao desenvolvimento de um arcabouço que possibilitou a execução da grande maioria dos procedimentos experimentais de forma automática.

6.1 Contribuições geradas pelo trabalho

O desenvolvimento deste trabalho refletiu nas seguintes contribuições:

- Teste robusto de variabilidade de análise de contorno de folhas.
- Combinação de vários assinaturas de análise de contornos no espectro da frequência e de potência com tipos de normalização e diferentes intervalos do espectro.
- Desenvolvimento de um sistema que avalia as combinações de assinaturas por classe
- Construção de um arcabouço (framework) de redes neurais para a criação, treinamento e teste automático de classificadores.
- Geração de folhas artificiais através da combinação do espectro de Fourier do contorno com operadores de algoritmos genéticos.
- Um método para estimar o potencial de classificação de um conjunto de vetores de características, para uma determinada estrutura de RN.
- Interdependência das redes geradas para a obtenção de classificadores
- Desenvolvimento de um sistema de reconhecimento de padrões que permite a combinação de atributos , utilizando múltiplas RNs.
- Método de geração de classificadores baseados em RNs, para classes com baixo número de amostras.
- Comparação entre os métodos de análise de formas, descritores e intervalos de frequência no espectro.

6.2 Trabalhos Futuros

Como continuidade a este projeto pretende-se:

- Incorporar o sistema desenvolvido ao projeto TreeVis;

-
- Expandir o arcabouço, com a implementação de um módulo para a geração automática de comitês de classificação para classes que obtiveram mais de um classificador;
 - Elaborar de uma heurística para re-seleção de assinaturas para classes que não tiveram nenhum tipo de assinatura indicado pelo método de filtragem *leave-one-out*;
 - Expandir o arcabouço, com a possibilidade de alteração da estrutura de rede adotada aplicando-se algoritmo genético para a reconfiguração dos parâmetros da rede tais como: número de camadas, número de nós por camada e tipos de função de ativação, possibilitando a seleção da melhor arquitetura de rede
 - Estudo de geração de formas 2D (curvas fechadas ou não) de formas mais complexas para a melhoria de algoritmos de busca por similaridade.
 - Adequar as implementações para mais experimentos em biometria.

Potencial de classificação por classe

Passiflora amethystina (Maracujá)		Intervalos de Frequência				
Dominio Frequência		2X30	2X60	2X90	2X120	2X150
FFTCz	cntgb					
NFT	cntgb		20%			
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap				40%	
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang		20%			
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb				20%	
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.1: Potencial de classificação para a classe P. amethystina.

Passiflora caerulea (Maracujá)					
Intervalos de Frequência					
Domínio Frequência		2X30	2X60	2X90	2X120 2X150
FFTCz	cntgb			20%	
NFT	cntgb	80%	80%	60%	40% 40%
PwsCz	cntgb				
PwsNFT	cntgb	40%	40%		40%
FFTCz	cntap		20%		
NFT	cntap	80%	40%	80%	80% 60%
PwsCz	cntap	20%		20%	40%
PwsNFT	cntap	40%	60%	40%	60% 20%
FFTCz	cntba				
NFT	cntba			20%	40% 20%
PwsCz	cntba				
PwsNFT	cntba	20%		20%	20%
FFTCz	aang			20%	40% 20%
NFT	aang	60%	60%	40%	60% 60%
PwsCz	aang	20%	60%		20%
PwsNFT	aang			20%	20%
FFTCz	angv				
NFT	angv				
PwsCz	angv				
PwsNFT	angv		20%		
FFTCz	crvgb				
NFT	crvgb				
PwsCz	crvgb				
PwsNFT	crvgb				
FFTCz	crvap	20%			
NFT	crvap				
PwsCz	crvap				
PwsNFT	crvap				
FFTCz	crvba			20%	
NFT	crvba				
PwsCz	crvba				
PwsNFT	crvba		20%		

Tabela A.2: Potencial de classificação para a classe P. caerulea

Passiflora coriacea (Maracujá)					
Intervalos de Frequência					
Domínio Frequência		2X30	2X60	2X90	2X120 2X150
FFTCz	cntgb				
NFT	cntgb				
PwsCz	cntgb				
PwsNFT	cntgb				
FFTCz	cntap				
NFT	cntap				
PwsCz	cntap			20%	
PwsNFT	cntap		20%		
FFTCz	cntba				
NFT	cntba				
PwsCz	cntba				
PwsNFT	cntba				
FFTCz	aang				
NFT	aang				
PwsCz	aang				
PwsNFT	aang				
FFTCz	angv				
NFT	angv				
PwsCz	angv				
PwsNFT	angv				
FFTCz	crvgb				
NFT	crvgb				
PwsCz	crvgb				
PwsNFT	crvgb				
FFTCz	crvap				
NFT	crvap				
PwsCz	crvap				
PwsNFT	crvap				
FFTCz	crvba				
NFT	crvba				
PwsCz	crvba				
PwsNFT	crvba				

Tabela A.3: Potencial de classificação para a classe P. coriacea

Passiflora foetida (Maracujá)						
		Intervalos de Frequência				
Domínio Frequência		2X30	2X60	2X90	2X120	2X150
FFTCz	cntgb					
NFT	cntgb	20%				
PwsCz	cntgb					
PwsNFT	cntgb	20%				
FFTCz	cntap					
NFT	cntap	40%	40%	40%	60%	20%
PwsCz	cntap					
PwsNFT	cntap	20%			20%	
FFTCz	cntba					
NFT	cntba	80%	60%	60%	60%	80%
PwsCz	cntba					
PwsNFT	cntba	80%	60%	20%	60%	40%
FFTCz	aang					
NFT	aang		20%	20%	40%	20%
PwsCz	aang					
PwsNFT	aang	20%				
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					20%
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.4: Potencial de classificação para a classe P. foetida

Passiflora gibertii (Maracujá)						
		Intervalos de Frequência				
Domínio Frequência		2X30	2X60	2X90	2X120	2X150
FFTCz	cntgb					
NFT	cntgb	60%	20%	20%		20%
PwsCz	cntgb					
PwsNFT	cntgb	60%	20%			
FFTCz	cntap					
NFT	cntap	60%	60%	80%	80%	80%
PwsCz	cntap					
PwsNFT	cntap	60%	40%	40%	80%	80%
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang		20%		40%	20%
PwsCz	aang					
PwsNFT	aang	20%	20%			
FFTCz	angv					
NFT	angv	20%				
PwsCz	angv					
PwsNFT	angv		20%			
FFTCz	crvgb	20%		20%	20%	20%
NFT	crvgb					
PwsCz	crvgb		20%	20%		
PwsNFT	crvgb				20%	
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.5: Potencial de classificação para a classe P. gibertii

Passiflora maliformis (Maracujá)					
		Intervalos de Frequência			
-----		2X30	2X60	2X90	2X120
Domínio	Frequência				2X150
FFTCz	cntgb				
NFT	cntgb				
PwsCz	cntgb				
PwsNFT	cntgb				
FFTCz	cntap				
NFT	cntap				
PwsCz	cntap				
PwsNFT	cntap				
FFTCz	cntba				
NFT	cntba				
PwsCz	cntba				
PwsNFT	cntba				
FFTCz	aang				
NFT	aang				
PwsCz	aang				
PwsNFT	aang				
FFTCz	angv				
NFT	angv				
PwsCz	angv				
PwsNFT	angv				
FFTCz	crvgb				
NFT	crvgb				
PwsCz	crvgb				
PwsNFT	crvgb				
FFTCz	crvap				
NFT	crvap				
PwsCz	crvap				
PwsNFT	crvap				
FFTCz	crvba				
NFT	crvba				
PwsCz	crvba				
PwsNFT	crvba				

Tabela A.6: Potencial de classificação para a classe P. maliformis

Passiflora miersii (Maracujá)					
		Intervalos de Frequência			
-----		2X30	2X60	2X90	2X120
Domínio	Frequência				2X150
FFTCz	cntgb				
NFT	cntgb				
PwsCz	cntgb				
PwsNFT	cntgb				
FFTCz	cntap				
NFT	cntap				
PwsCz	cntap				
PwsNFT	cntap				
FFTCz	cntba				
NFT	cntba				
PwsCz	cntba				
PwsNFT	cntba				
FFTCz	aang				
NFT	aang				
PwsCz	aang				
PwsNFT	aang				
FFTCz	angv				
NFT	angv				
PwsCz	angv				
PwsNFT	angv				
FFTCz	crvgb	20%			20%
NFT	crvgb				
PwsCz	crvgb				
PwsNFT	crvgb				
FFTCz	crvap				
NFT	crvap				
PwsCz	crvap				
PwsNFT	crvap				
FFTCz	crvba				
NFT	crvba				
PwsCz	crvba				
PwsNFT	crvba				

Tabela A.7: Potencial de classificação para a classe P. miersii

Passiflora organensis (Maracujá)					
Intervalos de Frequência					
-----		2X30	2X60	2X90	2X120
Dominio Frequência					2X150
FFTCz	cntgb				
NFT	cntgb				
PwsCz	cntgb				
PwsNFT	cntgb				
FFTCz	cntap				
NFT	cntap				
PwsCz	cntap				
PwsNFT	cntap				
FFTCz	cntba				
NFT	cntba				
PwsCz	cntba				
PwsNFT	cntba				
FFTCz	aang				
NFT	aang				
PwsCz	aang				
PwsNFT	aang				
FFTCz	angv				
NFT	angv				
PwsCz	angv				
PwsNFT	angv				
FFTCz	crvgb			20%	
NFT	crvgb				
PwsCz	crvgb				
PwsNFT	crvgb				
FFTCz	crvap		20%		
NFT	crvap				
PwsCz	crvap				
PwsNFT	crvap				
FFTCz	crvba				
NFT	crvba				
PwsCz	crvba				
PwsNFT	crvba				

Tabela A.8: Potencial de classificação para a classe P. organensis

Passiflora pohlii (Maracujá)					
Intervalos de Frequência					
-----		2X30	2X60	2X90	2X120
Dominio Frequência					2X150
FFTCz	cntgb				
NFT	cntgb				
PwsCz	cntgb				
PwsNFT	cntgb				
FFTCz	cntap				
NFT	cntap	20%			
PwsCz	cntap				
PwsNFT	cntap				
FFTCz	cntba				
NFT	cntba				
PwsCz	cntba				
PwsNFT	cntba				
FFTCz	aang				
NFT	aang				
PwsCz	aang				
PwsNFT	aang				
FFTCz	angv				
NFT	angv				
PwsCz	angv				
PwsNFT	angv				
FFTCz	crvgb				
NFT	crvgb				
PwsCz	crvgb				
PwsNFT	crvgb				
FFTCz	crvap				
NFT	crvap				
PwsCz	crvap				
PwsNFT	crvap				
FFTCz	crvba				
NFT	crvba				
PwsCz	crvba				
PwsNFT	crvba				

Tabela A.9: Potencial de classificação para a classe P. pohlii

Passiflora suberosa (Maracujá)		Intervalos de Frequência				
---		2X30	2X60	2X90	2X120	2X150
Domínio	Frequência					
FFTCz	cntgb					
NFT	cntgb	20%				
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap		20%	20%	20%	20%
PwsCz	cntap					
PwsNFT	cntap			40%	20%	20%
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang	20%		20%		
PwsCz	aang					
PwsNFT	aang		20%		20%	40%
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb	40%				40%
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap				20%	
NFT	crvap		20%			
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.10: Potencial de classificação para a classe P. suberosa

<i>Miroxylon peruiferum</i> (Cabreúva)		Intervalos de Frequência				
Domínio Frequência		2X30	2X60	2X90	2X120	2X150
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba	20%	40%			20%
NFT	crvba	20%	20%	60%	20%	20%
PwsCz	crvba					
PwsNFT	crvba	20%	20%		20%	20%

Tabela A.11: Potencial de classificação para a classe Miroxylon peruiiferum (Cabreúva)

Rauwolfia sellowii (Casca d'anta)		Intervalos de Frequência				
Dominio Frequência		2X30	2X60	2X90	2X120	2X150
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb	20%				
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba				20%	
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.12: Potencial de classificação para a classe Rauwolfia sellowii (Casca d’anta)

Pseudobombax grandiflorum (Imbiruçu)		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Dominio Frequência						
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb				20%	
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.13: Potencial de classificação para a classe Pseudobombax grandiflorum (Imbiruçu)

Tabebuia impetiginosa (Ipê-Roxo)		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Domínio Frequência						
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.14: Potencial de classificação para a classe Tabebuia impetiginosa (Ipê-Roxo)

Syzygium jambolanum (Jambolão)		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Domínio Frequência						
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.15: Potencial de classificação para a classe Syzygium jambolanum (Jambolão)

Hymenea courbaril (Jatobá)		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Dominio	Frequência					
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap	20%	20%	40%	40%	40%
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba		20%			

Tabela A.16: Potencial de classificação para a classe Hymenea courbaril (Jatobá)

Cariniana estrellensis (Jequitibá)		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Dominio	Frequência					
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb	20%				
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap				20%	
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba	20%		20%	20%	
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.17: Potencial de classificação para a classe Cariniana estrellensis (Jequitibá)

Cordia trichotoma (Louro-pardo)					
		Intervalos de Frequência			
Domínio	Frequência	2X30	2X60	2X90	2X120
		2X150			
FFTCz	cntgb				
NFT	cntgb				
PwsCz	cntgb				
PwsNFT	cntgb				
FFTCz	cntap				
NFT	cntap				
PwsCz	cntap				
PwsNFT	cntap				
FFTCz	cntba				
NFT	cntba				
PwsCz	cntba				
PwsNFT	cntba				
FFTCz	aang				
NFT	aang				
PwsCz	aang				
PwsNFT	aang				
FFTCz	angv				
NFT	angv				
PwsCz	angv				
PwsNFT	angv				
FFTCz	crvgb				
NFT	crvgb				
PwsCz	crvgb				
PwsNFT	crvgb				
FFTCz	crvap				
NFT	crvap				
PwsCz	crvap				
PwsNFT	crvap				
FFTCz	crvba				
NFT	crvba				
PwsCz	crvba				
PwsNFT	crvba				

Tabela A.18: Potencial de classificação para a classe Cordia trichotoma (Louro-pardo)

Eriotheca candoleana (Paina da mata)					
		Intervalos de Frequência			
Domínio	Frequência	2X30	2X60	2X90	2X120
		2X150			
FFTCz	cntgb				
NFT	cntgb				
PwsCz	cntgb				
PwsNFT	cntgb				
FFTCz	cntap				
NFT	cntap				
PwsCz	cntap				
PwsNFT	cntap				
FFTCz	cntba				
NFT	cntba	40%	40%		40%
PwsCz	cntba				
PwsNFT	cntba				
FFTCz	aang			20%	20%
NFT	aang	40%	60%	60%	40%
PwsCz	aang				
PwsNFT	aang	20%			20%
FFTCz	angv				
NFT	angv	20%	20%		
PwsCz	angv				
PwsNFT	angv	20%			
FFTCz	crvgb				
NFT	crvgb				
PwsCz	crvgb				
PwsNFT	crvgb				
FFTCz	crvap				
NFT	crvap		20%		20%
PwsCz	crvap	20%			
PwsNFT	crvap				
FFTCz	crvba	40%			
NFT	crvba				
PwsCz	crvba	20%			20%
PwsNFT	crvba				

Tabela A.19: Potencial de classificação para a classe Eriotheca candoleana (Paina da mata)

Caesalpinia echinata (Pau-Brasil)						
		Intervalos de Frequência				
Domínio	Frequência	2X30	2X60	2X90	2X120	2X150
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap				40%	80%
PwsCz	cntap					
PwsNFT	cntap					40%
FFTCz	cntba					
NFT	cntba					40%
PwsCz	cntba					
PwsNFT	cntba					20%
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv	40%	60%	60%	80%	60%
PwsCz	angv					
PwsNFT	angv		60%	60%	80%	80%
FFTCz	crvgb	20%			40%	20%
NFT	crvgb			40%		20%
PwsCz	crvgb	20%				
PwsNFT	crvgb					
FFTCz	crvap	20%	40%	20%	40%	40%
NFT	crvap	60%	60%	60%	60%	20%
PwsCz	crvap					
PwsNFT	crvap	40%	20%	20%	40%	60%
FFTCz	crvba	20%	60%	20%	40%	
NFT	crvba	20%		40%	60%	40%
PwsCz	crvba	20%			20%	
PwsNFT	crvba	40%	40%	20%		20%

Tabela A.20: Potencial de classificação para a classe Caesalpinia echinata (Pau-Brasil)

Platycianus regnelli (Pau-Pereira)		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Domínio	Frequência					
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.21: Potencial de classificação para a classe Platycianus regnelli (Pau-Pereira)

Eugenia Uniflora (Pitanga)		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Domínio	Frequência					
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv		20%	40%	60%	60%
PwsCz	angv					
PwsNFT	angv	20%	40%	60%	60%	40%
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap	40%	20%	40%	40%	40%
PwsCz	crvap		20%			
PwsNFT	crvap				20%	
FFTCz	crvba	20%		20%	20%	40%
NFT	crvba	20%			20%	40%
PwsCz	crvba			20%		
PwsNFT	crvba					

Tabela A.22: Potencial de classificação para a classe Eugenia Uniflora (Pitanga)

Tapirira guianensis (Peito de Pomba)		Intervalos de Frequência				
Domínio Frequência		2X30	2X60	2X90	2X120	2X150
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba		20%		20%	
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.23: Potencial de classificação para a classe Tapirira guianensis (Peito de Pombo)

Coqueiro de jardim		Intervalos de Frequência				
Dominio Frequência		2X30	2X60	2X90	2X120	2X150
FFTCz	cntgb		20%			
NFT	cntgb	60%	40%	20%		40%
PwsCz	cntgb					20%
PwsNFT	cntgb	60%	20%	60%	20%	20%
FFTCz	cntap					20%
NFT	cntap	80%	80%	80%	80%	80%
PwsCz	cntap					
PwsNFT	cntap	80%	80%	80%	80%	80%
FFTCz	cntba		20%	20%	20%	20%
NFT	cntba	80%	80%	80%	80%	80%
PwsCz	cntba					
PwsNFT	cntba	80%	60%	60%	60%	60%
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv	20%				
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb	20%				
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap		20%		20%	
PwsCz	crvap					
PwsNFT	crvap			20%		
FFTCz	crvba	20%	20%		20%	
NFT	crvba	20%	20%		20%	
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.24: Potencial de classificação para a classe Coqueiro de Jardim

Descon01		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Dominio	Frequência					
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.25: Potencial de classificação para a classe Descon01

Descon02		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Domínio Frequência						
FFTCz	cntgb					
NFT	cntgb			20%		
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.26: Potencial de classificação para a classe Descon02

Descon03		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Domínio Frequência						
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba			20%	20%	
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.27: Potencial de classificação para a classe Descon03

Descon04		Intervalos de Frequência				
Dominio Frequência		2X30	2X60	2X90	2X120	2X150
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					20%
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba		20%			

Tabela A.28: Potencial de classificação para a classe Descon04

Descon05		Intervalos de Frequência				
Dominio Frequência		2X30	2X60	2X90	2X120	2X150
FFTCz	cntgb					
NFT	cntgb					
PwsCz	cntgb					
PwsNFT	cntgb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba	20%	40%	20%	40%	20%
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.29: Potencial de classificação para a classe Descon05

Lima		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Dominio Frequência						
FFTCz	cnigb					
NFT	cnigb					
PwsCz	cnigb					
PwsNFT	cnigb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap					
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.30: Potencial de classificação para a classe Lima

Limão		Intervalos de Frequência				
-----		2X30	2X60	2X90	2X120	2X150
Dominio Frequência						
FFTCz	cnigb					
NFT	cnigb					
PwsCz	cnigb					
PwsNFT	cnigb					
FFTCz	cntap					
NFT	cntap					
PwsCz	cntap					
PwsNFT	cntap					
FFTCz	cntba					
NFT	cntba					
PwsCz	cntba					
PwsNFT	cntba					
FFTCz	aang					
NFT	aang					
PwsCz	aang					
PwsNFT	aang					
FFTCz	angv					
NFT	angv					
PwsCz	angv					
PwsNFT	angv					
FFTCz	crvgb					
NFT	crvgb					
PwsCz	crvgb					
PwsNFT	crvgb					
FFTCz	crvap					
NFT	crvap				20%	
PwsCz	crvap					
PwsNFT	crvap					
FFTCz	crvba					
NFT	crvba					
PwsCz	crvba					
PwsNFT	crvba					

Tabela A.31: Potencial de classificação para a classe Limão

Folhas artificialmente geradas

Figura B.1: Amostras geradas artificialmente da classe *Passiflora amethystina* (*amethystina*).

Figura B.2: Amostras geradas artificialmente da classe *Passiflora caerulea* (*caerulea*).

Figura B.3: Amostras geradas artificialmente da classe *Passiflora coriacea* (*coriacea*).

Figura B.4: Amostras geradas artificialmente da classe *Passiflora foetida* (*foetida*).

Figura B.5: Amostras geradas artificialmente da classe *Passiflora gibertii* (*gibertii*).

Figura B.6: Amostras geradas artificialmente da classe *Passiflora maliformis* (*maliformis*).

Figura B.7: Amostras geradas artificialmente da classe *Passiflora micrsii* (*micrsii*).

Figura B.8: Amostras geradas artificialmente da classe *Passiflora organensis* (*organensis*).

Figura B.9: Amostras geradas artificialmente da classe *Passiflora pohlii* (*pohlii*) .

Figura B.10: Amostras geradas artificialmente da classe *Passiflora suberosa* (*suberosa*).

Figura B.11: Amostras geradas artificialmente da classe *Miroxylon periferum* (*cabreúva*).

Figura B.12: Amostras geradas artificialmente da classe *Rauwolfia sellowii* (casca d'anta).

Figura B.13: Amostras geradas artificialmente da classe *Pseudobombax grandiflorum* (im-biruçu).

Figura B.14: Amostras geradas artificialmente da classe *Tabebuia impetiginosa* (ipê-roxo).

Figura B.15: Amostras geradas artificialmente da classe *Syzygium jambolanum* (jambolão).

Figura B.16: Amostras geradas artificialmente da classe *Hymenea courbaril* (jatobá).

Figura B.17: Amostras geradas artificialmente da classe *Cariniana estrellensis* (jequitibá).

Figura B.18: Amostras geradas artificialmente da classe *Cordia trichotoma* (louro-pardo).

Figura B.19: Amostras geradas artificialmente da classe *Eriotheca candoleana* (paina da mala).

Figura B.20: Amostras geradas artificialmente da classe *Caesalpinia echinata* (pau-Brasil).

Figura B.21: Amostras geradas artificialmente da classe *Platycianus regnelli* (pau-pereira).

Figura B.22: Amostras geradas artificialmente da classe *Eugenia Uniflora* (pitanga).

Figura B.23: Amostras geradas artificialmente da classe *Tapirira guianensis* (peito de pomba).

Figura B.24: Amostras geradas artificialmente da classe *coqueiro de jardim*.

Figura B.25: Amostras geradas artificialmente da classe *desconhecida 01 (descon01)*.

Figura B.26: Amostras geradas artificialmente da classe *desconhecida 02* (*descon02*).

Figura B.27: Amostras geradas artificialmente da classe *desconhecida 03* (*descon03*).

Figura B.28: Amostras geradas artificialmente da classe *desconhecida 04* (*descon04*).

Figura B.29: Amostras geradas artificialmente da classe *desconhecida 05* (*descon05*).

Figura B.30: Amostras geradas artificialmente da classe *lima*. Figura B.31: Amostras geradas artificialmente da classe *limao*.

APÊNDICE

C

Resultados da classificação de amostras artificiais por redes geradas com amostras artificiais

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeralAcertos
amethystina	aang	NFT	60	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	FFTCz	90	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	FFTCz	120	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	FFTCz	150	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	NFT	30	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	NFT	60	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	NFT	120	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	NFT	150	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	PwsCz	30	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	PwsCz	60	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	PwsCz	150	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	PwsNFT	90	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	aang	PwsNFT	120	50	0	1500	0	100,00%	100,00%	100,00%
foetida	aang	NFT	60	50	0	1500	0	100,00%	100,00%	100,00%
foetida	aang	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
foetida	aang	NFT	120	50	0	1500	0	100,00%	100,00%	100,00%
foetida	aang	NFT	150	50	0	1500	0	100,00%	100,00%	100,00%
foetida	aang	PwsNFT	30	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	aang	NFT	60	50	0	1472	28	100,00%	98,13%	98,19%
gibertii	aang	NFT	120	50	0	1472	28	100,00%	98,13%	98,19%
gibertii	aang	NFT	150	50	0	1472	28	100,00%	98,13%	98,19%
gibertii	aang	PwsNFT	30	50	0	1473	27	100,00%	98,20%	98,26%
gibertii	aang	PwsNFT	60	50	0	1498	2	100,00%	99,87%	99,87%
suberosa	aang	NFT	30	50	0	1500	0	100,00%	100,00%	100,00%
suberosa	aang	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
suberosa	aang	PwsNFT	60	49	1	1500	0	98,00%	100,00%	99,94%
suberosa	aang	PwsNFT	120	50	0	1500	0	100,00%	100,00%	100,00%
suberosa	aang	PwsNFT	150	50	0	1500	0	100,00%	100,00%	100,00%
paua da mata	aang	NFT	30	44	6	1497	3	88,00%	99,80%	99,42%
paua da mata	aang	NFT	60	43	7	1494	6	86,00%	99,60%	99,16%
paua da mata	aang	NFT	90	43	7	1495	5	86,00%	99,67%	99,23%

Tabela C.1: Resultados da classificação do conjunto de amostras artificiais através da assinatura de contorno angular (aang), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeraAcertos
gibertii	angv	NFT	30	43	7	1495	5	86,00%	99,67%	99,23%
gibertii	angv	PwsNFT	60	44	6	1473	27	88,00%	98,20%	97,87%
pau-brasil	angv	NFT	30	50	0	1499	1	100,00%	99,93%	99,94%
pau-brasil	angv	NFT	60	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	angv	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	angv	NFT	120	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	angv	NFT	150	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	angv	PwsNFT	60	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	angv	PwsNFT	90	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	angv	PwsNFT	120	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	angv	PwsNFT	150	50	0	1500	0	100,00%	100,00%	100,00%
pitanga	angv	NFT	60	16	4	1497	3	92,00%	99,80%	99,55%
pitanga	angv	NFT	90	19	1	1498	2	98,00%	99,87%	99,81%
pitanga	angv	NFT	120	18	2	1495	5	96,00%	99,67%	99,53%
pitanga	angv	NFT	150	19	1	1495	5	98,00%	99,67%	99,61%
pitanga	angv	PwsNFT	30	19	1	1500	0	98,00%	100,00%	99,94%
pitanga	angv	PwsNFT	60	18	2	1496	4	96,00%	99,73%	99,61%
pitanga	angv	PwsNFT	90	50	0	1493	7	100,00%	99,53%	99,55%
pitanga	angv	PwsNFT	120	43	7	1498	2	86,00%	99,87%	99,42%
pitanga	angv	PwsNFT	150	43	7	1500	0	86,00%	100,00%	99,55%

Tabela C.2: Resultados da classificação do conjunto de amostras artificiais através da assinatura de ângulo de visão (angv), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeraAcertos
amethystina	entgb	NFT	60	19	1	1493	7	98,00%	99,53%	99,48%
caerulea	entgb	PFTCz	90	18	2	1500	0	96,00%	100,00%	99,87%
caerulea	entgb	NFT	30	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	entgb	NFT	60	18	2	1500	0	96,00%	100,00%	99,87%
caerulea	entgb	NFT	90	18	2	1500	0	96,00%	100,00%	99,87%
caerulea	entgb	NFT	120	18	2	1500	0	96,00%	100,00%	99,87%
caerulea	entgb	NFT	150	15	5	1500	0	90,00%	100,00%	99,68%
caerulea	entgb	PwsNFT	30	16	4	1500	0	92,00%	100,00%	99,74%
caerulea	entgb	PwsNFT	60	16	4	1500	0	92,00%	100,00%	99,74%
caerulea	entgb	PwsNFT	150	13	7	1500	0	86,00%	100,00%	99,55%
foetida	entgb	NFT	30	17	3	1500	0	94,00%	100,00%	99,81%
foetida	entgb	PwsNFT	30	15	5	1500	0	90,00%	100,00%	99,68%
gibertii	entgb	NFT	30	50	0	1458	42	100,00%	97,20%	97,29%
gibertii	entgb	NFT	60	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	entgb	NFT	90	19	1	1492	8	98,00%	99,47%	99,42%
gibertii	entgb	NFT	150	19	1	1486	14	98,00%	99,07%	99,03%
gibertii	entgb	PwsNFT	30	50	0	1482	18	100,00%	98,80%	98,84%
gibertii	entgb	PwsNFT	60	50	0	1475	25	100,00%	98,33%	98,49%
sulcerosa	entgb	NFT	30	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entgb	PFTCz	60	19	1	1500	0	98,00%	100,00%	99,94%
coqueiro de jardim	entgb	NFT	30	17	3	1500	0	94,00%	100,00%	99,81%
coqueiro de jardim	entgb	NFT	60	19	1	1500	0	98,00%	100,00%	99,94%
coqueiro de jardim	entgb	NFT	90	19	1	1500	0	98,00%	100,00%	99,94%
coqueiro de jardim	entgb	NFT	150	14	6	1499	1	88,00%	99,93%	99,55%
coqueiro de jardim	entgb	PwsNFT	30	18	2	1499	1	96,00%	99,93%	99,81%
coqueiro de jardim	entgb	PwsNFT	60	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entgb	PwsNFT	90	19	1	1500	0	98,00%	100,00%	99,94%
coqueiro de jardim	entgb	PwsNFT	120	19	1	1500	0	98,00%	100,00%	99,94%
coqueiro de jardim	entgb	PwsNFT	150	19	1	1497	3	98,00%	99,80%	99,74%

Tabela C.3: Resultados da classificação do conjunto de amostras artificiais através da assinatura de contorno global (entgb), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	PACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeraAcertos
amethystina	entap	PwsNFT	120	48	2	1487	13	96,00%	99,13%	99,63%
caerulea	entap	PFTCz	60	48	2	1500	0	96,00%	100,00%	99,87%
caerulea	entap	NFT	30	48	2	1500	0	96,00%	100,00%	99,87%
caerulea	entap	NFT	60	45	5	1500	0	90,00%	100,00%	99,68%
caerulea	entap	NFT	90	48	2	1500	0	96,00%	100,00%	99,87%
caerulea	entap	NFT	120	46	4	1500	0	92,00%	100,00%	99,74%
caerulea	entap	NFT	150	48	2	1500	0	96,00%	100,00%	99,87%
caerulea	entap	PwsCz	30	48	2	1500	0	96,00%	100,00%	99,87%
caerulea	entap	PwsCz	90	48	2	1500	0	96,00%	100,00%	99,87%
caerulea	entap	PwsCz	150	48	2	1500	0	96,00%	100,00%	99,87%
caerulea	entap	PwsNFT	30	47	3	1500	0	94,00%	100,00%	99,81%
caerulea	entap	PwsNFT	60	46	1	1500	0	92,00%	100,00%	99,74%
caerulea	entap	PwsNFT	90	43	7	1500	0	86,00%	100,00%	99,55%
caerulea	entap	PwsNFT	120	48	2	1500	0	96,00%	100,00%	99,87%
caerulea	entap	PwsNFT	150	48	2	1500	0	96,00%	100,00%	99,87%
coriacea	entap	PwsCz	90	43	7	1500	0	86,00%	100,00%	99,55%
coriacea	entap	PwsNFT	60	43	7	1500	0	86,00%	100,00%	99,55%
foetida	entap	NFT	30	48	2	1500	0	96,00%	100,00%	99,87%
foetida	entap	NFT	60	49	1	1500	0	98,00%	100,00%	99,94%
foetida	entap	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
foetida	entap	NFT	120	50	0	1500	0	100,00%	100,00%	100,00%
foetida	entap	NFT	150	48	2	1500	0	96,00%	100,00%	99,87%
foetida	entap	PwsNFT	30	45	5	1500	0	90,00%	100,00%	99,68%
foetida	entap	PwsNFT	120	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	entap	NFT	30	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	entap	NFT	60	49	1	1500	0	98,00%	100,00%	99,94%
gibertii	entap	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	entap	NFT	120	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	entap	NFT	150	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	entap	PwsNFT	30	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	entap	PwsNFT	60	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	entap	PwsNFT	90	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	entap	PwsNFT	120	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	entap	PwsNFT	150	50	0	1500	0	100,00%	100,00%	100,00%
pohlII	entap	NFT	30	44	6	1498	2	88,00%	99,87%	99,48%
suberosa	entap	NFT	60	50	0	1495	5	100,00%	99,67%	99,68%
suberosa	entap	NFT	90	47	3	1500	0	94,00%	100,00%	99,81%
suberosa	entap	NFT	120	50	0	1492	8	100,00%	99,47%	99,48%
suberosa	entap	NFT	150	45	5	1496	4	90,00%	99,73%	99,42%
suberosa	entap	PwsNFT	90	49	1	1479	21	98,00%	98,60%	98,58%
suberosa	entap	PwsNFT	120	44	6	1493	7	88,00%	99,53%	99,16%
suberosa	entap	PwsNFT	150	49	1	1488	12	98,00%	99,20%	99,16%
coqueiro de jardim	entap	PFTCz	150	48	2	1487	13	96,00%	99,13%	99,63%
coqueiro de jardim	entap	NFT	30	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	NFT	60	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	NFT	90	49	1	1500	0	98,00%	100,00%	99,94%
coqueiro de jardim	entap	NFT	120	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	NFT	150	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	PwsNFT	30	48	2	1500	0	96,00%	100,00%	99,87%
coqueiro de jardim	entap	PwsNFT	60	48	2	1500	0	96,00%	100,00%	99,87%
coqueiro de jardim	entap	PwsNFT	90	48	2	1500	0	96,00%	100,00%	99,87%
coqueiro de jardim	entap	PwsNFT	120	48	2	1500	0	96,00%	100,00%	99,87%
coqueiro de jardim	entap	PwsNFT	150	48	2	1500	0	96,00%	100,00%	99,87%
pau-brasil	entap	NFT	120	43	7	1500	0	86,00%	100,00%	99,55%
pau-brasil	entap	NFT	150	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	entap	PwsNFT	150	43	7	1500	0	86,00%	100,00%	99,55%

Tabela C.4: Resultados da classificação do conjunto de amostras artificiais através da assinatura de contorno apical (entap), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CATC	CDCC	CDIC	%CACC	%CDCC	%GeralAcertos
caerulea	entba	NFT	90	48	2	1500	0	96,00%	100,00%	99,87%
caerulea	entba	NFT	120	48	2	1500	0	96,00%	100,00%	99,87%
caerulea	entba	NFT	150	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	entba	PwsNFT	30	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	entba	PwsNFT	90	50	0	1500	0	100,00%	100,00%	100,00%
caerulea	entba	PwsNFT	150	43	7	1500	0	86,00%	100,00%	99,55%
foetida	entba	NFT	30	50	0	1500	0	100,00%	100,00%	100,00%
foetida	entba	NFT	60	50	0	1500	0	100,00%	100,00%	100,00%
foetida	entba	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
foetida	entba	NFT	120	50	0	1500	0	100,00%	100,00%	100,00%
foetida	entba	NFT	150	50	0	1500	0	100,00%	100,00%	100,00%
foetida	entba	PwsNFT	30	50	0	1500	0	100,00%	100,00%	100,00%
foetida	entba	PwsNFT	60	50	0	1500	0	100,00%	100,00%	100,00%
foetida	entba	PwsNFT	90	50	0	1500	0	100,00%	100,00%	100,00%
foetida	entba	PwsNFT	120	50	0	1500	0	100,00%	100,00%	100,00%
foetida	entba	PwsNFT	150	50	0	1487	13	100,00%	99,13%	99,16%
coqueiro de jardim	entba	FFTCz	60	45	5	1500	0	90,00%	100,00%	99,68%
coqueiro de jardim	entba	FFTCz	90	18	2	1500	0	96,00%	100,00%	99,87%
coqueiro de jardim	entba	FFTCz	120	50	0	1499	1	100,00%	99,93%	99,94%
coqueiro de jardim	entba	FFTCz	150	48	2	1500	0	96,00%	100,00%	99,87%
coqueiro de jardim	entba	NFT	30	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	NFT	60	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	NFT	120	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	NFT	150	49	1	1500	0	98,00%	100,00%	99,94%
coqueiro de jardim	entba	PwsNFT	30	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	PwsNFT	60	50	0	1500	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	PwsNFT	90	49	1	1500	0	98,00%	100,00%	99,94%
coqueiro de jardim	entba	PwsNFT	120	49	1	1500	0	98,00%	100,00%	99,94%
coqueiro de jardim	entba	PwsNFT	150	49	1	1500	0	98,00%	100,00%	99,94%
pau da mata	entba	NFT	30	50	0	1497	3	100,00%	99,80%	99,81%
pau da mata	entba	NFT	60	49	1	1497	3	98,00%	99,80%	99,74%
pau da mata	entba	NFT	150	49	1	1496	4	98,00%	99,73%	99,68%
pau-brasil	entba	NFT	150	48	2	1500	0	96,00%	100,00%	99,87%
pau-brasil	entba	PwsNFT	150	48	2	1500	0	96,00%	100,00%	99,87%

Tabela C.5: Resultados da classificação do conjunto de amostras artificiais através da assinatura de contorno basal (entba), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CATC	CDCC	CDIC	%CACC	%CDCC	%GeralAcertos
amethystina	crvgb	FFTCz	120	47	3	1500	0	94,00%	100,00%	99,81%
foetida	crvgb	FFTCz	150	15	5	1488	12	90,00%	99,20%	98,90%
gibertii	crvgb	FFTCz	30	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	crvgb	FFTCz	90	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	crvgb	FFTCz	120	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	crvgb	FFTCz	150	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	crvgb	PwsCz	60	50	0	1500	0	100,00%	100,00%	100,00%
gibertii	crvgb	PwsCz	90	50	0	1485	15	100,00%	99,00%	99,03%
gibertii	crvgb	PwsNFT	120	50	0	1500	0	100,00%	100,00%	100,00%
miersii	crvgb	FFTCz	30	43	7	1496	4	86,00%	99,73%	99,29%
miersii	crvgb	FFTCz	120	48	2	1490	10	96,00%	99,33%	99,23%
orgatensis	crvgb	FFTCz	90	50	0	1499	1	100,00%	99,93%	99,94%
suberosa	crvgb	FFTCz	30	50	0	1500	0	100,00%	100,00%	100,00%
suberosa	crvgb	FFTCz	150	50	0	1500	0	100,00%	100,00%	100,00%
casca d'anta	crvgb	FFTCz	30	46	4	1488	12	92,00%	99,20%	98,97%
coqueiro de jardim	crvgb	PwsCz	30	44	6	1498	2	88,00%	99,87%	99,48%
imbricua	crvgb	FFTCz	120	14	6	1498	2	88,00%	99,87%	99,48%
jequitiba	crvgb	FFTCz	30	45	5	1493	7	90,00%	99,53%	99,23%
pau-brasil	crvgb	FFTCz	30	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvgb	FFTCz	120	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvgb	FFTCz	150	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvgb	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvgb	NFT	150	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvgb	PwsCz	30	50	0	1499	1	100,00%	99,93%	99,94%

Tabela C.6: Resultados da classificação do conjunto de amostras artificiais através da assinatura de curvatura global (crvgb), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assimilada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeraAcertos
organensis	crvap	FETCz	60	50	0	1500	0	100,00%	100,00%	100,00%
suberosa	crvap	FETCz	120	44	6	1486	14	88,00%	99,07%	98,71%
suberosa	crvap	NFT	60	46	4	1463	37	92,00%	97,53%	97,35%
coqueiro de jardim	crvap	NFT	60	43	7	1498	2	86,00%	99,87%	99,42%
coqueiro de jardim	crvap	NFT	120	45	5	1500	0	90,00%	100,00%	99,68%
coqueiro de jardim	crvap	PwsNFT	90	46	4	1496	4	92,00%	99,73%	99,48%
palma da mata	crvap	NFT	60	46	1	1499	1	92,00%	99,93%	99,68%
palma da mata	crvap	NFT	120	48	2	1499	1	96,00%	99,93%	99,81%
palma da mata	crvap	PwsCz	30	48	2	1499	1	96,00%	99,93%	99,81%
pau-brasil	crvap	FETCz	30	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	FETCz	60	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	FETCz	90	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	FETCz	120	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	FETCz	150	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	NFT	30	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	NFT	60	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	NFT	120	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	NFT	150	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	PwsNFT	30	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	PwsNFT	60	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	PwsNFT	90	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	PwsNFT	120	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvap	PwsNFT	150	50	0	1500	0	100,00%	100,00%	100,00%
pitanga	crvap	NFT	30	50	0	1495	5	100,00%	99,67%	99,68%
pitanga	crvap	NFT	60	50	0	1500	0	100,00%	100,00%	100,00%
pitanga	crvap	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
pitanga	crvap	NFT	120	50	0	1491	9	100,00%	99,40%	99,42%
pitanga	crvap	NFT	150	50	0	1498	2	100,00%	99,87%	99,87%
pitanga	crvap	PwsCz	60	50	0	1500	0	100,00%	100,00%	100,00%
pitanga	crvap	PwsNFT	120	50	0	1496	4	100,00%	99,73%	99,71%

Tabela C.7: Resultados da classificação do conjunto de amostras artificiais através da assinatura de curvatura apical (crvap), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assimilada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeraAcertos
caerulea	crvba	FFTCz	120	43	7	1500	0	86,00%	100,00%	99,55%
caerulea	crvba	PwsNFT	60	45	5	1500	0	90,00%	100,00%	99,68%
cabreuva	crvba	FFTCz	30	50	0	1500	0	100,00%	100,00%	100,00%
cabreuva	crvba	FFTCz	60	50	0	1500	0	100,00%	100,00%	100,00%
cabreuva	crvba	FFTCz	150	49	1	1500	0	98,00%	100,00%	99,94%
cabreuva	crvba	NFT	30	45	5	1500	0	90,00%	100,00%	99,68%
cabreuva	crvba	NFT	60	45	5	1500	0	90,00%	100,00%	99,68%
cabreuva	crvba	NFT	90	45	5	1500	0	90,00%	100,00%	99,68%
cabreuva	crvba	NFT	120	45	5	1500	0	90,00%	100,00%	99,68%
cabreuva	crvba	NFT	150	46	4	1500	0	92,00%	100,00%	99,74%
cabreuva	crvba	PwsNFT	30	45	5	1500	0	90,00%	100,00%	99,68%
cabreuva	crvba	PwsNFT	60	49	1	1500	0	98,00%	100,00%	99,94%
cabreuva	crvba	PwsNFT	120	44	6	1500	0	88,00%	100,00%	99,61%
cabreuva	crvba	PwsNFT	150	45	5	1499	1	90,00%	99,93%	99,61%
coqueiro de jardim	crvba	FFTCz	30	45	5	1500	0	90,00%	100,00%	99,68%
coqueiro de jardim	crvba	FFTCz	60	45	5	1500	0	90,00%	100,00%	99,68%
coqueiro de jardim	crvba	FFTCz	120	43	7	1500	0	86,00%	100,00%	99,55%
coqueiro de jardim	crvba	NFT	30	49	1	1491	9	98,00%	99,40%	99,35%
coqueiro de jardim	crvba	NFT	60	43	7	1500	0	86,00%	100,00%	99,55%
coqueiro de jardim	crvba	NFT	120	43	7	1500	0	86,00%	100,00%	99,55%
descont04	crvba	NFT	150	44	6	1486	14	88,00%	99,07%	98,71%
descont04	crvba	PwsNFT	60	48	2	1486	14	96,00%	99,07%	98,97%
descont05	crvba	NFT	150	46	4	1476	24	92,00%	98,40%	98,19%
jaboba	crvba	PwsNFT	60	49	1	1487	13	98,00%	99,13%	99,10%
jequitiba	crvba	FFTCz	30	48	2	1500	0	96,00%	100,00%	99,87%
jequitiba	crvba	FFTCz	90	48	2	1499	1	96,00%	99,93%	99,81%
jequitiba	crvba	FFTCz	120	48	2	1489	11	96,00%	99,27%	99,16%
paina da mata	crvba	FFTCz	30	45	5	1496	4	90,00%	99,73%	99,42%
pau-brasil	crvba	FFTCz	30	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	FFTCz	60	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	FFTCz	90	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	FFTCz	120	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	NFT	30	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	NFT	90	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	NFT	120	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	NFT	150	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsCz	30	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsCz	120	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsNFT	30	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsNFT	60	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsNFT	90	50	0	1500	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsNFT	150	50	0	1500	0	100,00%	100,00%	100,00%
pitanga	crvba	FFTCz	30	50	0	1485	15	100,00%	99,00%	99,03%
pitanga	crvba	FFTCz	90	50	0	1486	14	100,00%	99,07%	99,10%
pitanga	crvba	FFTCz	120	50	0	1486	14	100,00%	99,07%	99,10%
pitanga	crvba	FFTCz	150	50	0	1487	13	100,00%	99,13%	99,16%
pitanga	crvba	NFT	30	50	0	1484	16	100,00%	98,93%	98,97%
pitanga	crvba	NFT	120	50	0	1484	16	100,00%	98,93%	98,97%
pitanga	crvba	NFT	150	50	0	1487	13	100,00%	99,13%	99,16%
pitanga	crvba	PwsCz	90	50	0	1487	13	100,00%	99,13%	99,16%

Tabela C.8: Resultados da classificação do conjunto de amostras artificiais através da assinatura de curvatura basal (crvba), considerando-se as variações do intervalo de frequência e do domínio da frequência.

APÊNDICE

D

Resultados da classificação de amostras reais por redes geradas com amostras artificiais

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeralAcertos
anethystina	aang	NFT	60	3	2	303	0	60,00%	100,00%	99,35%
caerulea	aang	FFTCz	90	5	0	303	0	100,00%	100,00%	100,00%
caerulea	aang	FFTCz	120	5	0	303	0	100,00%	100,00%	100,00%
caerulea	aang	FFTCz	150	5	0	303	0	100,00%	100,00%	100,00%
caerulea	aang	NFT	30	5	0	303	0	100,00%	100,00%	100,00%
caerulea	aang	NFT	60	5	0	303	0	100,00%	100,00%	100,00%
caerulea	aang	NFT	90	5	0	303	0	100,00%	100,00%	100,00%
caerulea	aang	NFT	120	5	0	303	0	100,00%	100,00%	100,00%
caerulea	aang	NFT	150	5	0	303	0	100,00%	100,00%	100,00%
caerulea	aang	PwsCz	30	5	0	303	0	100,00%	100,00%	100,00%
caerulea	aang	PwsCz	60	5	0	303	0	100,00%	100,00%	100,00%
caerulea	aang	PwsCz	150	5	0	302	1	100,00%	99,67%	99,68%
caerulea	aang	PwsNFT	90	5	0	303	0	100,00%	100,00%	100,00%
caerulea	aang	PwsNFT	120	5	0	303	0	100,00%	100,00%	100,00%
foetida	aang	NFT	60	6	0	301	1	100,00%	99,67%	99,68%
foetida	aang	NFT	90	6	0	301	1	100,00%	99,67%	99,68%
foetida	aang	NFT	120	6	0	301	1	100,00%	99,67%	99,68%
foetida	aang	NFT	150	6	0	301	1	100,00%	99,67%	99,68%
foetida	aang	PwsNFT	30	6	0	301	1	100,00%	99,67%	99,68%
gibertii	aang	NFT	60	5	2	300	1	71,43%	99,67%	99,03%
gibertii	aang	NFT	120	5	2	299	2	71,43%	99,34%	98,70%
gibertii	aang	NFT	150	5	2	300	1	71,43%	99,67%	99,03%
gibertii	aang	PwsNFT	30	5	2	299	2	71,43%	99,34%	98,70%
gibertii	aang	PwsNFT	60	5	2	300	1	71,43%	99,67%	99,03%
suberosa	aang	NFT	30	6	1	301	0	85,71%	100,00%	99,68%
suberosa	aang	NFT	90	6	1	301	0	85,71%	100,00%	99,68%
suberosa	aang	PwsNFT	60	6	1	301	0	85,71%	100,00%	99,68%
suberosa	aang	PwsNFT	120	6	1	301	0	85,71%	100,00%	99,68%
suberosa	aang	PwsNFT	150	6	1	301	0	85,71%	100,00%	99,68%
palma da mata	aang	NFT	30	10	0	298	0	100,00%	100,00%	100,00%
palma da mata	aang	NFT	60	10	0	298	0	100,00%	100,00%	100,00%
palma da mata	aang	NFT	90	10	0	298	0	100,00%	100,00%	100,00%

Tabela D.1: Resultados da classificação do conjunto de amostras reais através da assinatura de contorno angular (aang), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeraAcertos
gibertii	angv	NFT	30	5	2	299	2	71.43%	99.31%	98.70%
gibertii	angv	PwsNFT	60	4	3	297	4	57.14%	98.67%	97.73%
pau-brasil	angv	NFT	30	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	angv	NFT	60	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	angv	NFT	90	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	angv	NFT	120	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	angv	NFT	150	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	angv	PwsNFT	60	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	angv	PwsNFT	90	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	angv	PwsNFT	120	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	angv	PwsNFT	150	25	0	283	0	100.00%	100.00%	100.00%
pitanga	angv	NFT	60	12	1	295	0	92.31%	100.00%	99.68%
pitanga	angv	NFT	90	13	0	295	0	100.00%	100.00%	100.00%
pitanga	angv	NFT	120	13	0	295	0	100.00%	100.00%	100.00%
pitanga	angv	NFT	150	13	0	295	0	100.00%	100.00%	100.00%
pitanga	angv	PwsNFT	30	13	0	295	0	100.00%	100.00%	100.00%
pitanga	angv	PwsNFT	60	13	0	295	0	100.00%	100.00%	100.00%
pitanga	angv	PwsNFT	90	13	0	295	0	100.00%	100.00%	100.00%
pitanga	angv	PwsNFT	120	13	0	295	0	100.00%	100.00%	100.00%
pitanga	angv	PwsNFT	150	13	0	295	0	100.00%	100.00%	100.00%

Tabela D.2: Resultados da classificação do conjunto de amostras reais através da assinatura de ângulo de visão (angv), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeraAcertos
amethystina	entgb	NFT	60	3	2	303	0	60.00%	100.00%	99.35%
caerulea	entgb	FFTCz	90	5	0	301	2	100.00%	99.34%	99.35%
caerulea	entgb	NFT	30	4	1	301	2	80.00%	99.34%	99.03%
caerulea	entgb	NFT	60	4	1	301	2	80.00%	99.34%	99.03%
caerulea	entgb	NFT	90	5	0	301	2	100.00%	99.34%	99.35%
caerulea	entgb	NFT	120	5	0	301	2	100.00%	99.34%	99.35%
caerulea	entgb	NFT	150	5	0	301	2	100.00%	99.34%	99.35%
caerulea	entgb	PwsNFT	30	4	1	301	2	80.00%	99.34%	99.03%
caerulea	entgb	PwsNFT	60	5	0	301	2	100.00%	99.34%	99.35%
caerulea	entgb	PwsNFT	150	5	0	301	2	100.00%	99.34%	99.35%
foetida	entgb	NFT	30	6	0	301	1	100.00%	99.67%	99.68%
foetida	entgb	PwsNFT	30	5	1	302	0	83.33%	100.00%	99.68%
gibertii	entgb	NFT	30	7	0	300	1	100.00%	99.67%	99.68%
gibertii	entgb	NFT	60	4	3	301	0	57.14%	100.00%	99.03%
gibertii	entgb	NFT	90	6	1	300	1	85.71%	99.67%	99.35%
gibertii	entgb	NFT	150	6	1	300	1	85.71%	99.67%	99.35%
gibertii	entgb	PwsNFT	30	7	0	300	1	100.00%	99.67%	99.68%
gibertii	entgb	PwsNFT	60	7	0	298	3	100.00%	99.00%	99.03%
saberosa	entgb	NFT	30	6	1	301	0	85.71%	100.00%	99.68%
coqueiro de jardim	entgb	FFTCz	60	20	0	288	0	100.00%	100.00%	100.00%
coqueiro de jardim	entgb	NFT	30	20	0	288	0	100.00%	100.00%	100.00%
coqueiro de jardim	entgb	NFT	60	20	0	288	0	100.00%	100.00%	100.00%
coqueiro de jardim	entgb	NFT	90	20	0	287	1	100.00%	99.65%	99.68%
coqueiro de jardim	entgb	NFT	150	18	2	288	0	90.00%	100.00%	99.35%
coqueiro de jardim	entgb	PwsNFT	30	20	0	288	0	100.00%	100.00%	100.00%
coqueiro de jardim	entgb	PwsNFT	60	20	0	287	1	100.00%	99.65%	99.68%
coqueiro de jardim	entgb	PwsNFT	90	20	0	288	0	100.00%	100.00%	100.00%
coqueiro de jardim	entgb	PwsNFT	120	20	0	288	0	100.00%	100.00%	100.00%
coqueiro de jardim	entgb	PwsNFT	150	20	0	288	0	100.00%	100.00%	100.00%

Tabela D.3: Resultados da classificação do conjunto de amostras reais através da assinatura de contorno global (entgb), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeraAcertos
ametivstina	entap	PwsNFT	120	4	1	302	1	80,00%	99,67%	99,35%
caerulea	entap	FFTCz	60	5	0	301	2	100,00%	99,34%	99,35%
caerulea	entap	NFT	30	5	0	302	1	100,00%	99,67%	99,68%
caerulea	entap	NFT	60	5	0	303	0	100,00%	100,00%	100,00%
caerulea	entap	NFT	90	5	0	302	1	100,00%	99,67%	99,68%
caerulea	entap	NFT	120	5	0	302	1	100,00%	99,67%	99,68%
caerulea	entap	NFT	150	4	1	302	1	80,00%	99,67%	99,35%
caerulea	entap	PwsCz	30	5	0	302	1	100,00%	99,67%	99,68%
caerulea	entap	PwsCz	90	5	0	301	2	100,00%	99,34%	99,35%
caerulea	entap	PwsCz	150	5	0	301	2	100,00%	99,34%	99,35%
caerulea	entap	PwsNFT	30	1	1	303	0	80,00%	100,00%	99,68%
caerulea	entap	PwsNFT	60	4	1	301	2	80,00%	99,34%	99,03%
caerulea	entap	PwsNFT	90	5	0	302	1	100,00%	99,67%	99,68%
caerulea	entap	PwsNFT	120	5	0	302	1	100,00%	99,67%	99,68%
caerulea	entap	PwsNFT	150	5	0	302	1	100,00%	99,67%	99,68%
coriacea	entap	PwsCz	90	6	2	300	0	75,00%	100,00%	99,35%
coriacea	entap	PwsNFT	60	5	3	300	0	62,50%	100,00%	99,03%
foetida	entap	NFT	30	5	1	302	0	83,33%	100,00%	99,68%
foetida	entap	NFT	60	5	1	302	0	83,33%	100,00%	99,68%
foetida	entap	NFT	90	5	1	302	0	83,33%	100,00%	99,68%
foetida	entap	NFT	120	5	1	302	0	83,33%	100,00%	99,68%
foetida	entap	NFT	150	5	1	302	0	83,33%	100,00%	99,68%
foetida	entap	PwsNFT	30	5	1	302	0	83,33%	100,00%	99,68%
foetida	entap	PwsNFT	120	5	1	302	0	83,33%	100,00%	99,68%
gibertii	entap	NFT	30	7	0	301	0	100,00%	100,00%	100,00%
gibertii	entap	NFT	60	7	0	301	0	100,00%	100,00%	100,00%
gibertii	entap	NFT	90	7	0	301	0	100,00%	100,00%	100,00%
gibertii	entap	NFT	120	7	0	301	0	100,00%	100,00%	100,00%
gibertii	entap	NFT	150	7	0	301	0	100,00%	100,00%	100,00%
gibertii	entap	PwsNFT	30	7	0	301	0	100,00%	100,00%	100,00%
gibertii	entap	PwsNFT	60	7	0	301	0	100,00%	100,00%	100,00%
gibertii	entap	PwsNFT	90	7	0	301	0	100,00%	100,00%	100,00%
gibertii	entap	PwsNFT	120	7	0	301	0	100,00%	100,00%	100,00%
gibertii	entap	PwsNFT	150	7	0	301	0	100,00%	100,00%	100,00%
polidii	entap	NFT	30	8	0	300	0	100,00%	100,00%	100,00%
suberosa	entap	NFT	60	7	0	301	0	100,00%	100,00%	100,00%
suberosa	entap	NFT	90	7	0	301	0	100,00%	100,00%	100,00%
suberosa	entap	NFT	120	7	0	301	0	100,00%	100,00%	100,00%
suberosa	entap	NFT	150	6	1	301	0	85,71%	100,00%	99,68%
suberosa	entap	PwsNFT	90	7	0	300	1	100,00%	99,67%	99,68%
suberosa	entap	PwsNFT	120	6	1	300	1	85,71%	99,67%	99,35%
suberosa	entap	PwsNFT	150	7	0	300	1	100,00%	99,67%	99,68%
coqueiro de jardim	entap	FFTCz	150	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	NFT	30	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	NFT	60	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	NFT	90	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	NFT	120	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	NFT	150	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	PwsNFT	30	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	PwsNFT	60	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	PwsNFT	90	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	PwsNFT	120	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entap	PwsNFT	150	20	0	288	0	100,00%	100,00%	100,00%
pau-brasil	entap	NFT	120	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	entap	NFT	150	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	entap	PwsNFT	150	25	0	283	0	100,00%	100,00%	100,00%

Tabela D.4: Resultados da classificação do conjunto de amostras reais através da assinatura de contorno apical (entap), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeralAcertos
caerulea	entba	NFT	90	4	1	302	1	80,00%	99,67%	99,35%
caerulea	entba	NFT	120	5	0	302	1	100,00%	99,67%	99,68%
caerulea	entba	NFT	150	5	0	302	1	100,00%	99,67%	99,68%
caerulea	entba	PwsNFT	30	4	1	301	2	80,00%	99,34%	99,03%
caerulea	entba	PwsNFT	90	4	1	302	1	80,00%	99,67%	99,35%
caerulea	entba	PwsNFT	150	4	1	302	1	80,00%	99,67%	99,35%
foetida	entba	NFT	30	6	0	302	0	100,00%	100,00%	100,00%
foetida	entba	NFT	60	6	0	302	0	100,00%	100,00%	100,00%
foetida	entba	NFT	90	6	0	302	0	100,00%	100,00%	100,00%
foetida	entba	NFT	120	6	0	302	0	100,00%	100,00%	100,00%
foetida	entba	NFT	150	6	0	302	0	100,00%	100,00%	100,00%
foetida	entba	PwsNFT	30	6	0	302	0	100,00%	100,00%	100,00%
foetida	entba	PwsNFT	60	6	0	302	0	100,00%	100,00%	100,00%
foetida	entba	PwsNFT	90	6	0	302	0	100,00%	100,00%	100,00%
foetida	entba	PwsNFT	120	6	0	302	0	100,00%	100,00%	100,00%
foetida	entba	PwsNFT	150	6	0	301	1	100,00%	99,67%	99,68%
coqueiro de jardim	entba	FFTCz	60	20	0	287	1	100,00%	99,65%	99,68%
coqueiro de jardim	entba	FFTCz	90	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	FFTCz	120	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	FFTCz	150	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	NFT	30	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	NFT	60	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	NFT	90	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	NFT	120	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	NFT	150	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	PwsNFT	30	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	PwsNFT	60	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	PwsNFT	90	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	PwsNFT	120	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	entba	PwsNFT	150	20	0	288	0	100,00%	100,00%	100,00%
pau da mata	entba	NFT	30	10	0	296	2	100,00%	99,33%	99,35%
pau da mata	entba	NFT	60	10	0	297	1	100,00%	99,66%	99,68%
pau da mata	entba	NFT	150	10	0	297	1	100,00%	99,66%	99,68%
pau-brasil	entba	NFT	150	21	4	283	0	84,00%	100,00%	98,70%
pau-brasil	entba	PwsNFT	150	24	1	283	0	96,00%	100,00%	99,68%

Tabela D.5: Resultados da classificação do conjunto de amostras reais através da assinatura de contorno basal (entba), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeralAcertos
amethystina	crvgb	FFTCz	120	5	0	302	1	100,00%	99,67%	99,68%
foetida	crvgb	FFTCz	150	5	1	299	3	83,33%	99,01%	98,70%
gibertii	crvgb	FFTCz	30	5	2	301	0	71,43%	100,00%	99,35%
gibertii	crvgb	FFTCz	90	5	2	300	1	71,43%	99,67%	99,03%
gibertii	crvgb	FFTCz	120	5	2	300	1	71,43%	99,67%	99,03%
gibertii	crvgb	FFTCz	150	5	2	300	1	71,43%	99,67%	99,03%
gibertii	crvgb	PwsCz	60	5	2	301	0	71,43%	100,00%	99,35%
gibertii	crvgb	PwsCz	90	5	2	300	1	71,43%	99,67%	99,03%
gibertii	crvgb	PwsNFT	120	5	2	300	1	71,43%	99,67%	99,03%
miersii	crvgb	FFTCz	30	5	1	301	1	84,33%	99,67%	99,35%
miersii	crvgb	FFTCz	120	6	0	300	2	100,00%	99,34%	99,35%
organensis	crvgb	FFTCz	90	5	2	301	0	71,43%	100,00%	99,35%
suberosa	crvgb	FFTCz	30	5	2	301	0	71,43%	100,00%	99,35%
suberosa	crvgb	FFTCz	150	6	1	301	0	85,71%	100,00%	99,68%
casca d'anta	crvgb	FFTCz	30	8	0	298	2	100,00%	99,33%	99,35%
coqueiro de jardim	crvgb	PwsCz	30	20	0	288	0	100,00%	100,00%	100,00%
imbiricu	crvgb	FFTCz	120	7	0	301	0	100,00%	100,00%	100,00%
jequitiba	crvgb	FFTCz	30	7	2	295	4	77,78%	98,66%	98,05%
pau-brasil	crvgb	FFTCz	30	25	0	282	1	100,00%	99,65%	99,68%
pau-brasil	crvgb	FFTCz	120	25	0	282	1	100,00%	99,65%	99,68%
pau-brasil	crvgb	FFTCz	150	25	0	282	1	100,00%	99,65%	99,68%
pau-brasil	crvgh	NFT	90	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvgb	NFT	150	25	0	282	1	100,00%	99,65%	99,68%
pau-brasil	crvgb	PwsCz	30	25	0	282	1	100,00%	99,65%	99,68%

Tabela D.6: Resultados da classificação do conjunto de amostras reais através da assinatura de curvatura global (crvgb), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeralAcertos
organensis	ervap	FFTCz	60	5	2	301	0	71.43%	100.00%	99.35%
suberosa	ervap	FFTCz	120	3	4	301	0	42.86%	100.00%	98.70%
suberosa	ervap	NFT	60	6	1	299	2	85.71%	99.34%	99.03%
coqueiro de jardim	ervap	NFT	60	17	3	288	0	85.00%	100.00%	99.03%
coqueiro de jardim	ervap	NFT	120	20	0	288	0	100.00%	100.00%	100.00%
coqueiro de jardim	ervap	PwsNFT	90	20	0	288	0	100.00%	100.00%	100.00%
paina da mata	ervap	NFT	60	6	4	298	0	60.00%	100.00%	98.70%
paina da mata	ervap	NFT	120	7	3	298	0	70.00%	100.00%	99.03%
paina da mata	ervap	PwsCz	30	8	2	298	0	80.00%	100.00%	99.35%
pau-brasil	ervap	FFTCz	30	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	FFTCz	60	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	FFTCz	90	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	FFTCz	120	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	FFTCz	150	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	NFT	30	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	NFT	60	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	NFT	90	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	NFT	120	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	NFT	150	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	PwsNFT	30	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	PwsNFT	60	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	PwsNFT	90	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	PwsNFT	120	25	0	283	0	100.00%	100.00%	100.00%
pau-brasil	ervap	PwsNFT	150	25	0	283	0	100.00%	100.00%	100.00%
pitanga	ervap	NFT	30	13	0	293	2	100.00%	99.32%	99.35%
pitanga	ervap	NFT	60	11	2	293	2	84.62%	99.32%	98.70%
pitanga	ervap	NFT	90	13	0	293	2	100.00%	99.32%	99.35%
pitanga	ervap	NFT	120	12	1	293	2	92.31%	99.32%	99.03%
pitanga	ervap	NFT	150	13	0	292	3	100.00%	98.98%	99.03%
pitanga	ervap	PwsCz	60	13	0	294	1	100.00%	99.66%	99.68%
pitanga	ervap	PwsNFT	120	12	1	292	3	92.31%	98.98%	98.70%

Tabela D.7: Resultados da classificação do conjunto de amostras reais através da assinatura de curvatura apical (ervap), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Classe Assinalada	Assinatura	Domínio	Intervalo	CACC	CAIC	CDCC	CDIC	%CACC	%CDCC	%GeraAcertos
caerulea	crvba	FFTCz	120	4	1	303	0	80,00%	100,00%	99,68%
caerulea	crvba	PwsNET	60	1	1	303	0	80,00%	100,00%	99,68%
cabreuva	crvba	FFTCz	30	10	0	298	0	100,00%	100,00%	100,00%
cabreuva	crvba	FFTCz	60	10	0	298	0	100,00%	100,00%	100,00%
cabreuva	crvba	FFTCz	150	6	4	298	0	60,00%	100,00%	98,70%
cabreuva	crvba	NFT	30	8	2	298	0	80,00%	100,00%	99,35%
cabreuva	crvba	NFT	60	8	2	298	0	80,00%	100,00%	99,35%
cabreuva	crvba	NFT	90	8	2	298	0	80,00%	100,00%	99,35%
cabreuva	crvba	NFT	120	10	0	298	0	100,00%	100,00%	100,00%
cabreuva	crvba	NFT	150	8	2	298	0	80,00%	100,00%	99,35%
cabreuva	crvba	PwsNET	30	9	1	298	0	90,00%	100,00%	99,68%
cabreuva	crvba	PwsNET	60	9	1	298	0	90,00%	100,00%	99,68%
cabreuva	crvba	PwsNET	120	7	3	298	0	70,00%	100,00%	99,03%
cabreuva	crvba	PwsNET	150	8	2	298	0	80,00%	100,00%	99,35%
coqueiro de jardim	crvba	FFTCz	30	20	0	287	1	100,00%	99,65%	99,68%
coqueiro de jardim	crvba	FFTCz	60	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	crvba	FFTCz	120	18	2	287	1	90,00%	99,65%	99,03%
coqueiro de jardim	crvba	NFT	30	20	0	288	0	100,00%	100,00%	100,00%
coqueiro de jardim	crvba	NFT	60	19	1	288	0	95,00%	100,00%	99,68%
coqueiro de jardim	crvba	NFT	120	19	1	287	1	95,00%	99,65%	99,35%
descon04	crvba	NFT	150	11	2	287	5	87,50%	98,29%	97,73%
descon04	crvba	PwsNET	60	16	0	288	1	100,00%	98,63%	98,70%
descon05	crvba	NFT	150	12	0	295	1	100,00%	99,66%	99,68%
jatoba	crvba	PwsNET	60	10	0	297	1	100,00%	99,16%	99,68%
jequitiba	crvba	FFTCz	30	8	1	298	1	88,89%	99,67%	99,35%
jequitiba	crvba	FFTCz	90	6	3	299	0	66,67%	100,00%	99,03%
jequitiba	crvba	FFTCz	120	5	4	299	0	55,56%	100,00%	98,70%
paina da mata	crvba	FFTCz	30	3	7	297	1	30,00%	99,66%	97,10%
pau-brasil	crvba	FFTCz	30	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	FFTCz	60	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	FFTCz	90	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	FFTCz	120	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	NFT	30	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	NFT	90	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	NFT	120	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	NFT	150	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsCz	30	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsCz	120	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsNET	30	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsNET	60	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsNET	90	25	0	283	0	100,00%	100,00%	100,00%
pau-brasil	crvba	PwsNET	150	25	0	283	0	100,00%	100,00%	100,00%
pitanga	crvba	FFTCz	30	13	0	295	0	100,00%	100,00%	100,00%
pitanga	crvba	FFTCz	90	13	0	295	0	100,00%	100,00%	100,00%
pitanga	crvba	FFTCz	120	13	0	295	0	100,00%	100,00%	100,00%
pitanga	crvba	FFTCz	150	13	0	291	1	100,00%	99,66%	99,68%
pitanga	crvba	NFT	30	12	1	295	0	92,31%	100,00%	99,68%
pitanga	crvba	NFT	120	13	0	295	0	100,00%	100,00%	100,00%
pitanga	crvba	NFT	150	13	0	295	0	100,00%	100,00%	100,00%
pitanga	crvba	PwsCz	90	13	0	295	0	100,00%	100,00%	100,00%

Tabela D.8: Resultados da classificação do conjunto de amostras reais através da assinatura de curvatura basal (crvba), considerando-se as variações do intervalo de frequência e do domínio da frequência.

Referências Bibliográficas

- ASH, A.; ELLIS, B.; HICKEY, L. J.; JOHNSON, K.; WILF, P.; WING, S. Manual of leaf architecture - morphological description and categorization of dicotyledonous and net-veined monocotyledonous angiosperms by leaf architecture. - <http://www.peabody.yale.edu/collections/pb/mla/mla.pdf>. 1999.
- ATTNEAVE, F. Some informational aspects of visual perception. *Psychological Review*, , no. 61, page 183-193, 1954.
- BANDERA, A.; URDIALES, C.; ARREBOLA, F.; SANDOVAL, F. 2d object recognition based on curvature functions obtained from local histograms of the contour chain code. *Pattern Recognition Letters*, volume 1999, no. 20, page 49-55, 1999.
- BANKS, E. *Signal processing, image processing and pattern recognition*. Prentice Hall International Series in Acoustics, Speech and Signal Processing. New York: Prentice Hall, 1990.
- BRAGA, A. D. P.; CARVALHO, A. C. P. D. L.; LUDERMIR, T. B. *Redes neurais artificiais - teoria e aplicações*. Rio de Janeiro: Livros Técnicos Científicos Ltda., 2000.
- BRUNO, O. M. *Paralelismo em visao natural e artificial*. phd thesis, Universidade de São Paulo, São Carlos, SP. 2000.
- BURDIN, V.; GHORBEL, F.; DE BOUGRENET DE LA TOCNAYE, J. L.; ROUX, C. A three-dimensional primitive extraction of long bones obtained from bi-dimensional fourier descriptors. *Pattern Recognition Letters*, volume 13, no. 3, page 213-217, 1992.
- CESAR, JR, R. M. *Análise multi-escala de formas bidimensionais*. phd thesis, Universidade de São Paulo, São Carlos, SP, 1997.
- COSTA, L. F.; CESAR, R. M. J. *Shape analysis and classification - theory and practice*. Image processing series. Boca Raton: CRC Press, 2001.
- EAMES; MACDANIELS. *Introduction to plant anatomy*. Second edition Book Company, page 317-318, 1947.
- EGMONT-PETERSEN, M.; HEDDER, D.; HANDELS, H. Image processing with neural networks a review. *Pattern Recognition*, volume 35, no. 10, page 2279-2301, 2001.
- FONGA, H. Pattern recognition in gray-level images by fourier analysis. *Pattern Recognition Letters*, volume 17, no. 9, page 1477-1489, 1996.

- GERMANO FILHO, P. Estudos taxionômicos do gênero *batysa* c. presl (rubiacae, rondeletieae), no brasil. *Rodriguésia: Revista do Jardim Botânico do Rio de Janeiro*, volume 50, no. 76/77, page 49–75, 1999.
- GIN, M.; CHIENG, R. *Genetic algorithms and engineerin design*. New York: John Wiley & Sons, Inc., 1997.
- GOLA, G. *Tratado de botânica*, chapter Shape Characterization. 2a. edition Boca Raton: Editora Labor, page 233–237, 1965.
- GOLDBERG, D. E. *Genetic algorithms in search, optimization and machine learning*. Massachusetts: Addison-Wesley Publishing Company, Inc., 1989.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de imagens digitais*. São Paulo: Edgard Blücher Ltda., 2000.
- GRANLUND, G. H. Fourier preprocessing for hand print character recogniton. *IEEE Transactions on Computers*, volume 2, no. C-21, page 195–201, 1972.
- HAYKIN, S. *Neural networks*. Second edition. New Jersey: Prentice Hall, 1999.
- HEBB, D. O. *The organization of the behavior*. Wiley, 1949.
- HICHEY, L. J. Classification of architecture of dicotyledonous leaves. *Amer. J. Bot.* volume 60, no. 1, page 17–33, 1973.
- HIKEY, L. J.; TAYLOR, D. W. The leaf architecture of ticodendrum and the application of foliar characters in discerning its relationships. In: *Annals of the Missouri Botanical Garden*, no. 78, 1991, page 105–130.
- HIKEY, L. J.; WOLFE, J. A. The bases of angiosperm phylogeny: vegetative morphology. In: *Annals of the Missouri Botanical Garden*, 1975, page 538–589.
- HOLLAND, J. H. *Adapatation in natural and artificial systems*. MIT Press, 1975.
- HOPFIELD, J. J. Neural networks and physical systems with emergent collective properties. *Proc. Nat. Acad. Sci.*, volume 79, page 2554–2558, 1982.
- JAIN, R.; KASTURI, R.; SCHUNK, B. G. *Machine vision*. Computer Science. New York: McGraw-Hill, 1995.
- KELLER, K.-D. Optische illusionen - <http://www.mathematik.uni-ulm.de/keller/illusionen/kipp/i> 2003.
- LACERDA, E. G. M. D.; CARVALHO, A. C. P. L. F. *Sistemas inteligentes - aplicações a recursos hídricos e ciências ambientais*, chapter Introdução aos algoritmos genéticos. Coleção ABRH de Recursos Hídricos, 1 edition Porto Alegre: Editora da Universidade - Universidade do Rio Grande do Sul, page 99–150, 1999.
- LEVINE, M. D. *Vision in man and machine*. New York: McGraw-Hill Publishin Company, 1985.
- LIMA, M. C. B. *Guia didático de botânica morfológica* Falta pegar, pages 64, 1995.

- LOPES, R. C. Ebenaceae vent. do estado do rio de janeiro. *Rodriguésia: Revista do Jardim Botânico do Rio de Janeiro*, volume 50, no. 76/77, page 85–107, 1999.
- MCCULLOCK, W. S.; PITTS. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, , no. 5, page 115–133, 1943.
- MISSK, M.; PAPERT, S. *Perceptrons: an introduction to computational gemetry*. Massachusetts: MIT Press, 1969.
- NELSON, M. M.; ILLINGWORTH, W. T. *A practical guide to neural nets*. Reading: Addison Wesley, 1991.
- OSOWSKI, S.; NGHIA, D. D. Fourier and wavelet descriptors for shape recognition using neural networks - a comparative study. *Pattern Recognition*, volume 35, no. 2002, page 1949–1957. 2001.
- PAPOULIS, A. *The fourier integral and its applications*. McGraw-Hill, 1962.
- PARKER, J. R. *Algorithms for image processing and computer vision*. New York: John Wiley & Sons, Inc., 1997.
- PAVILIDS, T. *Algoritms for graphics and image processing*. Rockville: Computer Science, 1982.
- PETERS, T. M.; BATES, J. H. T. *The fourier transform in biomedical engineering*, chapter The Discrete Fourier Transform and the Fast Fourier Transform Boston: Birkhäuser, page 176–194, 1998.
- PLOTZE, R. O.; FAIVO, M.; BRUNO, O. M. Identificação de espécies arbóreas através da dimensão fractal. In: *Anais do III Congresso Brasileiro de Computação*, Itajaí - Santa Catarina, 2003, page 1770–1779.
- PORMELAU, D. Efficient training of artificial neural networks for autonomous navigation. *Neural Computation*, volume 3, no. 1, page 88–97, 1991.
- ROSENBLATT, F. Perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, , no. 65, page 386–408, 1958.
- RUMERLHART, D. E.; HILTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagation errors. *Nature*, . no. 323, page 533–545, 1986.
- SERRA, J. *Image analysis and mathematical morphology*, volume 1. London: Academic Press, 1982.
- SEZGIN, M.; SANKUR, B. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, volume 1, no. 13, page 146–165, 2004.
- SIMMONS, G. F. *Cáculo com geometria analítica*. São Paulo: McGraw-Hill, 1987.
- SONKA, M.; HLAVAC, V.; BOYLE, R. *Image processing, analysis, and machine vision*. 2 edition. PWS Publishing, 1998.

- STONE, M. Cross-calidatory choice and assessment of statistical predictions. *Journal of Royal Statistica Society*, volume B36, page 111-133, 1974.
- TCHOUKANOV, I.; SAFEH-RAD, R.; BENHABIB, B.; SMITH, K. C. The angle-of-sight signature for 2d shape analysis. In: *Conference Publication*, IEEE, 1991, page 2461-2464.
- VALENÇA, M. J. S.; LUDERMIR, T. B. *Sistemas inteligentes - aplicações a recursos hídricos e ciências ambientais*, chapter Introdução à Redes Neurais. Coleção ABRH de Recursos Hídricos, 1 edition Porto Alegre: Editora da Universidade - Universidade do Rio Grande do Sul, page 19-59, 1999.
- VICENTE, A. C. A.; MACEDO, E. G.; SANTOS, J. U. M.; POTIGUARA, R. C. V.; BASTOS, M. N. C. *Flórula fanerogâmica das restingas do estado do pará, ilha do algodoul*, volume 15 of *Bot.* Bol. Museu Paraense Emílio Goeldi, 1999.
- WAGGONER, B. Carl linnaeus - <http://www.ucmp.berkeley.edu/history/linnaeus.html>. 2003.