Felipe Alves Cavani

***Análise de cenas de pomares de laranjeiras através
de segmentação de imagens e reconhecimento de
padrões***

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Mestre em Engenharia Mecânica.

Orientador:
Prof. Dr. Mário Luiz Tronco

São Carlos

2007

Folha de aprovação

Felipe Alves Cavani

Análise de cenas de pomares de laranjeiras através de segmentação de imagens e reconhecimento de padrões

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Mestre em Engenharia Mecânica.

Aprovado em:

Banca examinadora

Prof. Dr. Mário Luiz Tronco (Orientador)
Unesp - Instituto de Biociências, Letras e
Ciências Exatas

Prof. Dr. Banca Um
Universidade de Smallville

Prof. Dr. Banca Dois
Universidade de Metropolis

Agradecimentos

Primeiro, agradeço à Cris por estar perto de mim.

Ao Prof. Dr. Mário Luiz Tronco por ter me orientado.

Ao Prof. Dr. Arthur José Vieira Porto por ter dado a oportunidade de desenvolver este trabalho no Laboratório de Simulação e Controle de Eventos Discretos.

Ao Prof. Ricardo Yassushi Inamasu por ter me auxiliado com os temas da área agrícola.

Aos colegas de laboratório, pelas muitas idéias compartilhadas.

À equipe da Escola de Engenharia de São Carlos, pelo suporte fornecido aos alunos. Destaco: Beth, Ana Paula e Cláudio.

Ao CNPq pelo auxílio financeiro.

Resumo

CAVANI, F. A. *Análise de cenas de pomares de laranjeiras através de segmentação de imagens e reconhecimento de padrões*. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2007.

Os sistemas automáticos são normalmente empregados na indústria com o objetivo de otimizar a produção. Na agro-indústria, estes sistemas são usados com o mesmo propósito, sendo que dentre estes sistemas é possível destacar os que empregam a visão computacional, pois esta tem sido usada para inspeção de lavouras, colheita mecanizada, guiagem de veículos e robôs entre outras aplicações.

No presente trabalho, técnicas de visão computacional foram utilizadas para segmentar e classificar elementos presentes em imagens obtidas de pomares de laranjeiras. Uma arquitetura modular foi utilizada na qual a imagem é segmentada automaticamente e, posteriormente, os segmentos são classificados. Nesta arquitetura, o algoritmo de segmentação e o classificador podem ser alterados sem prejudicar a flexibilidade do sistema implementado.

Foram realizados experimentos com um banco de imagens composto por 658 imagens. Estas imagens foram obtidas sob diferentes condições de iluminação durante o período que as frutas estavam maduras. Estes experimentos foram realizados para avaliar, no contexto da arquitetura desenvolvida, o algoritmo de segmentação JSEG, vetores de características derivados dos espaços de cores RGB e HSV, além de três tipos de classificadores: bayesiano, classificador ingênuo de Bayes e classificador baseado no perceptron multicamadas. Finalmente, foram construídos os mapas de classes. As funções de distribuição de probabilidades foram estimadas com o algoritmo de Figueiredo-Jain.

Dos resultados obtidos, deve-se destacar que o algoritmo de segmentação mostrou-se adequado aos propósitos deste trabalho e o classificador bayesiano mostrou-se mais prático que o classificador baseado no perceptron multicamadas. Por fim, a arquitetura mostrou-se adequada para o reconhecimento de cenas obtidas em pomares de laranjeiras.

Palavras-chave: reconhecimento de cenas, segmentação imagens, JSEG, perceptron multicamadas, classificador bayesiano, algoritmo de Figueiredo-Jain.

Abstract

CAVANI, F. A. *Orange orchard scene analysis with image segmentation and pattern recognition*. Dissertation (Master) - Engineering school of São Carlos, São Paulo University, São Carlos, 2007.

Automation systems are usually used in the industry to optimize the production. In the agroindustry, these systems are used with the same intentions. Among them are systems that use computer vision for inspection, mechanized harvest, vehicles and robots guidance and other applications.

Because of this, in the present work, techniques of computer vision were used to segment and classify elements in the images from oranges orchards. A modular architecture was used. The image are automatically segmented and, then the segments are classified. In this architecture, the segmentation algorithm and the classifier can be modified without loss of flexibility.

The experiments were carried out with 658 images. These images were acquired under different illumination conditions during the period that the fruits are mature. These experiments were carried out to evaluate, in the context of developed architecture, the segmentation algorithm JSEG, characteristics vectors derived from the colors spaces RGB and HSV and three classifiers: Bayes's classifier, Bayes's naive classifier and multilayer perceptron classifier. Finally, the class maps were constructed. The Figueiredo-Jain algorithm was used to estimate the probability distribution functions.

The results show that the segmentation algorithm is adequate to this work and the Bayes classifier is more practical that the multilayer perceptron classifier. Finally, the architecture is adequate for recognition of images acquired in orange orchards.

Keywords: scene analysis, image segmentation, JSEG, multilayer perceptron, Bayes's classifier, Figueiredo-Jain algorithm.

Sumário

Lista de Siglas

1	Introdução	p. 17
1.1	Objetivos	p. 18
1.2	Organização da dissertação	p. 19
2	Visão computacional	p. 21
2.1	Processamento de imagens digitais	p. 22
2.1.1	Imagens digitais	p. 23
2.1.2	Pré-processamento	p. 33
2.1.3	Segmentação	p. 40
2.2	Reconhecimento de padrões	p. 55
2.2.1	Características dos elementos de uma imagem	p. 57
2.2.2	Normalização e extração das características	p. 66
2.2.3	Classificação das características	p. 68
2.2.4	Classificadores de padrões	p. 72
2.2.5	Seleção e avaliação do classificador	p. 79
2.3	Considerações finais	p. 82
3	Visão computacional aplicada à agricultura	p. 83
3.1	Localização, inspeção e colheita de frutos	p. 84
3.2	Localização e classificação de plantas	p. 96
3.3	Considerações finais	p. 104
4	Desenvolvimento	p. 107
4.1	Introdução	p. 107
4.2	Caracterização das imagens	p. 107
4.3	Ferramentas computacionais	p. 110
4.4	Métodos	p. 111

4.4.1	Segmentação das imagens	p. 113
4.4.2	Classificação manual dos segmentos	p. 116
4.4.3	Características dos segmentos	p. 118
4.4.4	Normalização e extração das características	p. 119
4.4.5	Classificação automática dos segmentos	p. 120
4.4.6	Avaliação dos classificadores	p. 124
4.5	Considerações finais	p. 125
5	Resultados experimentais	p. 127
5.1	Segmentação	p. 127
5.2	Normalização e extração de características	p. 130
5.3	Classificação dos segmentos	p. 136
5.3.1	Baseado em redes neurais artificiais	p. 136
5.3.2	Baseado no teorema de Bayes	p. 137
5.3.3	Classificador Ingênuo de Bayes	p. 140
5.3.4	Comparações entre os classificadores	p. 141
5.4	Mapas de classes	p. 143
5.5	Considerações finais	p. 146
6	Conclusões	p. 147
6.1	Considerações finais e conclusões	p. 147
6.2	Trabalhos futuros	p. 149
Apêndice A – Melhores resultados dos testes dos classificadores		p. 151
Apêndice B – EQM dos treinamentos dos melhores classificadores baseados em RNA		p. 155
Apêndice C – Matrizes de confusão dos testes do classificador baseado em RNA		p. 157
C.1	Testes dos classificadores treinados com o conjunto RGB – 20%	p. 157
C.2	Testes dos classificadores treinados com o conjunto RGB – 30%	p. 162
C.3	Testes dos classificadores treinados com o conjunto RGB – 50%	p. 166
C.4	Testes dos classificadores treinados com o conjunto RGB – 70%	p. 170
C.5	Testes dos classificadores treinados com o conjunto RGB – 100%	p. 174
C.6	Testes dos classificadores treinados com o conjunto HSV – 20%	p. 178

C.7	Testes dos classificadores treinados com o conjunto HSV – 30%	p. 182
C.8	Testes dos classificadores treinados com o conjunto HSV – 50%	p. 186
C.9	Testes dos classificadores treinados com o conjunto HSV – 70%	p. 190
C.10	Testes dos classificadores treinados com o conjunto HSV – 100%	p. 194
Apêndice D – Matrizes de confusão dos testes do classificador bayesiano		p. 199
D.1	Testes dos classificadores treinados com o conjunto RGB – 20%	p. 199
D.2	Testes dos classificadores treinados com o conjunto RGB – 30%	p. 202
D.3	Testes dos classificadores treinados com o conjunto RGB – 50%	p. 206
D.4	Testes dos classificadores treinados com o conjunto RGB – 70%	p. 210
D.5	Testes dos classificadores treinados com o conjunto RGB – 100%	p. 214
D.6	Testes dos classificadores treinados com o conjunto HSV – 20%	p. 218
D.7	Testes dos classificadores treinados com o conjunto HSV – 30%	p. 220
D.8	Testes dos classificadores treinados com o conjunto HSV – 50%	p. 224
D.9	Testes dos classificadores treinados com o conjunto HSV – 70%	p. 228
D.10	Testes dos classificadores treinados com o conjunto HSV – 100%	p. 232
Apêndice E – Matrizes de confusão dos testes do classificador de Bayes ingênuo		p. 237
E.1	Testes dos classificadores treinados com o conjunto RGB – 20%	p. 237
E.2	Testes dos classificadores treinados com o conjunto RGB – 30%	p. 242
E.3	Testes dos classificadores treinados com o conjunto RGB – 50%	p. 246
E.4	Testes dos classificadores treinados com o conjunto RGB – 70%	p. 250
E.5	Testes dos classificadores treinados com o conjunto RGB – 100%	p. 254
E.6	Testes dos classificadores treinados com o conjunto HSV – 20%	p. 258
E.7	Testes dos classificadores treinados com o conjunto HSV – 30%	p. 262
E.8	Testes dos classificadores treinados com o conjunto HSV – 50%	p. 266
E.9	Testes dos classificadores treinados com o conjunto HSV – 70%	p. 270
E.10	Testes dos classificadores treinados com o conjunto HSV – 100%	p. 274
Apêndice F – Mapas de classes		p. 279
F.1	Imagem 2	p. 279
F.2	Imagem 3	p. 281
F.3	Imagem 4	p. 282
F.4	Imagem 5	p. 283

F.5	Imagem 6	p. 284
F.6	Imagem 7	p. 285
F.7	Imagem 8	p. 286
F.8	Imagem 9	p. 287
F.9	Imagem 10	p. 288
F.10	Imagem 11	p. 289
F.11	Imagem 12	p. 290
F.12	Imagem 13	p. 291
F.13	Imagem 14	p. 292
F.14	Imagem 15	p. 293
F.15	Imagem 16	p. 294
F.16	Imagem 17	p. 295
F.17	Imagem 18	p. 296
F.18	Imagem 19	p. 297
F.19	Imagem 20	p. 298

Referências	p. 299
--------------------	--------

Lista de Siglas

ACP	Análise de componentes principais
AG	Algoritmo Genético
ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i> – sistema adaptativo nebuloso-neural
AP	Agricultura de precisão
CDD	<i>Charge coupled device</i> – dispositivo de carga emparelhada
CIE	<i>Commission International de l'Eclairage</i>
CLD	<i>Color layout descriptor</i>
CSNN	<i>Constraint satisfaction neural network</i> – rede neural para solução de restrições
CSP	<i>Constraint satisfaction problem</i> – problema de solução de restrições
DGPS	Differential GPS – GPS diferencial
DSP	<i>Digital signal processor</i> – processador de sinais digitais
EM	Algoritmo de maximização da esperança – <i>expectation-maximization</i>
EQM	Erro quadrático médio
EUA	Estados Unidos da América
Fann	<i>Fast artificial neural network</i>
FCM	<i>Fuzzy c-means</i> – C-médias nebuloso
FDCP	Funções de densidade conjunta de probabilidades
FDP	Função densidade de probabilidade
GPS	Global positioning system – sistema de posicionamento global
HSB	Matiz (<i>hue</i>), saturação e brilho
HSI	Matiz (<i>hue</i>), saturação e intensidade
HSL	Matiz (<i>hue</i>), saturação e luminosidade
HSV	Matiz (<i>hue</i>), saturação e valor
HTML	<i>Hyper text markup language</i> – linguagem de marcação de texto
IA	Inteligência artificial

ILPF	<i>Ideal lowpass filter</i> – filtro ideal passa-baixa
INPE	Instituto Nacional de Pesquisas Espaciais
JPEG	Joint photographic experts group
ML	<i>Maximum-likelihood</i>
MPEG	<i>Moving picture experts group</i>
Nrgb	RGB normalizado
NTSC	<i>National Television System Commission</i> , Estados Unidos da América (EUA)
PC	Personal computer – computador pessoal
PCM	Perceptron multi-camadas
PGF	<i>Peer group filtering</i>
PHP	<i>PHP: hypertext preprocessor</i>
RBIR	<i>Region-based image retrieval</i> – recuperação de imagens baseada em regiões
RGB	<i>Red, green, blue</i> – vermelho, verde, azul
RNA	Redes neurais artificiais
SCD	<i>Scalable color descriptor</i>
SIN	Sistema de inferência nebulosa
SiRIC	Sistemas de recuperação de imagens baseada em conteúdo
SOM	<i>Self-organizing maps</i> – mapas auto-organizáveis
SSR	<i>Segmentation success rate</i> – índice de sucesso de segmentação
SVG	<i>Scable vectorial graphics</i> – gráficos vetoriais escaláveis
XML	<i>Extensible markup language</i> – linguagem de marcação extensível

1 Introdução

A agricultura contribui de forma significativa para a economia do estado de São Paulo, com destaque para dois produtos: a cana de açúcar e a laranja. Em especial, as culturas de laranjas desempenham papel importante na economia de São Paulo, pois a produção também é destinada ao consumo em todo o Brasil e no exterior. Por isto, a manutenção da competitividade é importante.

A automação pode ser usada como um instrumento para diminuir custos e elevar a produtividade. Devido a isto, a área agrícola tem adotado a automação de modo semelhante à indústria convencional. Além da automação, a área agrícola tem absorvido tecnologias oriundas de outras áreas, com por exemplo a do GPS (*global positioning system* – sistema de posicionamento global). Tal fato fica evidente ao observar-se as práticas ligadas à agricultura de precisão – AP (MOLIN, 2003).

Como consequência desta evolução, técnicas de visão computacional aplicadas à agricultura tem sido pesquisadas. Tais técnicas viabilizam algumas práticas relacionadas com a AP, como por exemplo, a contagem de frutos para a confecção de mapas de produtividade. Quando considerada a cadeia produtiva de frutas cítricas, técnicas de visão computacional também desempenham importante papel, principalmente em tarefas relacionadas à inspeção, contagem de frutos, colheita automática, identificação de doenças, etc.

A visão computacional aplicada à áreas agrícola é viável pois esta tem se beneficiado do desenvolvimento dos computadores e de novos algoritmos. Entre estes algoritmos, destacam-se os algoritmos de segmentação de imagens de cenas naturais e os classificadores de padrões que são robustos às variabilidades encontradas nos ambientes agrícolas. Tais algoritmos são

importantes, pois tais sistemas são viabilizados para o uso comercial.

Devido a isto, neste trabalho, tais algoritmos são avaliados com o objetivo de desenvolver uma arquitetura para reconhecimento de imagens agrícolas obtidas em pomares de laranjeiras. Assim, busca-se contribuir com a área agrícola e, ainda, contribuir com a área de visão computacional, através dos resultados obtidos em diversos experimentos realizados.

1.1 Objetivos

Este trabalho lida com as técnicas de visão computacional quando estas são usadas com o objetivo de reconhecer os principais elementos presentes em cenas de pomares de laranjeiras: frutos, folhas e céu. Várias decisões devem ser tomadas ao empregar as técnicas de visão computacional para identificar estes elementos. Neste sentido, o objetivo do presente trabalho é detalhado como segue:

- Avaliar o comportamento do algoritmo de segmentação JSEG com imagens de pomares de laranjeiras com o objetivo de determinar, através da inspeção das imagens segmentadas, se este algoritmo é capaz de criar segmentos coerentes.
- Avaliar, através dos resultados obtidos com os classificadores de padrões, vetores de características que identificam os elementos de interesse, sendo que tais vetores tem diferentes números de dimensões e são derivados dos espaços de cores RGB e HSV.
- Avaliar classificadores de padrões baseados em redes neurais artificiais (RNA) e no teorema de Bayes, comparando seus desempenhos, através das taxas de acerto e das matrizes de confusão, ao classificarem conjuntos de treinamento onde existem vetores que estão mais distantes ou não da centróide da classe a que estes vetores pertencem.
- Avaliar, através de inspeção visual, os resultados obtidos com os mapas de classes de modo a determinar como os classificadores comportam-se perante as diferentes imagens que compõem o banco de imagens.

1.2 Organização da dissertação

Os assuntos abordados no presente trabalho foram divididos de forma que inicialmente são apresentadas de forma introdutória as técnicas relacionadas a visão computacional. Depois, são apresentadas aplicações da visão computacional na área agrícola, o desenvolvimento do trabalho, os resultados obtidos e, por fim, as conclusões. A seguir, o conteúdo de cada Capítulo é detalhado.

O Capítulo 2 apresenta inicialmente uma introdução à visão computacional, onde o conceito de imagem digital é revisado. Os principais espaços de cores são apresentados. Também, são apresentados os principais conceitos necessários para o entendimento de segmentação de imagens. Após isto, é feita uma introdução ao reconhecimento de padrões, onde são apresentadas técnicas de descrição de elementos, normalização, extração de características, classificação de padrões e validação de um classificador.

O Capítulo 3 traz a revisão dos principais trabalhos da área agrícola que utilizam visão computacional, separados conforme a área de aplicação.

No Capítulo 4, primeiro as imagens utilizadas neste trabalho são caracterizadas, possibilitando conhecer os problemas impostos por tais imagens. Depois são apresentadas as ferramentas computacionais utilizadas para implementar os principais algoritmos. Por fim, são apresentados métodos, usados neste trabalho, para segmentação de imagens, classificação manual dos segmentos, extração de características, normalização, classificação automática dos segmentos e avaliação dos classificadores.

No Capítulo 5, são apresentados os resultados obtidos com a segmentação das imagens e também são apresentados os resultados obtidos com os vários classificadores avaliados. Também é feita a comparação entre os diferentes tipos de vetores de características e as diferentes abordagens de classificação. As imagens com os segmentos classificados são apresentadas no final deste capítulo.

Por fim, no Capítulo 6 são apresentadas as principais conclusões relacionadas ao presente

trabalho.

2 *Visão computacional*

O homem, assim como outros seres vivos, é dotado de sensores que percebem o espectro eletromagnético. No caso humano, a faixa de frequência captada pelos sensores responsáveis pela visão é chamada de espectro visível. Estas ondas tem origem na luz solar ou na luz artificial. Os sensores captam, também, a localização espacial destas ondas. Por fim, a variação temporal destas ondas também é considerada. Todas estas informações são processadas pelo cérebro, com o objetivo de criar um modelo dinâmico do ambiente, permitindo ao homem interagir com ele. A visão, portanto, é um dos principais meios usados pelo homem e por outros seres vivos para reconhecer o mundo.

A visão computacional, utilizando sensores, técnicas de processamento de imagens digitais, reconhecimento de padrões e inteligência artificial (IA), tem como objetivo obter informações de alto nível do ambiente que deu origem à imagem analisada (SCHALKOFF, 1989). Os sensores usados em visão computacional geram uma grande quantidade de informações, pois, além da informação espacial, eles captam a informação de cor e, no caso das câmeras de vídeo, a informação temporal. O processamento de imagens digitais é a área de estudo responsável por lidar com estas informações. A imagem é processada com o objetivo de melhorar sua qualidade ou enfatizar alguns de seus aspectos. Processar estas informações demanda tempo, pois o tamanho da imagem influencia o tempo de processamento. Este tempo, de processamento, e a sofisticação dos algoritmos também estão relacionados com a complexidade da imagem a ser processada. Imagens complexas são imagens de cenas onde existem elementos com formas, tamanhos e cores variadas, sob diferentes condições de iluminação, e com localizações diversas.

A análise da imagem é feita na maioria das vezes através do uso de técnicas de IA (inte-

ligência artificial). Segundo Russell e Norvig (2004), IA pode ser definida como “o estudo dos agentes que percebem o ambiente e executam ações”. Cada agente implementa uma função que mapeia seqüências de percepções em ações, onde estas funções podem ser representadas por sistemas de produção, agentes reativos etc. Entretanto, estas funções devem representar o ambiente onde operam; para isto são utilizadas técnicas de aprendizagem. O reconhecimento de padrões, empregado em visão computacional, enquadra-se dentre as técnicas de aprendizagem.

Além das incertezas causadas por limitações dos sensores e adversidades naturais, é necessário considerar a natureza ambígua do processo de visão. Duas pessoas podem observar cenas semelhantes, porém elas podem enxergar ou interpretar a cena de forma diferente, pois a cena desperta interesses diferentes em cada uma delas (LEVINE, 1985).

Visão computacional se apresenta como uma ferramenta adequada para reconhecer o ambiente. Entretanto, criar um modelo computacional semelhante à visão humana impõe muitos desafios. Um destes desafios é a quantidade de informação que deve ser processada. Também, o funcionamento da visão humana não é de todo conhecido, o que dificulta a construção de modelos computacionais adequados, levando ao uso de modelos simplificados.

2.1 Processamento de imagens digitais

Os primeiros estágios de um sistema de visão computacional são responsabilidade do processamento de imagens digitais, onde a imagem é adquirida e processada. A aquisição da imagem é realizada utilizando-se um sensor. Neste processo, como em qualquer sensor, a informação sofre algum tipo de degradação que deve ser corrigida ou minimizada. Também, a imagem pode ser transformada de tal forma a gerar outro tipo de informação.

Nesta seção, primeiro serão definidas imagens digitais, imagens monocromáticas e coloridas. Depois, são apresentadas algumas técnicas de pré-processamento destas imagens. Por fim, é apresentada uma introdução às técnicas de segmentação de imagens.

2.1.1 Imagens digitais

Imagens monocromáticas

A imagem digital é uma representação de uma imagem real. Esta representação é construída de forma que ocorra o mínimo de degradação da informação possível. A informação armazenada na imagem deve ser suficiente para que o sistema de visão computacional funcione adequadamente. Também, o formato da imagem digital, ou seja, o modelo matemático discreto que representa a imagem, deve ser adequado para o processamento em computadores digitais.

Uma imagem pode ser representada por uma função bidimensional $f(x,y)$, onde (x,y) são as coordenadas no plano onde a imagem é projetada. O valor de $f(x,y)$ é a intensidade da luz neste ponto. Esta função deve ser transformada para o formato digital através de duas operações: a amostragem espacial e a quantização da amplitude (FAIRHURST, 1988; GONZALEZ; WINTZ, 1987).

Na amostragem espacial, o plano (x,y) passa a ser representado por um número finito de pontos, que são organizados na forma de uma estrutura bidimensional. Os pontos são uniformemente distribuídos nesta estrutura. A quantidade de pontos pode ser variada; quanto mais pontos, maior a quantidade de informação espacial. Estes pontos são chamados de *picture elements* ou *pixels*. Cada um destes pontos é associado ao respectivo valor quantizado de $f(x,y)$. A Figura 1 mostra o esquema de uma imagem digital, onde o valor quantizado de $f(x,y)$ ocupa um *pixel*, que é representado pelos quadrados.

O valor de $f(x,y)$ deve ser quantizado em um número finito de valores. Estes valores recebem o nome de níveis de cinza. O conjunto de todos os níveis de cinza recebe o nome de escala de tons de cinza. O número de níveis de cinza é 2^l , onde l é um número inteiro positivo. Quanto maior o número l mais nuances de cinza o sistema será capaz de captar.

Em uma imagem discreta com $M \times N$ *pixels*, onde M é a largura e N é o comprimento e cada *pixel* pode representar 2^l tons de cinza, temos:

$$b = N \times M \times 2^l, \quad (2.1)$$

$f(0,0)$	$f(0,1)$	$f(0,2)$	$f(0,3)$	$f(0,4)$	$f(0,5)$	$f(0,6)$
$f(1,0)$	$f(1,1)$	$f(1,2)$	$f(1,3)$	$f(1,4)$	$f(1,5)$	$f(1,6)$
$f(2,0)$	$f(2,1)$	$f(2,2)$	$f(2,3)$	$f(2,4)$	$f(2,5)$	$f(2,6)$
$f(3,0)$	$f(3,1)$	$f(3,2)$	$f(3,3)$	$f(3,4)$	$f(3,5)$	$f(3,6)$
$f(4,0)$	$f(4,1)$	$f(4,2)$	$f(4,3)$	$f(4,4)$	$f(4,5)$	$f(4,6)$
$f(5,0)$	$f(5,1)$	$f(5,2)$	$f(5,3)$	$f(5,4)$	$f(5,5)$	$f(5,6)$

Figura 1: Esquema de uma imagem digital monocromática.

onde b é o número de *bits* necessários para armazenar esta imagem no formato digital.

A aquisição dessas imagens monocromáticas é feita de forma mais simples, já que não é necessário considerar os diferentes comprimentos de onda. Também, diversos sistemas de visão computacional não necessitam das informações de cores para funcionarem adequadamente. Entretanto, quando a cor é uma característica importante, o modelo monocromático não é mais adequado. Então é necessário utilizar modelos onde são considerados diversos comprimentos de onda. Tais modelos serão apresentados na próxima seção.

Imagens coloridas

O modelo de imagem apresentado anteriormente não leva em conta que o olho humano percebe a luz com comprimentos de onda variando desde 400 nm (violeta) até 700 nm (vermelho), aproximadamente. Além destas cores, chamadas de primárias, o olho humano percebe misturas delas. Isto cria uma grande variedade de cores, que devem ser representadas por um modelo matemático adequado a um computador digital.

Os seres humanos são dotados de três tipos diferentes de receptores de cores, que são chamados de cones. Cada um destes tipos de cone têm pico de receptividade em um compri-

mento de onda, que são: 650 nm (R - *red*/vermelho), 530 nm (G - *green*/verde) e 430 nm (B - *blue*/azul) (RUSSELL; NORVIG, 2004).

A intensidade da luz nos comprimentos de ondas do vermelho, do verde e do azul podem ser obtidas da imagem original através do uso de filtros ideais, que são representados pelas seguintes equações:

$$R = \int_{\lambda} E(\lambda) S_R(\lambda) d\lambda, \quad (2.2)$$

$$G = \int_{\lambda} E(\lambda) S_G(\lambda) d\lambda \quad (2.3)$$

e

$$B = \int_{\lambda} E(\lambda) S_B(\lambda) d\lambda, \quad (2.4)$$

onde S_R , S_G e S_B são respectivamente os filtros vermelho, verde e azul. Estes filtros fazem o papel da curva de absorção dos pigmentos presentes nos cones do olho humano. $E(\lambda)$ representa a energia luminosa e λ é o comprimento de onda (LEVINE, 1985).

A visão humana, a partir da luz filtrada com estes três filtros, constrói o que chamamos de cor. É importante ressaltar que esta é apenas uma primeira etapa da visão humana. Outras etapas, pouco compreendidas, ocorrem após esta. Disto conclui-se que para representar todas as cores vistas pelo homem bastam apenas três cores. Este modelo é chamado de modelo tricromático e foi proposto por Thomas Young em 1801 (RUSSELL; NORVIG, 2004).

A partir das equações 2.2, 2.3 e 2.4 é definido o espaço de cores RGB, onde estão representadas todas as cores visíveis pelo homem. O RGB é representado geometricamente por um cubo onde cada eixo é associado a uma das três cores. As coordenadas dos espaços de cores também são conhecidas como canais ou componentes de cores. Qualquer combinação de coordenadas neste cubo representa uma cor única.

O modelo de imagem, apresentado anteriormente, pode ser estendido para usar cores. Então, a imagem da função $f(x, y)$ será um conjunto de vetores tridimensionais pertencentes ao espaço de cores RGB. Com isto, a quantidade de *bits* necessária para armazenar a imagem

discreta resultará da equação:

$$b = 3 \times N \times M \times 2^l, \quad (2.5)$$

onde b é o tamanho da imagem em *bits*, N é a largura, M é o comprimento e cada componente do espaço de cores pode representar 2^l tons de cores. Nota-se que a imagem terá três vezes o tamanho da sua similar monocromática. Isto exige mais espaço de armazenamento e mais tempo de processamento.

O espaço de cores RGB é adequado para apresentar imagens em telas ou monitores. Entretanto, devido à correlação existente entre os três canais de cores, este modelo pode prejudicar o desempenho de um sistema de visão computacional que deve fazer distinção entre as cores. Apesar disto, vários autores adotam o RGB nos seus trabalhos e obtêm resultados adequados ao seus propósitos (SLAUGHTER; HARRELL, 1989; RUIZ et al., 1996; JING et al., 2003; JAFARI et al., 2004; STEWARD et al., 2004; DAINESE et al., 2004).

A correlação entre os canais do espaço de cores RGB podem ser minimizados ou evitados quando aplicadas transformações lineares ou não-lineares. As transformações aplicadas ao RGB originam novos espaços de cores. Estes novos espaços de cores têm características próprias, onde cada um deles apresenta vantagens e desvantagens quando usados em algum sistema de visão computacional.

A correlação existente no RGB é reduzida quando este passa por uma transformação não-linear, como a que origina o espaço de cores RGB normalizado (Nrgb). Esta transformação é feita através da normalização dos componentes do RGB. Com isto, a influência da intensidade da luz é diminuída e os componentes do Nrgb passam a representar apenas a informação cromática. As equações 2.6, 2.7 e 2.8 convertem os valores do RGB para o Nrgb (CHENG et al., 2001).

$$r = \frac{R}{R + G + B} \quad (2.6)$$

$$g = \frac{G}{R + G + B} \quad (2.7)$$

$$b = \frac{B}{R + G + B} \quad (2.8)$$

O Nrgb é adequado para aplicações que necessitam de respostas em tempo real, pois sua implementação é simples, já que ele necessita apenas de somas, adições e divisões. Entretanto, em situações de pouca iluminação, o Nrgb não tem comportamento estável.

O RGB é inspirado no primeiro estágio da visão humana, onde a energia luminosa atinge os cones e é convertida em impulsos nervosos. Outros sistemas de cores levam em conta outros estágios da visão humana. Este fato pode ajudar no desenvolvimento de sistemas de visão computacional mais robustos.

A luz, após ser captada pelos cones, é transformada em impulsos nervosos que representam a energia luminosa das cores vermelha, verde e azul. Após este processamento linear, a luz passa por uma transformação não-linear. Neste estágio a cor é analisada em pares opostos, isto é, vermelho-verde, amarelo-azul e preto-branco. Este processamento resulta na separação da parte cromática da luz da parte acromática (LEVINE, 1985).

A separação entre as porções cromática e acromática da luz é explorada em diversos espaços de cores, exemplos desses espaços são: HSI (matiz (*hue*), saturação e intensidade), HSV (matiz (*hue*), saturação e valor), YIQ, YUV, $L^*a^*b^*$ e $L^*u^*v^*$. Nestes espaços existem dois canais que caracterizam a cor e um canal que representa a intensidade da luz. A principal vantagem destes espaços de cores está no fato de que a influência da intensidade da luz nas cores é reduzida. Isto possibilita aos sistemas de visão computacional, uma forma de definir qual é a cor de um elemento mesmo que o tom da cor mude devido à iluminação (CHENG et al., 2001).

O espaço de cores HSI é bastante usado em sistemas de visão computacional devido aos fatos mencionados anteriormente. O canal de *hue* ou de matiz define o comprimento de onda dominante da cor. O canal de saturação mede a pureza da cor, ou seja, mede a quantidade de

branco misturada a esta cor. O terceiro canal mede a intensidade da luz.

O HSI é definido a partir do RGB pelas equações 2.9, 2.10 e 2.11 (CHENG et al., 2001).

$$H = \arctan \left(\frac{\sqrt{3}(G-B)}{(R-G)(R-B)} \right) \quad (2.9)$$

$$I = \frac{(R+G+B)}{3} \quad (2.10)$$

$$S = 1 - \frac{\min(R,G,B)}{I} \quad (2.11)$$

Existem algumas variações do HSI, como HSV, HSB (matiz (*hue*), saturação e brilho) e HSL (matiz (*hue*), saturação e luminosidade) (CHENG et al., 2001).

O HSI não comporta-se de forma adequada quando a saturação é baixa. Nesta situação, os algoritmos de segmentação não atribuem os *pixels* para os segmentos corretos. Isto é resultado de uma instabilidade numérica nesta região da saturação. Também em situações de baixa luminosidade, a informação cromática passa a não ter importância. Conseqüentemente, os valores de H e S não representam as cores de forma adequada (CHENG et al., 2001).

Uma forma de evitar a instabilidade numérica é usar uma transformação linear. Os espaços de cores YIQ, YUV, YCbCr e outros são transformações lineares do RGB. Semelhantemente ao espaço de cores HSI, a parte cromática é separada da acromática. Também, a correlação entre os componentes é menor. Obter estes espaços de cores a partir do RGB é computacionalmente rápido devido à transformação linear como a dada pela equação 2.12, a seguir:

$$\begin{pmatrix} Y \\ I \\ Q \end{pmatrix} = \begin{pmatrix} 0,299 & 0,587 & 0,144 \\ 0,596 & -0,274 & -0,322 \\ 0,211 & -0,523 & 0,312 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (2.12)$$

onde, Y representa a intensidade da luz, I representa a diferença laranja-ciano e Q é a diferença verde-magenta. Este espaço de cores tira proveito do fato de que a maioria das cores em cenas

tem coeficientes cromáticos próximos ao ponto de branco. Devido a isto, a largura de banda necessária para a transmissão de um sinal contendo o YIQ é menor. O YIQ é usado pelo NTSC (*National Television System Commission*, Estados Unidos da América (EUA)) (LEVINE, 1985).

O YUV é o espaço de cores adotado no sistema de televisão europeu. A equação 2.13 é a transformação do RGB para o YUV (CHENG et al., 2001).

$$\begin{pmatrix} Y \\ U \\ V \end{pmatrix} = \begin{pmatrix} 0,299 & 0,587 & 0,144 \\ -0,147 & -0,289 & 0,437 \\ 0,615 & -0,515 & -0,100 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (2.13)$$

A transformação do espaço de cores RGB para o YCbCr é feita pela equação 2.14 (MANJUNATH et al., 2001).

$$\begin{pmatrix} Y \\ Cb \\ Cr \end{pmatrix} = \begin{pmatrix} 0,299 & 0,587 & 0,144 \\ -0,169 & -0,331 & 0,500 \\ 0,500 & -0,419 & -0,081 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (2.14)$$

Com o objetivo de desenvolver um espaço de cores perceptualmente uniforme e que atende às necessidades psicofísicas do homem, a CIE (*Commission Internationale de l'Eclairage*) desenvolveu os espaços de cores $L^*a^*b^*$ e $L^*u^*v^*$. Entende-se por espaço de cores perceptualmente uniforme, o espaço de cores onde a distância entre duas cores representa a diferença percebida pelo cérebro humano entre estas duas cores (CHENG et al., 2001; LUCCHESI; MITRA, 2001).

Para obter-se os valores do $L^*a^*b^*$ e $L^*u^*v^*$ é necessário converter o espaço RGB para o XYZ através da equação 2.15, que foi estabelecida pelo NTSC (CHENG et al., 2001).

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} 0,607 & 0,174 & 0,200 \\ 0,299 & 0,587 & 0,114 \\ 0,000 & 0,066 & 1,116 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (2.15)$$

Então, as equações 2.16, 2.17 e 2.18 convertem as cores do XYZ para o $L^*a^*b^*$, onde $\frac{Y}{Y_0} > 0,01$, $\frac{X}{X_0} > 0,01$, $\frac{Z}{Z_0} > 0,01$ e (X_0, Y_0, Z_0) é o branco padrão.

$$L^* = 116 \left(\sqrt[3]{\frac{Y}{Y_0}} \right) - 16 \quad (2.16)$$

$$a^* = 500 \left[\sqrt[3]{\frac{X}{X_0}} - \sqrt[3]{\frac{Y}{Y_0}} \right] \quad (2.17)$$

$$b^* = 200 \left[\sqrt[3]{\frac{Y}{Y_0}} - \sqrt[3]{\frac{Z}{Z_0}} \right] \quad (2.18)$$

As equações 2.19, 2.20 e 2.21 convertem XYZ para o $L^*u^*v^*$, onde $\frac{Y}{Y_0} > 0,01$, (Y_0, u_0, v_0) é o branco padrão e os valores de u' e v' são calculados pelas equações 2.22 e 2.23, respectivamente.

$$L^* = 116 \left(\sqrt[3]{\frac{Y}{Y_0}} \right) - 16 \quad (2.19)$$

$$u^* = 13L^* (u' - u_0) \quad (2.20)$$

$$v^* = 13L^* (v' - v_0) \quad (2.21)$$

$$u' = \frac{4X}{X + 15Y + 3Z} \quad (2.22)$$

$$v' = \frac{6Y}{X + 15Y + 3Z} \quad (2.23)$$

Nestes espaços é possível calcular a distância entre duas cores com a equação 2.24 no caso do $L^*a^*b^*$ e com a equação 2.25 no caso do $L^*u^*v^*$.

$$\Delta E_{ab} = \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2} \quad (2.24)$$

$$\Delta E_{uv} = \sqrt{(\Delta L^*)^2 + (\Delta u^*)^2 + (\Delta v^*)^2} \quad (2.25)$$

O fato de usar a distância euclidiana para calcular a diferença entre duas cores pode contribuir para o funcionamento adequado dos algoritmos de segmentação (LEVINE, 1985; CHENG et al., 2001; LUCCHESI; MITRA, 2001). Entretanto, devido à transformação não-linear, tanto o $L^*a^*b^*$ quanto o $L^*u^*v^*$ possuem singularidade não removível¹.

Trabalhos que utilizam imagens coloridas em visão computacional

A seguir são descritos alguns trabalhos que utilizam imagens coloridas. Estes trabalhos são exemplos de aplicações da visão computacional que não estão ligadas à área agrícola (os trabalhos sobre visão computacional aplicada à agricultura serão revisados em outro capítulo).

Devido à grande variedade de representações das cores, é natural que cada autor escolha um ou mais espaços de cores, com o objetivo de avaliá-los.

A cor pode ser usada para definir as fronteiras entre regiões de uma imagem, além de caracterizar um elemento na imagem. Este fato é muito explorado por algoritmos de segmentação. O algoritmo de segmentação de imagens desenvolvido por Jing et al. (2003) utiliza o RGB. Este algoritmo foi baseado no algoritmo desenvolvido por Deng, Manjunath e Shin (1999). Ambos os algoritmos consideram tanto a informação cromática como a espacial. Também foram consideradas diferentes escalas da imagem, o que contribui com a segmentação de imagens com texturas. Os autores afirmaram ter obtido resultados adequados com estes algoritmos.

O uso de mapas auto-organizáveis (SOM - *self-organizing maps*) juntamente com características extraídas dos *pixels* de uma imagem foi explorado por Moreira e Costa (1996) em uma

¹Entende-se como singularidade, os pontos não definidos pelas equações de transformação dos espaços de cores.

aplicação de segmentação de imagens. O espaço de cores Nrgb foi adotado, pois o predicado de homogeneidade considera apenas a informação cromática. Os *pixels* semelhantes foram agrupados por um processo que envolveu duas etapas. Primeiro a informação cromática dos *pixels* foi reorganizada em um espaço bidimensional com uma rede de Kohonen. Através desta técnica os autores viabilizaram o agrupamento dos *pixels* com cores semelhantes. Na segunda etapa, a classificação dos *pixels* foi feita através de um algoritmo que identifica os agrupamentos. O algoritmo inicialmente cria dois grupos, então uma métrica de qualidade é calculada para cada grupo, caso a qualidade de um grupo não seja aceitável, este é dividido. Após este processo, cada *pixel* recebe uma etiqueta que identifica a qual grupo ele pertence, o que origina a imagem segmentada.

O espaço de cores HSV pode ser adotado para criar descritores de uma imagem ou de uma região de interesse. Isto é feito utilizando-se métodos que geram vetores que descrevem a cor ou as cores presentes nesta região. Um destes métodos usa os valores das categorias do histograma. Manjunath et al. (2001) descreveram as normas candidatas ao padrão MPEG-7. Uma destas normas utiliza os histogramas das componentes do HSV para descrever imagens ou trechos de filmes (SCD - *Scalable color descriptor*). Outro descritor apresentado neste trabalho utiliza o YCbCr para representar a distribuição espacial das cores na imagem (CLD - *Color layout descriptor*). Os descritores candidatos a fazerem parte do MPEG-7 foram submetidos a vários testes com o objetivo de garantir que são adequados.

A cor de uma região em uma imagem pode ser usada para criar informações com maior valor semântico. Sistemas de recuperação de imagens fazem uso disto para melhorar a taxa de acerto na recuperação de imagens. Liu et al. (2005) usaram os valores médios dos componentes do espaço de cores HSV para nomear a cor de uma região na imagem. A componente *H* origina o nome da cor. As componentes *S* e *V* originam os adjetivos dos nomes das cores. Os autores reportam que tal abordagem é promissora para melhorar a busca de imagens.

Os espaços de cores YUV, YQQ e RGB foram comparados por Littmann e Ritter (1997), onde os autores utilizaram métodos estatísticos e RNA para segmentar imagens de mãos. A

posição e a postura das mãos foram usadas para melhorar a interação homem-máquina. Foi observado que ambos os classificadores tiveram melhor desempenho quando usado o espaço de cores RGB.

2.1.2 Pré-processamento

O pré-processamento é parte fundamental no processamento de imagens, pois ele é o responsável pelas operações de realce e de restauração. Gonzalez e Wintz (1987) afirmaram que tais operações podem ser dependentes da aplicação. Devido a isto, nesta seção serão apresentadas as operações comuns de pré-processamento e ao final da seção, um destes algoritmos será apresentado.

As operações de realce da imagem são aquelas onde a imagem é transformada de tal forma a obter-se uma imagem mais adequada para uma aplicação específica. Estas operações podem ser feitas no domínio espacial ou no domínio das frequências.

As operações espaciais globais são aquelas que consideram alguma característica inerente à imagem inteira. O algoritmo pode, devido às influências do restante da imagem, descaracterizar de alguma forma as regiões menos significativas. Isto não ocorre se a imagem for uniforme para as características relevantes.

As técnicas de alteração de histograma são um exemplo de operação global. Estas técnicas consideram a distribuição estatística dos valores dos *pixels*. A distribuição destes valores pode ser alterada com o objetivo de melhorar a qualidade da imagem. Para isto, o histograma é gerado e as categorias do histograma são re-arranjadas. Os valores dos *pixels* da imagem original são alterados de forma a refletir o novo arranjo.

Quando devem ser consideradas pequenas regiões é necessário usar operações que utilizam a informação local, ou seja, uma pequena região ao redor do *pixel* a ser manipulado. Os algoritmos utilizados nas operações locais podem ser implementados de forma paralela, pois a manipulação de um *pixel* não depende de um outro *pixel* alterado.

As operações que ocorrem no domínio das frequências podem usar a transformada de Fou-

rier. A imagem transformada é multiplicada pela função de transferência, que é um filtro de frequências. A transformada inversa é aplicada ao resultado da multiplicação, o que resulta na nova imagem. Existem diversas funções de transferência, como, por exemplo, o filtro ideal passa-baixa (ILPF - *ideal lowpass filter*).

As operações apresentadas anteriormente buscam recuperar informações que foram degradadas de forma desconhecida durante a aquisição da imagem, ou seja, não é possível obter-se a informação original; obtém-se somente uma aproximação. Por outro lado, se o processo de degradação é conhecido, é possível utilizar isto para restaurar a imagem original (GONZALEZ; WINTZ, 1987).

As operações de pré-processamento mais adequadas no contexto deste trabalho são as operações de realce locais, pois as imagens de cenas naturais são degradadas de formas variadas, já que não é possível controlar os fatores naturais. Também estas imagens são compostas por regiões com características variadas, como por exemplo regiões claras ou escuras, regiões com ou sem texturas etc. Por isto, é necessário utilizar um algoritmo que considere de forma adequada cada uma das regiões da imagem; regiões de bordas (mudança de intensidade de luz, de cor ou de textura), de texturas, ou com cor homogênea devem ser tratadas de forma a não serem descaracterizadas.

Operações locais no domínio espacial

As operações espaciais manipulam diretamente os *pixels* da imagem. Estas operações podem ser definidas pela seguinte função:

$$g(x,y) = T[f(x,y)] \quad (2.26)$$

onde $f(x,y)$ é a imagem de entrada, $g(x,y)$ é a imagem processada e T é o operador em f definido em uma vizinhança de (x,y) . A vizinhança de (x,y) normalmente é uma região quadrada, onde o *pixel* central desta região é o *pixel* na posição (x,y) . Além das vizinhanças quadradas, existem também vizinhanças circulares e retangulares.

As funções T mais simples são aquelas onde a vizinhança tem tamanho 1×1 *pixel*. Nestas funções apenas o *pixel* a ser alterado é considerado. As vizinhanças com dimensões maiores que 1×1 *pixels* são conhecidas por janelas, máscaras ou filtros.

Como T é uma função que analisa os *pixels* ao redor de (x, y) , então é possível definir T como sendo a soma ponderada dos *pixels* pertencentes à máscara. Devido a isto, é atribuído um peso a cada elemento da máscara, como ilustrado na Figura 2. Então, a função T é definida como a equação 2.27. O resultado desta soma é atribuído ao *pixel* em (x, y) na nova imagem.

$w_1 f(x-1, y-1)$	$w_2 f(x-1, y)$	$w_3 f(x-1, y+1)$
$w_4 f(x, y-1)$	$w_5 f(x, y)$	$w_6 f(x, y+1)$
$w_7 f(x+1, y-1)$	$w_8 f(x+1, y)$	$w_9 f(x+1, y+1)$

Figura 2: Exemplo de janela em uma região com 3×3 *pixels*.

$$\begin{aligned}
 T[f(x, y)] = & w_1 f(x-1, y-1) + w_2 f(x-1, y) + w_3 f(x-1, y+1) + \\
 & w_4 f(x, y-1) + w_5 f(x, y) + w_6 f(x, y+1) + \\
 & w_7 f(x+1, y-1) + w_8 f(x+1, y) + w_9 f(x+1, y+1)
 \end{aligned} \tag{2.27}$$

Uma imagem degradada por ruído pode ser melhorada através de uma técnica de suavização. Isto pode ser obtido considerando-se uma pequena região da imagem, onde o valor médio dos *pixels* nesta região será o novo valor do *pixel* central. Para uma vizinhança quadrada com 3×3 *pixels*, isto pode ser obtido com a equação 2.27, onde $w_i = \frac{1}{9}, i = 1, \dots, 9$. A suavização pode considerar uma vizinhança maior, o que resulta em uma imagem mais borrada.

Quando uma imagem é suavizada de forma uniforme, os contornos dos elementos desta imagem ficam borrados. Para evitar este problema, deve-se adotar um limiar. Se a diferença

entre o *pixel* central e o valor médio da região for maior que o limiar é provável que o *pixel* pertença a uma região de borda. O uso do limiar tem o inconveniente de necessitar de testes para obter-se um valor adequado.

Os *pixels* pertencentes à máscara podem ser considerados de forma não-linear. Isto ocorre quando é adotado o filtro mediano. Os *pixels* na vizinhança são ordenados em ordem crescente e o valor que estiver na posição central será o novo valor do *pixel*. Este método não interfere tanto nas bordas e ainda suaviza a imagem sem a necessidade de um limiar (GONZALEZ; WINTZ, 1987).

Além dos exemplos de filtros apresentados, é possível desenvolver novos filtros utilizando os conceitos apresentados anteriormente. Por exemplo, outros pesos podem ser adotados para a máscara, pesos que consideram os *pixels* de forma diferente da que foi exemplificada. Também é possível avaliar os *pixels* de forma não-linear, através de uma equação ou de um algoritmo mais elaborado.

Deng et al. (1999) propuseram um algoritmo, chamado *peer group filtering* (PGF) para suavizar e remover ruídos das imagens. O algoritmo proposto busca o valor adequado de um *pixel* sem prejudicar os contornos. Para isto, foi apresentada uma heurística que identifica se o *pixel* é ruído ou não. Caso o *pixel* seja considerado ruído, o valor real é estimado. Caso não seja ruído, o valor do *pixel* suavizado é calculado com base nos vizinhos mais semelhantes a ele. O algoritmo é detalhado abaixo.

Seja $x_0(n)$ um vetor contendo um *pixel* da imagem. Este vetor representa a cor do *pixel* no ponto n centrado na janela com dimensões $w \times w$. Os *pixels* nesta janela, inclusive o *pixel* n , são organizados em ordem crescente segundo a distância entre ele e $x_0(n)$. Para isto é usada a distância euclidiana (eq. 2.28). Estes *pixels* são chamados de $x_i(n)$ com $i = 0, \dots, k$ e $k = w^2 - 1$, respeitando-se a ordem crescente.

$$d_i(n) = \|x_0(n) - x_i(n)\|, i = 0, \dots, k \quad (2.28)$$

O *peer group* $P(n)$ de tamanho $m(n)$ é definido por 2.29.

$$P(n) = \{x_i(n), i = 0, \dots, m(n) - 1\} \quad (2.29)$$

O $P(n)$ é usado para estimar o novo valor do *pixel*. Para isto, o valor de corte, ou seja, o $m(n)$, deve ser definido. O valor de corte é usado para evitar que regiões de bordas sejam descaracterizadas. Adotar um valor fixo não é adequado, pois as características de cada região da imagem são diferentes. A solução adotada pelos autores é utilizar análise de grupos. O método adotado encontra dois grupos, um deles contendo o $x_0(n)$. Caso existam mais que dois grupos, um grupo sempre conterá o $x_0(n)$ e os outros grupos são unidos em um único grupo. Os grupos são formados considerando-se as distâncias $d_i(n)$. Este procedimento é feito maximizando-se

$$J(i) = \frac{|a_1(i) - a_2(i)|^2}{s_1^2(i) + s_2^2(i)}, i = 1, \dots, k, \quad (2.30)$$

onde

$$a_1(i) = \frac{1}{i} \sum_{j=0}^{i-1} d_j(n), \quad (2.31)$$

$$a_2(i) = \frac{1}{k+1-i} \sum_{j=i}^k d_j(n), \quad (2.32)$$

$$s_1^2(i) = \sum_{j=0}^{i-1} |d_j(n) - a_1(i)|^2 \quad (2.33)$$

e

$$s_2^2(i) = \sum_{j=i}^k |d_j(n) - a_2(i)|^2. \quad (2.34)$$

Então, o valor de corte é:

$$m(n) = \arg \max J(i). \quad (2.35)$$

Os elementos em $P(n)$ são testados para que os elementos considerados ruídos sejam removidos. Primeiro são calculadas as diferenças de primeira ordem com a equação 2.36.

$$f_i(n) = d_{i+1}(n) - d_i(n) \quad (2.36)$$

Depois são testados os M primeiros e últimos $x_i(n)$ com a equação 2.37, onde $M = \frac{w}{2}$ e α assumem valores altos para imagens muito corrompidas e valores baixos para imagens pouco corrompidas.

$$f_i(n) \leq \alpha \quad (2.37)$$

Se a condição da equação 2.37 não for satisfeita, os $x_i(n)$ correspondentes são removidos. Os demais elementos em $P(n)$ são usados para estimar o *peer group* verdadeiro.

O valor real de $x_0(n)$ é estimado com o *peer group* verdadeiro. O *pixel* de $x_0(n)$ é substituído pela soma ponderada dos *pixels* pertencentes ao *peer group*. Para isto, é usada a equação 2.38, onde os valores de w_i são os pesos gaussianos padrão que dependem da posição de $p_i(n)$ com relação a $x_0(n)$.

$$x_{real}(n) = \frac{\sum_{i=0}^{m(n)-1} w_i p_i(m)}{\sum_{i=0}^{m(n)-1} w_i}, p_i(n) \in P(n) \quad (2.38)$$

Os autores do PGF testaram este algoritmo em imagens corrompidas com ruído aleatório. O espaço de cores utilizado nos testes foi o RGB. Com o objetivo de verificar o desempenho do PGF com relação a outros algoritmos, foram feitas comparações com o *vector median filtering* (ASTOLA; HAAVISTO; NEUVO, 1990) e o *teager-operator method* (CHEIKH et al., 1996). Os parâmetros dos algoritmos foram setados de tal forma a obter-se a melhor imagem. Os filtros foram comparados utilizando-se o valor da relação sinal-ruído. Os testes revelaram que o PGF teve melhor desempenho que os outros filtros.

Filtros podem ser usados para outros objetivos, além de melhorar a qualidade da imagem. É possível utilizar esta técnica para fazer detecção de características (linhas retas, curvas, texturas, bordas). Destas características, a que mais se destaca é a detecção de bordas, pois esta pode ser

aplicada em muitas situações.

A detecção de bordas é considerada a abordagem mais comum para detectar discontinuidades em imagens em tons de cinza. Um pré-requisito para o uso desta técnica é a existência de regiões homogêneas com tons de cinza distintos. Existem generalizações desta técnica, onde também é possível utilizar as cores. Estas técnicas de detecção de bordas podem ser utilizadas na segmentação de imagens.

A abordagem utilizada por vários detectores de bordas é o cálculo do gradiente. Considerando um perfil da imagem, onde o tom de cinza representa a altura, a descontinuidade vai ser caracterizada pela mudança de altura do perfil. O valor resultante do cálculo da primeira derivada será zero, quando a altura for constante. Quando houver uma mudança de altura, o valor será diferente de zero. O sinal da segunda derivada indica se a transição está indo de uma região mais alta para uma mais baixa ou o inverso.

O valor da primeira derivada pode ser obtido em qualquer ponto da imagem com o cálculo do gradiente. Devem ser calculados dois gradientes, o horizontal e o vertical. Destes dois valores, a magnitude é calculada com a equação 2.39, que representa a presença ou não de bordas. É possível fazer uma aproximação da magnitude com a equação 2.40. G_x é o gradiente na vertical, G_y é o gradiente na horizontal e $G[.]$ é a magnitude do gradiente.

$$G[f(x,y)] = \sqrt{(G_x^2 + G_y^2)} \quad (2.39)$$

$$G[f(x,y)] = |G_x| + |G_y| \quad (2.40)$$

Os gradientes G_x e G_y podem ser aproximados com o uso de uma máscara, da mesma forma que foi feito na suavização da imagem. O operador de Sobel utiliza máscaras com 3×3 pixels. A Figura 3 mostra as duas máscaras do operador de Sobel (GONZALEZ; WINTZ, 1987).

Conhecer a localização das bordas em uma imagem é uma boa indicação das fronteiras dos elementos desta imagem. Entretanto, é necessário realizar outras operações para obter-se a

$$G_x = \begin{bmatrix} -f(x-1,y-1) & -2f(x-1,y) & -f(x-1,y+1) \\ 0 & 0 & 0 \\ f(x+1,y-1) & 2f(x+1,y) & f(x+1,y+1) \end{bmatrix} \quad G_y = \begin{bmatrix} -f(x-1,y-1) & 0 & f(x-1,y+1) \\ -2f(x,y-1) & 0 & 2f(x,y+1) \\ -f(x+1,y-1) & 0 & f(x+1,y+1) \end{bmatrix}$$

Figura 3: Máscaras usadas no Operador de Sobel.

segmentação da imagem.

2.1.3 Segmentação

Segmentação de imagens é uma etapa importante dentre as existentes em um sistema de visão computacional. Isto fica evidente quando Cheng et al. (2001), citando Spirkovska (1993), afirma que:

“Segmentação de imagens é a ponte na visão computacional entre os sub-sistemas de visão de baixo nível, que inclui as operações de processamento de imagens (como redução de ruídos e extração de bordas) para melhorar a imagem de entrada, e o sub-sistema de alto-nível que inclui reconhecimento de objetos e interpretação de cena.”

A ligação entre estes dois sub-sistemas é feita na segmentação de imagens (Figura 4), pois é neste momento que os elementos, ou objetos, presentes na cena são separados do resto da imagem. Então, as informações pertinentes a estes elementos são extraídas para serem usadas nas etapas seguintes. A correta segmentação de um elementos é importante, pois informações inexatas prejudicam as próximas etapas. Um elemento com o contorno mal traçado pode prejudicar um algoritmo que reconhece formas.

Os elementos podem ser extraídos da imagem pois existem descontinuidades entre eles e o resto da cena, ou seja, existe uma mudança nas propriedades dos *pixels* entre estas regiões. Também é possível particionar a imagem em regiões homogêneas com respeito a um conjunto de propriedades, onde estas propriedades são semelhantes em cada partição e diferentes entre as partições. Estas duas abordagens são equivalentes (LUCCHESI; MITRA, 2001). Segmentação

Figura 4: Segmentação de imagens é a ponte entre os sub-sistemas de visão computacional.

de imagens pode ser definida formalmente da seguinte maneira (CHENG et al., 2001): Seja $P()$ um predicado de homogeneidade definido sobre um grupo de *pixels* conectados. Segmentação é particionar um conjunto F em subconjuntos conectados $(S_1, S_2, \dots, S_n)$, tal que

$$\bigcup_{i=1}^n S_i = F \text{ com } S_i \cap S_j = \emptyset \text{ e } (i \neq j). \quad (2.41)$$

A Figura 5 mostra isto.

Figura 5: Conjunto F particionado em sub-conjuntos conectados.

O predicado de homogeneidade $P(S_i) = \text{verdadeiro}$ para todas as regiões e $P(S_i \cup S_j) = \text{falso}$ quando $i \neq j$ e S_i e S_j são vizinhos.

As regiões obtidas com o algoritmo de segmentação podem ser coerentes segundo o pre-

dicado $P(\cdot)$, entretanto isto não implica que as regiões tenham algum significado para um observador humano ou para algum sistema de visão computacional. Devido a isto, as escolhas do algoritmo de segmentação e da forma de avaliação deste são complexas. Nem todos os algoritmos são adequados para uma imagem e nem todas as imagens são segmentadas adequadamente por um mesmo algoritmo (PAL; PAL, 1993).

A escolha ou desenvolvimento de um algoritmo de segmentação pode ser simplificada quando é considerado um universo específico de imagens. Características comuns a estas imagens podem ser usadas no predicado de homogeneidade por um algoritmo, ou seja, o conhecimento adquirido pelo homem pode ser usado, o que resultará em um algoritmo adequado e mais simples. Entretanto, mesmo esta abordagem pode apresentar muitos desafios para o desenvolvedor. Isto ocorre quando não é possível abstrair das imagens um modelo adequado.

Cada sistema de visão computacional opera em um domínio de imagens. Alguns destes domínios contém imagens mais simples do ponto de vista da segmentação. Imagens mais simples são aquelas originadas de cenas em ambientes controlados ou em ambientes com uma estrutura bem definida, como por exemplo ambientes onde iluminação e as posições dos elementos são conhecidos. A complexidade da imagem aumenta quando surgem texturas, reflexos, sombras, cores não homogêneas, iluminação não constante etc. Ao considerar-se um algoritmo é necessário ponderar todos estes fatores.

Algoritmos de segmentação de imagens em tons de cinza utilizam o valor do *pixel*, ou algum valor derivado deste como predicado. Também é possível considerar a textura formada por estes *pixels*. A segmentação de imagens coloridas pode utilizar a cor como critério de homogeneidade, sendo que a cor pode ser representada em qualquer um dos espaços de cores. Também é possível considerar a textura em imagens coloridas.

O algoritmo de segmentação deve criar regiões ou segmentos de forma que o predicado seja verdadeiro. Da mesma forma que na escolha do predicado, a técnica empregada para formar os segmentos é dependente da aplicação. Algumas destas técnicas são específicas, outras foram desenvolvidas para vários tipos de imagens. Apesar das dificuldades inerentes ao assunto, os

autores reportam bons resultados para ambos os casos.

Tipos de algoritmos de segmentação

Os autores de revisões sobre segmentação de imagens propõem diversas classificações para os algoritmos de segmentação. Eles são classificados considerando-se a técnica usada para criar os segmentos. O uso de várias técnicas em um mesmo algoritmo é comum, o que dificulta a classificação adequada.

Como neste trabalho existe um interesse particular em segmentação de imagens coloridas, as classes de algoritmos apresentadas estão restritas às citadas nos trabalhos de revisão da área. Mais informações sobre segmentação de outros tipos de imagens, como por exemplo imagens de distâncias (*range images*) e imagens de ressonância magnética, podem ser encontradas em (PAL; PAL, 1993), onde são apresentadas outras revisões e os respectivos métodos de classificação dos algoritmos.

Cheng et al. (2001) classificam os algoritmos de segmentação na seguinte forma:

- **Baseados em limiarização de histogramas** - Esta técnica é muito usada em imagens em tons de cinza, quando as regiões da imagem se distinguem claramente. Os algoritmos que usam esta técnica buscam por vales e picos nos histogramas com o objetivo de encontrar um ou mais limiares que definam as regiões da imagem. Em imagens coloridas é possível calcular o histograma tridimensional, embora esta técnica exija muita capacidade computacional. Alguns trabalhos buscam alternativas a isto, como por exemplo calcular os histogramas das três componentes separadamente;
- **Baseados na formação de agrupamentos no espaço de características** - Nesta classe, o espaço de características normalmente usado é o espaço de cores. Como somente a informação cromática é considerada, esta classe de algoritmos exige que a imagem seja formada por regiões com cores uniformes. Utilizando técnicas de análise de agrupamentos, o algoritmo de segmentação agrupa as cores semelhantes, então os *pixels* de um mesmo

grupo recebem a mesma etiqueta, o que caracteriza um segmento. Podem ser utilizadas tanto técnicas supervisionadas como não supervisionadas. Exemplo de técnicas supervisionadas são k -vizinhos mais próximos, perceptron multicamadas etc. As técnicas não supervisionadas são k -médias, FCM (*fuzzy c-means* – c-médias nebuloso) etc. Uma das dificuldades impostas no uso de algoritmos não supervisionados é determinar o número de agrupamentos;

- **Baseados em regiões** - Estes algoritmos consideram a disposição espacial dos *pixels*. Imagens com cores não uniformes ou texturas podem ser melhor segmentadas com estes algoritmos. Os métodos usados pelos algoritmos desta classe são: crescimento de regiões, divisão de regiões e fusão de regiões. Também é possível adotar uma combinação destes métodos. No crescimento de região, o algoritmo seleciona uma semente para a nova região, ou seja, um *pixel* ou uma região pequena. A região crescerá a partir desta semente agrupando os *pixels* que satisfazem um critério previamente adotado. O desenvolvedor do algoritmo de segmentação deverá escolher as sementes e, também, a sequência de avaliação dos *pixels*. Os algoritmos de divisão de regiões adotam como estratégia particionar as regiões não homogêneas em regiões menores, até que as regiões sejam homogêneas. Esta abordagem tende a gerar regiões com forma semelhante a usada para particionar as regiões. A técnica de fusão de regiões é usada em conjunto com as demais técnicas para juntar duas regiões semelhantes segundo algum critério. Todas estas técnicas tem natureza sequencial, logo são computacionalmente mais caras;
- **Baseados em detecção de bordas** - A detecção de bordas não segmenta a imagem, ela apenas fornece informações para determinar onde estão as fronteiras entre as regiões. Para segmentar a imagem, por exemplo, é possível utilizar as bordas em conjunto com um algoritmo de crescimento de regiões. Existem duas abordagens para a detecção de bordas: a paralela (apresentada anteriormente neste trabalho), onde o fato de um conjunto de *pixels* pertencer a uma borda não influencia se os demais *pixels* devem ou não pertencer a uma borda, e a sequencial, onde o fato de um *pixel* pertencer a borda influencia os demais. Na abordagem sequencial são utilizadas busca heurística e programação dinâmica. O

resultado final depende da escolha de um ponto inicial adequado. Também, a escolha de um critério de parada é difícil. Existem diferentes abordagens para utilizar a informação cromática juntamente com a detecção de bordas. As bordas podem ser definidas como descontinuidades no espaço tridimensional. Também é possível definir borda como uma descontinuidade de uma distância métrica de cores. Outra possibilidade seria extrair as bordas de cada uma das imagens dos componentes de cores e fundir esta informação segundo algum critério;

- **Baseados em lógica nebulosa** - A teoria dos conjuntos nebulosos é uma ferramenta para manipular incertezas e ambigüidades. Diversos autores exploram esta capacidade ao inserir estes conceitos em algoritmos já conhecidos, como por exemplo a versão nebulosa do c-médias, o FCM. A abordagem nebulosa é motivada pelo fato que utilizando estas técnicas é possível reter mais informações para as próximas etapas de processamento, já que uma decisão rígida é evitada;
- **Baseados em rede neurais artificiais (RNA)** - As RNA são estruturas inspiradas nos sistemas nervosos. Adquirem conhecimento através de treinamento, diferentemente da abordagem convencional que usa algoritmos. O treinamento é feito com um conjunto de exemplos, os quais podem ser previamente classificados ou não. O tempo de treinamento é dependente do problema e pode ser demasiado longo. Duas características importantes das RNA são: sua tolerância a ruídos e a alta velocidade de processamento. Existem diferentes arquiteturas de RNA, cada uma delas podendo ser usada para implementar alguma das estratégias de segmentação já conhecidas. Por exemplo, é possível utilizar rede de Kohonen para agrupar cores semelhantes. Também podem ser usadas redes de Hopfield para minimizar um critério e segmentar a imagem. RNA's que são treinadas de forma supervisionada também podem ser usadas, como o perceptron multicamadas. Eegmont-Petersen, Ridder e Handels (2002) fizeram uma revisão das técnicas de processamento de imagens que usam RNA, inclusive as técnicas de segmentação;
- **Baseados na física** - As propriedades da luz refletida por um objeto estão relacionadas

com o material usado na construção do objeto e a fonte de luz. Com estas informações é possível criar um modelo deste fenômeno. Estes modelos são capazes de localizar as bordas dos objetos, eliminar a influência das sombras e dos reflexos. Os dois modelos mais comuns são o modelo dicromático de reflexão e o modelo aproximado de reflexão cromática. Os algoritmos de segmentação de imagens que usam estes modelos são baseados em técnicas como detecção de bordas e agrupamentos, só que não no espaço de cores e sim numa imagem processada com o modelo físico adotado. O uso destas técnicas é limitado a imagens onde as propriedades reflexivas dos materiais são conhecidas e fáceis de modelar.

Os algoritmos de segmentação foram classificados de modo semelhante por Lucchese e Mitra (2001). Entretanto os autores dividiram os algoritmos em três grandes grupos e então em grupos menores. A seguir é apresentado o esquema de classificação proposto.

Tabela 1: Tipos de algoritmos de segmentação segundo Lucchese e Mitra (2001).

Baseado em espaço de características <ul style="list-style-type: none">• Agrupamento• K-médias adaptativo• Limiarização de histograma
Baseado no domínio da imagem <ul style="list-style-type: none">• Dividir e agrupar• Crescimento de região• Bordas• Redes neurais artificiais
Baseado na física

Os autores deste esquema de classificação apresentam a classe de algoritmos “ k -médias adaptativo”, onde são classificados os algoritmos que usam o k -médias juntamente com infor-

mação espacial local para criar uma segmentação mais uniforme. Estes algoritmos são considerados como uma classe que está situada entre os algoritmos baseados em espaço de características e os algoritmos baseados no domínio da imagem.

A sub classe “redes neurais” foi colocada na classe “baseado no domínio da imagem” para destacar as RNA que usam a informação espacial de forma diferente das demais classes. Estas RNA não se agrupam em nenhuma das demais classes pois não implementam nenhuma das técnicas convencionais de segmentação.

A classe dos algoritmos iterativos não é apresentada por Cheng et al. (2001) e por Lucchese e Mitra (2001). Nesta classe de algoritmos podem ser utilizadas técnicas de relaxamento estatístico ou nebuloso, modelos de interação espacial, como os campos aleatórios de Markov e de Gibbs e, também, podem ser usadas RNA. Uma característica importante destes algoritmos é que eles consideram a disposição espacial dos *pixels*. Também, os algoritmos iterativos tem natureza paralela, devido ao modo como os *pixels* são avaliados a cada iteração (PAL; PAL, 1993).

Neste trabalho é adotado um esquema de classificação semelhante ao adotado por Lucchese e Mitra (2001). Os algoritmos que lidam somente com agrupamento de características são agrupados em “algoritmo de segmentação baseados em característica”. Os algoritmos que consideram a disposição espacial dos *pixels* são agrupados em “algoritmos de segmentação baseados em regiões”. Os algoritmos de segmentação baseados em física não são considerados neste trabalho, pois a técnica é dependente de variáveis que não podem ser facilmente controladas em um ambiente ao ar livre, como o ambiente agrícola.

O contexto das imagens agrícolas exige o uso de algoritmos que foram projetados para segmentar imagens de cenas naturais. Na literatura sobre segmentação de imagens são apresentados diversos algoritmos que segmentam tais imagens. Os autores que desenvolvem estes algoritmos têm como objetivo avaliar novas abordagens, ou, no caso mais prático, desenvolver algoritmos que são usados em alguma aplicação, como os sistemas de recuperação de imagens baseada em regiões (RBIR – *Region-based image retrieval*) (PARK; LEE; KIM, 2004; LIU; ZHOU,

2004; LIU et al., 2005). Isto torna estes algoritmos adequados no contexto deste trabalho.

Avaliação da segmentação de imagens

Dentre as muitas dificuldades encontradas em segmentação de imagens, uma delas é a avaliação dos algoritmos de segmentação e conseqüentemente a avaliação dos resultados produzidos por estes. Como não existe uma teoria geral de segmentação, a pesquisa e o uso de métodos de avaliação são importantes, pois somente assim é possível determinar se determinados algoritmos desenvolvidos são melhores ou piores que outros (ZHANG, 1996).

Zhang (1996) aponta que pouca importância foi dada à avaliação, pois as pesquisas concentravam-se apenas no desenvolvimento de novos algoritmos de segmentação, entretanto, a avaliação subjetiva era feita em alguns casos. Em outro trabalho realizado anos depois pelo mesmo autor, foi constatado que os desenvolvedores de algoritmos de segmentação estavam dando mais atenção para a avaliação destes algoritmos (ZHANG, 2001).

A abordagem subjetiva, através da inspeção manual da imagem segmentada, avalia se os segmentos são coerentes com a imagem. Este método não pode ser usado para avaliar de forma comparativa dois algoritmos diferentes, já que está sujeito a falha humana. Este método de avaliação foi usado em alguns trabalhos (DENG; MANJUNATH; SHIN, 1999; WEI, 2002; JING et al., 2003; CHEN et al., 2005).

Os métodos objetivos de avaliação dos algoritmos de segmentação podem ser divididos em duas categorias: a analítica e a empírica (ZHANG, 1996).

A avaliação analítica do algoritmo considera o algoritmo propriamente dito. O algoritmo é analisado com relação a sua complexidade, propriedades, princípios etc. Entretanto, este método não avalia todas as propriedades do algoritmo, como a acurácia e a precisão da segmentação, que são propriedades importantes para as aplicações. Mas, com a avaliação analítica do algoritmo é possível complementar as informações obtidas com outros métodos de avaliação (ZHANG, 2001).

Os métodos empíricos avaliam indiretamente o algoritmo através das imagens segmentadas. A partir das imagens segmentadas são calculados índices, que medem a qualidade da segmentação com relação a algum critério. É necessário escolher corretamente o critério já que nem todos são adequados para um determinado tipo de imagem. Esta categoria de avaliação pode ser dividida em duas: métodos que medem a adequabilidade e os métodos que medem a discrepância.

Os métodos que medem a adequabilidade adotam critérios estabelecidos de forma intuitiva pelo homem. Os diversos índices associados à adequabilidade não consideram nenhuma informação *a priori* a respeito da segmentação correta da imagem. São considerados a uniformidade dos segmentos, o contraste entre os segmentos ou a forma destes segmentos. Também é possível utilizar uma combinação destes três. Como não é considerada a segmentação ideal, estes métodos podem ser usados pelo algoritmo de segmentação para auto-avaliação. Entretanto, os resultados obtidos na avaliação são inadequados quando o mesmo método é usado na avaliação e na auto-avaliação. A subjetividade presente em alguns destes índices não os tornam adequados para a avaliação objetiva dos algoritmos de segmentação.

Os métodos que medem a discrepância são usados para determinar o quanto a imagem segmentada está distante de uma imagem segmentada ideal. A segmentação ideal pode ser obtida através de outro algoritmo, quando este produz uma segmentação suficientemente adequada. Quando são utilizadas imagens artificiais é possível gerar a segmentação ideal a partir do algoritmo usado para gerar as imagens artificiais. Se nenhuma destas opções estiverem disponíveis é possível segmentar uma imagem manualmente; entretanto se a imagem for complexa ou se existirem muitos tipos de imagens, este procedimento pode tornar-se extremamente tedioso. Quando existir a segmentação ideal adequada, os métodos que medem a discrepância têm como principal vantagem o fato de serem objetivos e quantitativos. As medidas de discrepância são baseadas no número de *pixels* atribuídos incorretamente ou corretamente para um segmento. Entretanto, mesmo com valores iguais de discrepância, a imagem pode ter sido segmentada de forma diferente. As medidas de discrepância que consideram a posição dos *pixels* não sofrem deste problema. Outra abordagem considera somente o número de segmentos na imagem ideal e na imagem segmentada. Também é possível comparar duas imagens segmenta-

das considerando-se as características dos segmentos. Caso os segmentos sejam diferentes, os valores associados as características de cada segmento serão diferentes. Zhang (1996) constatou que os métodos empíricos que medem a discrepância são superiores aos demais métodos.

A avaliação da segmentação de imagens mostra-se uma área tão complexa quanto a segmentação de imagens, devido à natureza pouco compreendida do assunto. Apesar disto, existe um esforço no sentido de aperfeiçoar as técnicas relacionadas à avaliação da segmentação de imagens como foi possível notar nos trabalhos citados.

Exemplos de algoritmos de segmentação

Algoritmos de segmentação baseados em características

Uma das dificuldades existentes na segmentação de imagens é escolher qual representação de cores é a mais adequada. Alguns autores testam diversos espaços de cores ou, no caso de aplicações mais específicas, escolhem o espaço de cores que proporciona melhor separação entre os elementos da imagem. Uma outra abordagem foi adotada em Li e Li (2003), onde os autores utilizaram mapas auto-organizáveis na forma de rede de Kohonen para escolher as características relevantes de uma determinada imagem. Foram usadas as componentes de diversos espaços de cores como possíveis características. Após a seleção de características, uma versão modificada do FCM foi usada para agrupar as características semelhantes. Os autores segmentaram diversas imagens e obtiveram bons resultados. Eles afirmaram que o algoritmo proposto foi adequado para automação do processo de segmentação.

Uma abordagem semelhante foi adotada por Vandenbroucke, Macaire e Postaire (2003), onde os autores buscam, dentre as componentes de diversos espaços de cores, as que maximizam a discriminação entre as classes. O novo espaço de cores foi chamado de espaço de cores híbrido adaptado. Para um determinado conjunto de imagens foi gerado de forma supervisionada um novo espaço de cores. Os *pixels* a serem classificados foram convertidos para o novo espaço de cores. Então estes *pixels* são atribuídos à classe mais próxima, segundo a distância euclidiana. Este algoritmo foi implementado para segmentar imagens de jogadores de futebol com o objetivo de rastreá-los e identificar a qual time o jogador pertence. Comparações feitas com outros espaços de cores indicam que o método proposto é adequado para segmentação de imagens de jogadores de futebol em tempo-real.

Análise de agrupamentos no espaço de cores pode resultar em segmentações com ruídos, pois esta não considera a disposição espacial dos *pixels*. Estes ruídos podem ser eliminados em uma operação de pós-processamento, onde os ruídos são agrupados aos segmentos corretos. Macaire, Vandenbroucke e Postaire (2006) propuseram um algoritmo de segmentação que

agrupa as cores semelhantes e, posteriormente, verifica se estes grupos são coerentes com a disposição espacial dos *pixels* na imagem. Caso um grupo não seja coerente, este grupo é dividido. A divisão do grupo é feita com base no grau de compactação cromo-espacial, isto é, é feita uma análise dos *pixels* em uma vizinhança no plano da imagem para determinar se estes *pixels* possuíam cores semelhantes. Os autores consideraram como cores semelhantes uma região cúbica no espaço de cores RGB. Este algoritmo foi testado com imagens sintéticas e imagens naturais. Os autores afirmaram que o algoritmo é viável e que o estão aperfeiçoando.

Algoritmos de segmentação baseados em regiões

O uso de ferramentas estatísticas é bastante comum na segmentação de imagens. Kato, Pong e Lee (2001) utilizaram campos aleatórios de Markov para classificar os *pixels* de uma imagem. Este método considera uma região ao redor do *pixel*, incorporando assim a informação espacial no processo de segmentação. O modelo de segmentação adotado exige que alguns parâmetros iniciais sejam fornecidos. É importante estimar adequadamente estes parâmetros, pois eles influenciam diretamente a qualidade da segmentação. Como não é adequado estimar a média e a matriz de covariância a partir do histograma de cores, os autores re-quantizaram as cores na imagem de forma que o histograma apresentasse picos. A imagem foi re-quantizada com um processo de segmentação grosseiro, o qual usa divisão e fusão de regiões. Os autores realizaram testes em imagens artificiais e em imagens de ambientes fechados e abertos. Foram feitas comparações com algoritmos de segmentação supervisionados e não-supervisionados.

Chen e Chen (2002) explorou uma abordagem que alia à informação cromática a informação de bordas para segmentar texturas, sem usar técnicas de análise de texturas. A imagem foi inicialmente re-quantizada, utilizando o método de decomposição celular. Este método utiliza o espaço de cores HSV, o que viabiliza, segundo os autores, a obtenção de regiões com significados atribuídos pelo homem, como “céu”, “grama” etc. Outra vantagem da decomposição celular enfatizada pelos autores é que este algoritmo foi desenvolvido para o espaço de cores HSV. A imagem quantizada foi submetida ao algoritmo de segmentação de texturas no qual

foram usados dois descritores de textura: o histograma de cores e o histograma local de padrões de bordas. O primeiro descreve a distribuição de cores em uma região, e o segundo as bordas em uma região. A segmentação foi feita em três etapas: primeiro, divisão hierárquica, onde foram encontradas regiões de texturas uniformes; depois foi feita a fusão, onde regiões semelhantes adjacentes foram unidas; e, por último, os *pixels* foram classificados, o que melhorou as fronteiras dos segmentos. Os autores reportaram que o erro na segmentação de imagens artificiais foi baixo, e que o algoritmo segmentou imagens naturais satisfatoriamente.

Uma técnica iterativa em conjunto com RNA foi explorada por Lin, Tsao e Chen (1992) para segmentar imagens. Os autores solucionaram um *constraint satisfaction problem* (CSP) através de uma RNA especialmente construída para tal tarefa. Esta RNA, chamada de *constraint satisfaction neural network* (CSNN), foi formada por camadas de neurônios, onde cada neurônio representa um *pixel* e cada camada representa um segmento. Os neurônios foram interligados com todas as camadas em uma vizinhança 8-conectada, onde as interligações foram associadas a pesos; os pesos representam as restrições do CSP. Os pesos dos neurônios foram atualizados através de um processo iterativo que termina quando os valores dos neurônios ficam estáveis. É esperado que ao final das iterações os valores dos neurônios sejam zeros, com exceção dos neurônios na camada que representa o segmento a qual os *pixels* pertencem. Esta arquitetura de RNA exige que os pesos dos neurônios sejam iniciados de forma específica, para isto foi utilizada uma rede SOM. Os autores consideraram cada neurônio da rede SOM como uma classe de segmento. A cada classe de *pixels* foram associados valores iniciais para os pesos dos neurônios na CSNN. Lin, Tsao e Chen (1992) consideraram apenas imagens em tons de cinza, mas Kurugollu, Sankur e Harmanci (2002) consideraram a informação cromática e propuseram melhorias para a CSNN. Estas modificações visaram melhorar a qualidade da segmentação e reduzir o número de iterações. As novas CSNN foram avaliadas com imagens artificiais e naturais. Os resultados mostraram que a versão do CSNN que utilizou campos aleatórios de Markov apresentou os melhores resultados.

Alguns autores escolhem re-quantizar a imagem, pois assim o algoritmo de segmentação lidará com menos cores. O algoritmo de segmentação JSEG é um destes algoritmos. Neste

algoritmo, a imagem é re-quantizada de forma a reduzir sua complexidade, sem que os detalhes da imagem sejam perdidos. Usando como fundamento o algoritmo JSEG, Jing et al. (2003) propuseram um algoritmo de segmentação que usa o conceito de H-imagem. A H-imagem é um critério de homogeneidade que é extraído diretamente das cores dos *pixels*. Posteriormente, os valores dos *pixels* da H-imagem foram usados pelo algoritmo de crescimento de região da mesma forma que no JSEG. Os resultados obtidos ao segmentar diversas imagens foram satisfatórios.

O crescimento de regiões também pode ser obtido através de relaxamento. Usando esta abordagem, Cheng (2003), desenvolveu um algoritmo de segmentação que primeiro agrupa as cores semelhantes sem descaracterizar a imagem e depois realiza o relaxamento utilizando como restrição a distância triangular. Desta forma, os *pixels* foram atribuídos às classes e a diferença entre a cor que representa a classe e a cor original do *pixel* foi reduzida. Devido ao critério adotado, o custo computacional do algoritmo foi menor que quando usado o relaxamento probabilístico, segundo o autor. O algoritmo proposto foi comparado com outros algoritmos na segmentação de imagens artificiais com e sem ruídos e mostrou-se melhor que os demais algoritmos, principalmente quando o ruído era maior. O algoritmo foi também testado com imagens naturais e apresentou bons resultados.

Com o objetivo de segmentar imagens de cenas naturais em regiões semanticamente coerentes, Chen et al. (2005) utilizaram dois tipos de características perceptivas adaptativas, uma para cores e outra para texturas. As cores foram descritas por características que representam a composição local desta em uma região, ou seja, a característica foi formada pela cor predominante em uma região juntamente com a porcentagem de ocorrência desta cor. A característica de textura foi extraída empregando-se um filtro direcional à componente da intensidade da luz. Os *pixels* semelhantes foram agrupados usando-se uma métrica de distância que considera a cor dominante e a porcentagem de ocorrência desta. As informações de cor e de textura foram combinadas e uma segmentação grosseira foi obtida. A segmentação final foi obtida através de um processo iterativo de refinamento das fronteiras dos segmentos. Este algoritmo foi comparado qualitativamente com o algoritmo de segmentação JSEG. As imagens obtidas com o

algoritmo proposto não apresentam o problema de super-segmentação que ocorre nas imagens segmentadas com o JSEG.

2.2 Reconhecimento de padrões

As técnicas de reconhecimento de padrões são usadas para extrair informações que tenham maior valor semântico, segundo critérios humanos. Estas são empregadas em diversas áreas além da visão computacional, como por exemplo na mineração de dados e na taxonomia. Esta informação, com maior valor semântico, não é usada somente pelo homem. Ela pode ser empregada em diversos sistemas automáticos que devem abstrair a informação (aprender) com o objetivo de viabilizar uma interação sofisticada da máquina com o meio. Entende-se como interação sofisticada com o meio, situações onde exista incerteza ou situações onde seja necessário utilizar conceitos desenvolvidos pelo homem.

A visão computacional faz uso das técnicas de reconhecimento de padrões para identificar imagens, elementos da imagem ou a interação entre os elementos em uma imagem. A interação entre os elementos da imagem deve ser analisada usando uma abordagem descritiva (DUDA; HART, 1973). A identificação de imagens e seus elementos pode ser feita utilizando-se a classificação de padrões, que pode ser aplicada a sistemas de recuperação de imagens baseada em conteúdo (SiRIC), onde uma imagem é usada como chave da busca e o sistema retorna imagens semelhantes (BUENO, 2001; CASTANÓN; TRAINA, 2003; PARK; LEE; KIM, 2004). A identificação de elementos em uma imagem pode ser usada por robôs industriais, que necessitam manipular de forma específica alguma peça (TRONCO, 1999). Também, a identificação de elementos é aplicada na colheita automática de frutos (SLAUGHTER; HARRELL, 1989; PLEBE; GRASSO, 2001; ANNAMALAI; LEE; BURKS, 2004), e aplicações de localização de plantas através da análise da imagem das folhas (TIAN; SLAUGHTER, 1998; TANG; TIAN; STEWARD, 2003; STEWARD et al., 2004; TANG; TIAN; STEWARD, 2000; NETO et al., 2003).

A classificação de padrões tem sua origem nas atividades realizadas pelo homem, que tende a categorizar tudo ao seu redor com o objetivo de compreender ou viabilizar alguma atividade.

O homem realiza esta tarefa de forma subjetiva e instintiva. Conseqüentemente, os mecanismos humanos utilizados no processo de classificação são pouco compreendidos. Este fato dificulta a reprodução destes mecanismos humanos nas máquinas (COSTA; CESAR JÚNIOR, 2001).

Quando o homem sistematiza algo através da classificação, ele enfatiza as qualidades dos objetos. Os objetos com qualidades comuns são agrupados de forma que os grupos tenham significado. Por consequência disto, é possível criar uma hierarquia entre os objetos, onde os objetos mais complexos incorporam as qualidades dos objetos que o sucedem na hierarquia. Portanto, a informação é organizada de forma que as redundâncias sejam eliminadas. Exemplo disto são as classificações das espécies usadas por biólogos. Neste trabalho, objeto é qualquer realidade, exterior à mente humana, apreendida pela percepção e/ou pelo pensamento. Os objetos podem receber outros nomes, conforme o contexto, por exemplo: casos, unidade de dados, observações, eventos, indivíduos, entidade e unidades de taxonomia operacionais (COSTA; CESAR JÚNIOR, 2001).

Além de organizar a informação, ao classificar os objetos, a quantidade de informação utilizada para representá-lo é reduzida, pois ao invés de utilizar vários *bits* são usados apenas alguns *bits* que representam a classe do objeto (DUDA; HART, 1973). Também, a classificação pode levar a uma compreensão melhor do objeto de estudo, já que a procura por qualidades e hierarquias pode fornecer informações novas à pesquisa (COSTA; CESAR JÚNIOR, 2001).

As qualidades de um objeto também são conhecidas como características. As características podem ser representadas por valores numéricos, onde um conjunto de características forma um vetor, chamado de vetor de características. Escolher as características adequadas para a aplicação é um desafio. Outro desafio é escolher o algoritmo que irá classificar os vetores de características. Estes algoritmos podem ser inspirados na natureza, entretanto tal abordagem não é uma regra obrigatória. O propósito dos algoritmos de classificação é dividir o espaço formado pelos vetores de características em regiões que estão associadas às classes dos objetos. Estes espaços n -dimensionais são chamados de espaços de características, onde n é a quantidade de características (COSTA; CESAR JÚNIOR, 2001).

O reconhecimento de padrões e sua classificação são tarefas complexas, pois devem lidar com incertezas. Além disso, muitas escolhas devem ser feitas ao construir um classificador, como por exemplo, escolher as características, medidas de distância e parâmetros diversos. Cada uma destas escolhas leva a um diferente classificador, que pode ser melhor ou pior que um outro. De forma semelhante ao que ocorre em segmentação de imagens, cabe ao desenvolvedor do classificador escolher e avaliar os classificadores que apresentam as qualidades mais adequadas à aplicação (COSTA; CESAR JÚNIOR, 2001).

Os principais aspectos relevantes ao desenvolvimento de um classificador de padrões são abordados a seguir.

2.2.1 Características dos elementos de uma imagem

Ao escolher as características que representaram os objetos é necessário considerar como os vetores formados por estas características estão dispersos no espaço. Mais especificamente devem ser observados os seguintes itens (COSTA; CESAR JÚNIOR, 2001):

- escolher características que proporcionem discriminação entre as classes, assim, evitando ambigüidades entre elas;
- deve-se evitar características correlacionadas, pois estas características são redundantes, o que exigirá mais espaço para armazenamento e tempo de processamento. Entretanto são conhecidos casos onde tais características são necessárias;
- observar se existem objetos que fogem do padrão da classe a qual eles pertencem (objetos *outliers*). Caso estes objetos estejam presentes, as características que os tornam discrepantes dos demais devem ser evitadas.

Além destes itens relacionados com a dispersão dos objetos, também devem ser observados os seguintes itens:

- deve ser adotada uma quantidade mínima de características, pois assim reduz-se o custo associado ao processo de obtenção e classificação destas características;

- as características devem ser medidas de forma objetiva, ou seja, estas não podem depender de muitos parâmetros, pois obter os parâmetros ótimos pode ser uma tarefa difícil;
- alguns casos exigem o uso de características invariantes, como as características geométricas, que podem sofrer transformações durante o processo de aquisição de dados.

Organizar os dados em tabelas, quando existem poucas características, ou plotar os dados em um gráfico de dispersão pode ajudar na escolha das características. Entretanto, algumas vezes, faz-se necessário usar mais que três características e estas técnicas não são adequadas para tais situações. Uma das formas de resolver este problema é projetar os vetores de características, que estão em um espaço n -dimensional em um espaço com três ou menos dimensões (COSTA; CESAR JÚNIOR, 2001).

São muitas as características existentes na literatura, então é necessário conhecer aquelas associadas à visão computacional, onde os objetos estão associados à imagem ou a parte desta, caso esta tenha sido segmentada.

No caso das imagens, as características de um objeto, ou elemento, podem ser sistematizadas considerando a forma de representação e de descrição deste elemento. A imagem ou segmento é representada originalmente por uma matriz que contém os valores da intensidade da luz ou das cores. Entretanto, representações diferentes desta podem reduzir a quantidade de informação e ainda possibilitar o cálculo de alguns descritores. Os descritores complementam o que é feito pelas representações, assim, caracterizando os elementos (GONZALEZ; WOODS, 2002).

A representação pode considerar o contorno do elemento ou os *pixels* que preenchem o elemento. A primeira abordagem, chamada de representação externa, é adequada quando devem ser extraídas características que descrevem a forma do contorno do elemento. Exemplos de representações externas são: códigos de cadeias, aproximação poligonal, assinaturas e segmentos de bordas. A representação interna é voltada para descritores baseados em tons de cinza, cores e texturas. A esqueletização é um exemplo de representação interna (GONZALEZ; WOODS, 2002).

Com isto é possível apresentar os descritores classificados em suas duas principais classes, onde alguns destes descritores podem fornecer mais de uma característica.

Os descritores que utilizam a representação externa são (GONZALEZ; WOODS, 2002):

Comprimento ou perímetro - Este é um dos descritores mais simples. O comprimento pode ser aproximado a partir do número de *pixels* do contorno ou pelo código de cadeia, o qual consiste em uma forma de representar o contorno através de segmentos com tamanho fixo e direção variável. Estes segmentos são usados para aproximar o contorno original, então a cada um dos segmentos é associado um valor que representa a direção. A sequência desses valores é chamada de código de cadeia. A Figura 6 mostra o código de cadeia de um contorno, onde seu comprimento pode ser calculado pela quantidade de segmentos na vertical e na horizontal mais a quantidade de segmentos na diagonal multiplicado por $\sqrt{2}$, o que resulta, para esse exemplo, em aproximadamente 14,5, considerando que os segmentos na horizontal e na vertical tem comprimento unitário.

Figura 6: Exemplo de código de cadeia e direções dos segmentos baseada em região 8-conectada.

Diâmetro - O diâmetro é a distância máxima entre dois pontos pertencentes a borda do elemento. A reta ligando estes dois pontos é chamada de eixo-maior, como ilustrado na Figura 7. Além do diâmetro é possível usar a orientação do eixo-maior como característica.

Figura 7: Eixo-maior, onde d_{max} é o diâmetro deste eixo.

Excentricidade - É a razão entre o comprimento do eixo-maior e do eixo-menor, onde este último é a reta perpendicular ao eixo-maior com comprimento igual a um dos lados do retângulo que envolve todo o elemento; o outro lado do retângulo têm comprimento igual ao do eixo-maior, como pode ser observado na Figura 8. Este retângulo é chamado de retângulo básico.

Figura 8: Eixo-maior, eixo-menor e retângulo básico.

Curvatura - É definida como a taxa de variação da inclinação da curva definida pelo contorno. Obter esta medida é difícil, pois os contornos tendem a ser localmente ondulados, o que torna necessário o uso de medidas diferentes de curvatura, como por exemplo a diferença da inclinação entre dois segmentos adjacentes do contorno, como mostrado na Figura 9. Entretanto, este descritor depende da relação entre o comprimento total e o comprimento do trecho a ser analisado, por isso ele deve ser usado com cautela.

Números de formas (*shape numbers*) - Os números de formas são calculados a partir da primeira diferença do código de cadeia, onde, a primeira diferença é re-arranjada de forma que o primeiro menor valor ocupe a primeira posição da sequência. Ao re-arranjar esta sequência, ela deve ser tratada como uma sequência circular. Os números de formas são independentes da rotação, mas dependem da orientação da grade formada pelos *pixels*.

Figura 9: Contorno e a inclinação de dois segmentos.

Esta grade pode ser alinhada com o retângulo básico, assim a normalização com relação a orientação é obtida. A quantidade de divisões da grade pode ser determinada a partir da ordem do número de formas, que é a quantidade de valores que existem na cadeia. Primeiro é escolhido um valor para a ordem (para o exemplo da Figura 10 o valor é 18), então o retângulo básico é dividido com uma grade, cujo perímetro é igual ao valor da ordem, a quantidade de divisões em cada um dos lados é proporcional aos eixos maior e menor. Este procedimento pode resultar em uma cadeia com ordem maior que a escolhida, caso isto ocorra deve ser escolhida uma grade com perímetro menor que a ordem.

Descritores de Fourier - O contorno de um elemento pode ser interpretado como uma função com imagem complexa, onde os valores reais e imaginários representam as coordenadas dos *pixels* da borda, como mostrado na Figura 11. A equação 2.42 mostra esta função, onde k é um *pixel* na borda, $x(k)$ e $y(k)$ são as coordenadas nos eixos x e y , respectivamente. Os coeficientes da transformada direta de Fourier são calculados para a função $s(k)$ e estes coeficientes são usados como descritores. Entretanto é necessário escolher quantos coeficientes serão usados. Este descritor é insensível ao ponto de início da função que descreve o contorno, entretanto ele é sensível a transformações geométricas. Para evitar essa limitação é possível adicionar parâmetros ao descritor que corrigem isto.

$$s(k) = x(k) + iy(k) \quad (2.42)$$

Momentos estatísticos - Os momentos estatísticos (média, variância e momentos de ordem maior) podem ser usados para descrever um contorno representado como assinatura. A

Figura 10: Exemplo de como obter os números de formas a partir de um contorno.

assinatura de um contorno é uma função com imagem unidimensional que pode ser obtida de várias formas. A vantagem de utilizar esta representação é que o contorno, originalmente representado em duas dimensões, passa a ser representado em uma dimensão. A amplitude da função de assinatura é tratada como uma variável aleatória, então os momentos são calculados. Estes descritores tem implementação mais simples que os descritores de Fourier, são insensíveis a rotação e podem ser normalizados com relação ao tamanho.

Costa e Cesar Júnior (2001) exploram diversos descritores de contornos e técnicas voltadas para a classificação das características obtidas a partir destes descritores.

Os descritores que utilizam representação interna são (GONZALEZ; WOODS, 2002):

Figura 11: Representação do contorno com números complexos.

Área - A área de uma região pode ser aproximada pelo número de *pixels* que preenche esta região. Os elementos avaliados por este descritor não podem sofrer transformações de escala. Caso isto ocorra, esta distorção deve ser corrigida. A Figura 12 mostra um elemento discretizado com relação a uma grade pré-estabelecida. A área deste elemento é dada pelos quadrados em cinza escuro, que representam os *pixels*.

Figura 12: Área de um elemento discretizado.

Compactação - Os descritores de área e perímetro são usados com mais frequência para obter-se o descritor de compactação. O valor deste descritor é a razão entre o quadrado do perímetro e a área. Este descritor é adimensional, insensível a mudanças de escala e orientação. O valor deste descritor é mínimo para elementos com formato circular.

Descritor topológico - Topologia pode ser definida como o estudo das propriedades das Figuras (imagens) que não são afetadas por deformações. As propriedades topológicas são adequadas para representar as propriedades globais de uma imagem, sendo que estas propriedades não dependem de medidas de distâncias. Exemplos de descritores topológicos são: número de buracos em um elemento, número de elementos conectados e número de Euler. A Figura 13 tem três buracos, um componente conectado e número de Euler igual a -1 , onde este último é definido como o número de componentes menos o número de buracos.

Figura 13: Figura com três buracos, um componente conectado e número de Euler igual a -1 .

Textura - Apesar de não existir uma definição formal de texturas, estes descritores procuram caracterizar as principais propriedades das texturas, como por exemplo a suavidade, regularidade ou direção. Gonzalez e Woods (2002) citam três abordagens para extrair características de texturas: estatística, estrutural e espectral. Uma abordagem estatística utiliza os momentos estatísticos, que são calculados a partir do histograma dos tons de cinza. Os momentos caracterizam a textura como suave, grosseira ou granular, entretanto uma desvantagem desta abordagem é que esta não considera a informação espacial. Outra abordagem estatística considera a informação espacial através das matrizes de co-ocorrência de tons de cinza, onde a partir destas matrizes são calculadas características como, por exemplo, máxima probabilidade, uniformidade e entropia. A abordagem estrutural utiliza regras sintáticas para criar modelos de texturas que dão origem a uma textura mais complexa. A abordagem espectral utiliza a transformada de Fourier para analisar a textura com respeito à direção principal e ao período fundamental. A representação polar

do espectro viabiliza a extração destas últimas características.

Além dos descritores apresentados é importante mencionar os descritores de cores e os descritores de texturas que utilizam análise multi-resolução.

Cor - Muitos elementos têm cor uniforme ou uma cor predominante. Isto faz das cores uma característica adequada para muitas situações. As cores dos elementos podem ser descritas pelas categorias de um histograma. O histograma apresenta a vantagem de ser invariante à translação e a rotação dos elementos com relação ao eixo perpendicular à imagem. Também, o histograma sofre pouca alteração quando rotacionado em relação aos outros eixos, quando o elemento está parcialmente oculto ou quando a distância entre a câmera e o elemento é variável (SWAIN; BALLARD, 1991). Para imagens em tons de cinza, o histograma é calculado a partir dos valores dos *pixels*. Para imagens coloridas, o histograma pode ser calculado para todas as cores discretas, uma categoria para cada cor. Este histograma retém a informação de cor, entretanto, o cálculo é inviável, pois a quantidade de cores é muito grande (CHENG et al., 2001). Como alternativa a isto, a quantidade de categorias do histograma pode ser reduzida. Para tal, o espaço de cores pode ser re-discretizado, como feito por Swain e Ballard (1991). Uma outra alternativa é calcular os histogramas de cada canal de cor e unir estes histogramas em um único vetor de características, como feito no descritor SCD (MANJUNATH et al., 2001). Utilizar as categorias dos histogramas como descritor requer cuidados, pois elementos diferentes podem ter histogramas semelhantes, caso eles apresentem as mesmas cores distribuídas de forma diferente na superfície do elemento.

Análise de texturas multi-resolução - Algumas imagens contêm regiões com detalhes que exigem maior resolução espacial para que estes possam ser visualizados adequadamente. Também, imagens apresentam padrões de texturas grosseiras que não exigem muita resolução geométrica. Estes dois casos podem aparecer ao mesmo tempo em uma mesma imagem, o que indica a necessidade do uso de técnicas que consideram diferentes resoluções ou escalas de uma mesma imagem. Os descritores que utilizam as técnicas

multi-resolução possibilitam extrair características das texturas em diferentes escalas, assim, descrevendo-as de forma mais completa. As duas principais técnicas de análise de texturas são a transformada de *wavelet* e os filtros de Gabor. Ambas as técnicas analisam o espectro em diversas escalas da imagem, sendo que os filtros de Gabor possuem a melhor relação entre a resolução espacial e a resolução espectral. Também, estas técnicas são capazes de captar a orientação da textura. A transformada complexa de *wavelet* é capaz de analisar a direção das texturas e é invariante a deslocamentos. Os filtros de Gabor apresentam uma dificuldade relacionada a escolha dos filtros, pois é necessário determinar para cada filtro quais frequências, orientações e espaço de análise este deverá considerar (HILL, 2002).

2.2.2 Normalização e extração das características

A escolha das características é uma etapa importante dentre todas as etapas que existem no processo de construção de um classificador, como foi visto. Alguns problemas, entretanto, não permitem que sejam adotadas características que originem espaços onde a dispersão dos vetores favoreça a classificação. Nesta situação é necessário transformar o espaço de características de forma a melhorar a discriminação entre as classes. Em outros casos, não é possível determinar qual é a influência exata de um conjunto de características sobre os elementos, então é necessário utilizar técnicas que evidenciem um espaço de características mais apropriado. Algumas destas técnicas podem ser usadas para reduzir o número de dimensões, assim, é possível projetar vetores n -dimensionais em espaços com três ou menos dimensões viabilizando a visualização destes vetores em um gráfico de dispersão.

Estas técnicas devem ser usadas com cautela, pois elas podem alterar o espaço de forma a prejudicar a dispersão das classes. Não existe um consenso sobre em que casos estas técnicas produzem bons resultados, por isto, elas devem ser avaliadas (COSTA; CESAR JÚNIOR, 2001).

Normalização

As unidades das características influenciam a dispersão dos vetores no espaço motivando o uso de espaços sem unidades. Isto pode ser obtido através da normalização das características. A normalização pode ser feita com relação a uma referência, onde esta pode ser o maior valor entre os dados. Outra forma de normalização é a da equação 2.43, onde $f(i, j)$ é o valor da característica j do vetor i e μ_j e σ_j são o valor médio e o desvio padrão. Assim, o conjunto de dados terá média igual a zero e desvio padrão igual a um (COSTA; CESAR JÚNIOR, 2001).

$$F(i, j) = \frac{f(i, j) - \mu_j}{\sigma_j} \quad (2.43)$$

Análise de componentes principais

A análise de componentes principais (ACP) utiliza uma transformação linear que seja capaz de minimizar a co-variância e maximizar a variância. As características encontradas através desta transformação são completamente descorrelacionadas, logo, a redundância entre as características são removidas. Isto é feito de forma que as componentes (características) principais representem a maior parte da informação contida nos dados, assim as demais componentes podem ser desprezadas, reduzindo o número de dimensões (COSTA; CESAR JÚNIOR, 2001; HAYKIN, 1999).

Seja X uma matriz com dimensões $m \times n$. Cada coluna desta matriz representa um vetor m -dimensional. A ACP é feita nesta matriz segundo a equação 2.44, onde A é a matriz com a projeção de X sobre as componentes principais e Q é a matriz de transformação linear, onde matriz Q deve ser encontrada.

$$A = X^T Q \quad (2.44)$$

A matriz Q é composta pelos auto-vetores da matriz de correlação de X , onde os auto-vetores são organizados respeitando-se a ordem decrescente dos auto-valores correspondentes. Os auto-vetores q_j e auto-valores λ_j são encontrados segundo a equação 2.45, onde $R = E[XX^T]$, ou seja, R é a matriz de correlação de X e $j = 1, \dots, m$.

$$Rq_j = \lambda_j q_j \quad (2.45)$$

A matriz Q é obtida quando a equação 2.45 é re-escrita na forma da equação 2.46, onde $Q = [q_1, q_2, \dots, q_m]$ e $\Lambda = \text{diag}[\lambda_1, \lambda_2, \dots, \lambda_m]$.

$$RQ = \Lambda Q \quad (2.46)$$

A projeção do espaço m -dimensional em um espaço l -dimensional, sendo que $l < m$, é feita da mesma forma, entretanto a matriz Q deve ser re-escrita apenas com os primeiros l auto-vetores. Então aplica-se a equação 2.44 para obter-se os vetores no novo espaço. O erro quadrático médio desta projeção será o valor da soma das variâncias das componentes eliminadas. Quanto menores forem os valores dos auto-vetores eliminados, ou seja os λ_j , onde $l + 1 \leq j \leq m$, menor será o erro quadrático médio. A ACP é feita de forma que este erro seja mínimo.

2.2.3 Classificação das características

As técnicas de normalização e de extração de características são um passo na direção da classificação, pois reorganizam o espaço de características de forma a viabilizar a classificação, onde é possível que sejam evidenciados aglomerados naturais de pontos, mas estes aglomerados não são identificados, ou seja, suas fronteiras e classes não são conhecidas.

A classificação de padrões tem como objetivo dividir o espaço de características em regiões, nas quais podem ser encontrados os vetores pertencentes a uma das classes. Desta forma as fronteiras das classes são definidas. Para isto, são empregados métodos e critérios. O método

de classificação pondera as características de um objeto para que um critério julgue o resultado desta ponderação, assim, com este julgamento é estabelecida a classe do objeto (COSTA; CESAR JÚNIOR, 2001). O método e critério também podem ser interpretados como um modelo que descreve os dados e suas classes. Exemplo de métodos são: medidas de similaridade e dissimilaridade, estatísticos e limiares. Exemplos de critérios são: próximo ou distantes, acima de determinado valor ou maior probabilidade.

O conhecimento adquirido a respeito do fenômeno que originou os dados a serem classificados pode evidenciar os métodos e os critérios. Caso isto não seja possível, podem ser empregados algoritmos que aproximem os métodos e os critérios. Tendo isto em mente, é possível dividir as técnicas de classificação de padrões da seguinte forma (COSTA; CESAR JÚNIOR, 2001): critério imposto, classificação por exemplos e critério aberto. Estes três tipos serão descritos a seguir.

Critério Imposto

Neste caso, existe conhecimento suficiente a respeito do fenômeno que originou os dados. As classes são conhecidas e, também, as qualidades, que tornam um objeto membro de uma classe, são conhecidas. Logo, o critério e o método são conhecidos. Devido a isto, somente a extração de características deve ser feita. Um exemplo de critério imposto é a classificação da temperatura em algum equipamento. Neste caso existe somente uma característica e o método de classificação é comparar o valor com outro pré-estabelecido. Os critérios de atribuição são: caso a temperatura esteja maior que o valor pré-estabelecido, esta é atribuída a uma classe; caso contrário, é atribuída a outra classe (COSTA; CESAR JÚNIOR, 2001).

Classificação por exemplos

A classificação por exemplos ou supervisionada é usada quando não é claro o que faz um

objeto pertencer ou não a uma classe, entretanto as classes são conhecidas e existem protótipos ou exemplos destas. Isto faz deste caso mais complexo que o critério imposto.

Os algoritmos de classificação de padrões que utilizam exemplos trabalham de duas formas distintas. Inicialmente, eles analisam o conjunto de exemplos, ou conjunto de treinamento. Depois desta fase, o algoritmo faz o reconhecimento dos padrões apresentados a ele como mostrado na Figura 14. A primeira fase, conhecida também como treinamento, é responsável por encontrar o método e/ou critério, ou encontrar os parâmetros associados a um modelo pré-estabelecido.

Figura 14: Esquema da classificação por exemplos.

Alguns dos classificadores de padrões utilizam métodos específicos outros genéricos, ou seja, abstraem o método. O mesmo ocorre com o critério, onde alguns classificadores adotam critérios específicos e outros conseguem abstrair estes critérios. Exemplo disto são os classificadores bayesianos e RNA treinadas com algoritmo *backpropagation* ou derivados deste.

O classificador bayesiano adota o método estatístico e o critério maior probabilidade, sendo que o método estatístico é usado para estimar o modelo dos dados (função distribuição de probabilidade (PDF) e probabilidades *a priori*) a partir dos dados de treinamento. O modelo estatístico dos dados é utilizado para calcular a probabilidade *a posteriori*, que neste caso é a probabilidade de um objeto pertencer a uma classe.

Os classificadores que utilizam RNA aprendem o método de classificação e o critério a par-

tir dos dados durante a fase de treinamento. Os pesos sinápticos dos neurônios são ajustados de tal forma que as entradas da rede (vetor de características de um objeto) sejam ponderadas e julgadas conforme os dados são propagados em direção a saída da RNA. Isto ocorre pois a RNA implementa a aproximação de uma função não-linear que divide o espaço de características nas classes desejadas (COSTA; CESAR JÚNIOR, 2001).

Critério aberto

Os classificadores baseados em critério aberto são caracterizados pela ausência de um conjunto de treinamento dividido em classes pré-estabelecidas. Também, pouco é conhecido sobre os dados que devem ser classificados, o que faz deste caso o mais complexo dos apresentados. Devido a estes fatos, estes classificadores são chamados de não-supervisionados. A Figura 15 mostra o esquema geral destes algoritmos.

Figura 15: Esquema do funcionamento de um algoritmo baseado em critério aberto.

Estes algoritmos buscam pelos padrões evidentes nos objetos. Isto é feito segundo um método e um critério. A busca é feita de forma a agrupar objetos semelhantes, o que é equivalente a maximizar a diferença entre os agrupamentos. Isto pode ser obtido através de um dos dois métodos principais: o particional e o hierárquico.

A abordagem particional busca dividir o espaço de características em um número definido de agrupamentos, segundo um critério pré-estabelecido. Um dos critérios que pode ser adotado é a dispersão dos objetos em um agrupamento. Se a dispersão de um agrupamento for muito grande, este agrupamento deverá ser dividido de forma a minimizar a dispersão. Outra abordagem busca minimizar a soma das distâncias, ou seja, a dissimilaridade dos elementos de um mesmo agrupamento com relação a um determinado membro deste mesmo agrupamento. Este último é o caso do algoritmo *k*-médias.

Os algoritmos de agrupamento hierárquico constroem os grupos progressivamente, agregando os objetos similares segundo algum critério de similaridade ou dissimilaridade. Estes algoritmos não determinam a quantidade ótima de agrupamentos, eles fornecem os possíveis agrupamentos para um número de grupos que varia do número um até o número de objetos no conjunto de dados. O resultado produzido por estes algoritmos é representado por um gráfico, onde são evidenciadas as relações hierárquicas entre os agrupamentos e os objetos. Este gráfico é chamado de dendograma.

A quantidade de agrupamentos é um problema presente também nos algoritmos particionais, onde esta quantidade deve ser indicada ou deve ser adotada alguma técnica que a estime. Além deste problema, os algoritmos não supervisionados devem lidar com outras dificuldades, como por exemplo:

- classes com formas complexas,
- agrupamentos evidentes em diferentes escalas,
- regiões com poucas amostras,
- classes sobrepostas,
- classes próximas uma das outras.

O critério do algoritmo de classificação não-supervisionado influencia diretamente a forma dos grupos encontrados. Dependendo da natureza dos dados, o critério pode não corresponder com a realidade, então outros critérios devem ser considerados quando não existe informação sobre a forma dos agrupamentos (COSTA; CESAR JÚNIOR, 2001).

2.2.4 Classificadores de padrões

Classificador baseado em redes neurais artificiais

Redes neurais artificiais são estruturas computacionais inspiradas no cérebro, ou seja, sistemas massivamente paralelos com capacidade de realizar operações não-lineares em pouco

tempo de processamento. Os cérebros são compostos de estruturas celulares independentes chamadas de neurônios, os quais estão presentes em alta quantidade, contribuindo para a tolerância a falhas. A capacidade de processamento paralelo, a velocidade de processamento, a capacidade computacional e a tolerância a falhas fazem o modelo do cérebro biológico adequado para diversas aplicações (HAYKIN, 1999).

O neurônio artificial é um modelo simplificado do natural, onde os dendritos, corpo celular e os axônios são representados de forma matemática. A Figura 16 mostra o esquema de um neurônio artificial. Neste neurônio o estímulo é feito pela entradas $x_1, x_2, \dots, x_m$. As quais são ponderadas com os pesos sinápticos $w_{k1}, w_{k2}, \dots, w_{km}$ e os resultados são somados. O limiar b_k é responsável pela ativação ou não do neurônio, ou seja, se este neurônio irá responder a um estímulo. A função de ativação $\phi(\cdot)$ limita o sinal de saída y_k a um intervalo finito. Este modelo é representado pela equação 2.47.

Figura 16: Neurônio artificial.

$$y_k = \phi \left(\sum_{j=1}^m w_{kj} x_j + b_k \right) \quad (2.47)$$

As RNA que utilizam este modelo de neurônio têm seus neurônios organizados em camadas, onde as entradas são ligadas aos neurônios da primeira camada e as saídas destes podem ser ligadas aos neurônios de uma segunda camada e assim por diante. Estas RNA são chamadas de alimentadas adiante, pois o sinal é propagado das entradas dos neurônios até as suas saídas por todas as camadas, sucessivamente.

O modelo mais simples das redes alimentadas adiante é o com uma camada. Esta rede tem

apenas uma camada de entrada e uma camada de processamento, ou seja, de neurônios. Os pesos sinápticos e o limiar são ajustados com um algoritmo de treinamento supervisionado. Este ajuste é feito com base no erro da rede, onde este erro é calculado a partir da diferença entre as saídas dos neurônios e os valores esperados de saídas. Estas redes tem capacidade computacional limitada pois elas aproximam somente funções lineares. Exemplo desta arquitetura de RNA é o perceptron e redes adaline (HAYKIN, 1999).

A capacidade computacional limitada das redes com uma camada levou ao desenvolvimento de outras RNA, como o perceptron multicamadas, (PMC) que tem capacidade computacional maior, pois aproxima qualquer função não-linear. Conseqüentemente, estas redes são capazes de reconhecer padrões que são separados por superfícies não-lineares. Conjuntos convexos, não convexos, conectados ou desconexos são reconhecidos também por redes com esta arquitetura.

O PMC deve ser treinado, como o perceptron, entretanto, tal treinamento deve ser feito de modo a considerar as diversas camadas. Para isto, foi desenvolvida a regra delta generalizada, ou *backpropagation*, onde o erro da rede é considerado nos ajustes dos pesos sinápticos da camada de saída, e os pesos das demais camadas são ajustados com base no erro propagado no sentido inverso, ou seja, da saída para as entradas. O ajuste dos pesos é proporcional ao gradiente da função de erro, logo o *backpropagation* é um algoritmo de descida de gradiente e está sujeito a produzir resultados não ótimos, pois o algoritmo pode encontrar um mínimo local da função de erro. Apesar disso, este algoritmo é capaz de aprender padrões complexos, ou seja, padrões que são separados por superfícies de decisões não triviais ou padrões degradados por ruídos. Entretanto, a velocidade de treinamento é baixa, pois são necessárias muitas iterações do algoritmo para a rede convergir, se a convergência for possível (HAYKIN, 1999).

O Rprop (*resilient backpropagation*) é um algoritmo de descida de gradiente derivado do *backpropagation*, que ajusta a taxa de treinamento conforme a necessidade, assim, minimizando as oscilações e maximizando a descida do gradiente. A quantidade de memória necessária para este algoritmo cresce linearmente com o número de parâmetros livres. Além destas características, o Rprop é conhecido por ser acurado, robusto e de rápida convergência. O iRprop

(*improved* Rprop) (IGEL; HÜSKEN, 2000)) é um algoritmo derivado do Rprop onde foram introduzidas modificações para melhorar a velocidade de aprendizado, ou seja, diminuir o número de iterações. Os parâmetros do iRprop são intuitivos e fáceis de serem ajustados. Estas são as propriedades mais relevantes para este trabalho. Igel e Hüsken (2003) descrevem outras vantagens do algoritmo e o compara com outros algoritmos.

Classificador baseado no teorema de Bayes

Antes de apresentar o classificador bayesiano é necessário definir alguns conceitos relacionados com probabilidades. Seja E um experimento qualquer que pode gerar vários resultados, todos os resultados possíveis compõem o espaço amostral S . Os resultados que ocorrem a cada execução deste experimento são chamados de eventos A . Assim é possível definir probabilidade para o caso discreto segundo a equação 2.48.

$$P(A) = \frac{\text{Quantidade de elementos em } A}{\text{Quantidade de elementos em } S} \quad (2.48)$$

O modelo probabilístico deve respeitar os seguintes axiomas:

$$P(S) = 1, \quad (2.49)$$

$$0 \leq P(A) \leq 1 \quad (2.50)$$

e

$$P(A \cup B) = P(A) + P(B), \quad (2.51)$$

tal que $A \cap B = \emptyset$, ou seja, os eventos A e B são mutualmente exclusivos.

É possível relacionar dois eventos de forma a obter a probabilidade de A ocorrer caso B tenha ocorrido. Isto é chamado de probabilidade condicional e é calculado segundo a equação 2.52.

$$P(A | B) = \frac{P(A \cap B)}{P(B)} \quad (2.52)$$

A partir destes conceitos é possível introduzir o teorema de Bayes usando como ponto de vista a classificação de padrões. Considere que é desejado saber se um determinado evento B é da classe que corresponde a A ; sabe-se *a priori* que a probabilidade de A ocorrer é igual a $P(A)$ e, também, conhece-se a probabilidade do evento B ocorrer para a classe A , ou seja, $P(B | A)$. Para determinar se B pertence a classe A é necessário calcular $P(A | B)$, que é o calculado pelo teorema de Bayes, definido pela equação 2.53, onde $P(B)$ é uma constante normalizadora (COSTA; CESAR JÚNIOR, 2001).

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)} \quad (2.53)$$

Os problemas de classificação envolvem normalmente mais de uma classe. Para estes casos, a equação 2.53 é usada para cada uma das classes e a que resultar maior probabilidade é escolhida. Este problema pode ser formulado segundo a equação 2.54, onde k é a classe de B , C_i é o evento relacionado a classe i , $P(C_i)$ é a probabilidade da classe C_i ocorrer, $P(B | C_i)$ é probabilidade de B ocorrer dado a classe C_i e K é o número total de classes.

$$k = \operatorname{argmax}_i (P(B | C_i)P(C_i)), i = 1, 2, \dots, K \quad (2.54)$$

Esta abordagem exige que $P(C_i)$ e $P(B | C_i)$ sejam conhecidos. As probabilidades *a priori* podem ser estimadas do conjunto de treinamento, supondo-se que o conjunto de dados é grande o suficiente. Entretanto a probabilidade condicional raramente está disponível, então é possível reformular o teorema de Bayes para utilizar a função densidade de probabilidade (FDP), como mostrado na equação 2.55, onde $p(y|C_i)$ é FDP condicional da classe i (COSTA; CESAR JÚNIOR, 2001).

$$P(C_i | y) = \frac{p(y | C_i)P(C_i)}{\sum_{j=1}^K p(y | C_j)P(C_j)} \quad (2.55)$$

Na equação 2.55, y é um valor escalar, entretanto é possível utilizar vetores, o que é mais comum em classificação de padrões, pois esta normalmente lida com mais que uma característica. Quando utilizados vetores, as variáveis aleatórias passam a ser chamadas de variáveis aleatórias multi-variadas e as FDP passam a ser chamadas de funções de densidade conjunta de probabilidades (FDCP).

O modelo do classificador bayesiano adotado neste trabalho é o da equação 2.55, para o caso em que y é um vetor n -dimensional, entretanto, a FDCP não é conhecida. A FDCP pode ser obtida através das técnicas paramétricas ou não-paramétricas. As técnicas paramétricas são utilizadas quando é conhecida a FDCP que originou os dados, mas os parâmetros desta não são conhecidos e devem ser estimados. As técnicas não-paramétricas são necessárias quando não existe conhecimento suficiente que possa ser utilizado para determinar a FDCP ou quando a densidade dos dados assume uma função não conhecida, como é o caso deste trabalho.

As técnicas não-paramétricas podem ser baseadas em janelas ou em vizinhos mais próximos. Uma das dificuldades é encontrar um tamanho de janela adequado para todo o domínio do conjunto de dados. Os métodos de vizinhos mais próximos não sofrem deste problema, entretanto a quantidade de vizinhos também deve ser determinada. Os dados a serem avaliados na estimativa de um ponto da FDCP podem ser suavizados por meio de uma função de núcleo, como é o caso da função gaussiana, que atribui menor peso aos pontos que estão mais distantes do centro. Esta última técnica é chamada de não-paramétrica de núcleo (DUDA; HART, 1973).

Os modelos baseados em misturas finitas são semelhantes aos métodos não-paramétricos de núcleo e são capazes de representar FDCP arbitrárias e complexas (HASTIE; TIBSHIRANI; FRIEDMAN, 2003). Estes modelos permitem uma abordagem formal ao aprendizado não supervisionado e, conseqüentemente, permitem que a escolha do número de misturas e a validação do modelo sejam feitas formalmente, diferente das heurísticas de agrupamento como o k -médias. As misturas são semelhantes aos modelos criados pelos algoritmos de agrupamentos, pois cada

componente da mistura é associado a um sub-conjunto (agrupamento) de dados, onde estes dados têm a maior probabilidade de terem sido gerados por esta componente da mistura. A função gaussiana é normalmente escolhida para compor a mistura (FIGUEIREDO; JAIN, 2002).

A FDCP pode ser aproximada como uma mistura de funções gaussianas e assume a forma da equação 2.56, onde k é o número de misturas, α_m são as probabilidades da mistura ou pesos, θ_m são os parâmetros da função gaussiana, $\theta \equiv \{\theta_1, \dots, \theta_k, \alpha_1, \dots, \alpha_k\}$, $\alpha_m \geq 0$ com $m = 1, \dots, k$ e $\sum_{m=1}^k \alpha_m = 1$ (FIGUEIREDO; JAIN, 2002).

$$\hat{p}(y|\theta) = \sum_{m=1}^k \alpha_m p(y|\theta_m) \quad (2.56)$$

Determinar a FDCP, neste caso, está restrito a escolha do número de componentes da mistura (k) e a encontrar os parâmetros destas componentes (θ). Estes parâmetros podem ser encontrados analiticamente, mas devido a falta de informação a respeito dos dados, como médias e matrizes de co-variâncias, esta abordagem não é adequada. Entretanto, o número de componentes e os parâmetros destas podem ser encontrados através de *maximum-likelihood* (ML) ou através da estimativa Bayesiana. Na prática a ML é mais simples e produz resultados tão acurados quanto a estimativa Bayesiana (PAALANEN et al., 2006).

O algoritmo padrão para obter a ML é o algoritmo de maximização da esperança (EM - *expectation-maximization*). Entretanto, este algoritmo tem algumas deficiências, como, por exemplo, sensibilidade à inicialização e a necessidade da escolha do número de componentes da mistura, onde este número leva a sub-adaptação ou a super-adaptação, como mostrado na Figura 17. Figueiredo e Jain (2002) modificaram o algoritmo EM de forma que o novo algoritmo fosse capaz de lidar com estes problemas. Este novo algoritmo inicia com um número arbitrário e grande de componentes, onde as médias destas componentes são distribuídas pelo espaço formado pelo conjunto de treinamento. Estas componentes são eliminadas quando o algoritmo detecta que estas não são suportados pelos dados. Após o algoritmo atingir um número mínimo de componentes, o melhor modelo é escolhido dentre os avaliados. Os modelos são ponderados através de uma função objetivo que deve ser minimizada com relação a θ .

Classificador Ingênuo de Bayes

Este classificador é semelhante ao apresentado anteriormente, entretanto, neste caso, é admitido que as características são independentes. Devido a esta suposição improvável, este tipo de classificador recebe o nome de ingênuo. Então, para cada uma das classe é suposto que a FDP assume a forma de equação 2.57, onde $p(y_j | C_i)$ é a função de densidade marginal condicional, estimada da mesma forma que FDCP, e n é o número de características.

$$p(y | C_i) = \prod_{j=1}^n p(y_j | C_i) \quad (2.57)$$

Classificadores que adotam a FDP desta forma podem lidar com mais características, pois cada FDP marginal terá apenas uma dimensão. Também é possível misturar FDP marginais contínuas e discretas. Apesar da FDP deste classificador ser distorcida, ela não prejudica a probabilidade *a posteriori*, pois a distorção é menor perto das regiões de decisão (HASTIE; TIBSHIRANI; FRIEDMAN, 2003).

2.2.5 Seleção e avaliação do classificador

O objetivo das técnicas de classificação é criar um modelo dos dados que os separem em classes ou agrupamentos. Devido às incertezas inerentes ao problema de classificação, faz-se necessário verificar se o modelo encontrado é adequado. Um modelo adequado é aquele que tem capacidade de prever corretamente a classe de um vetor, sendo que tal vetor não foi usado no treinamento. Caso o modelo seja adequado, diz-se que tal modelo generaliza.

A capacidade de um modelo generalizar está associada à complexidade deste modelo e esta complexidade está associada ao número de parâmetros que são ajustados durante o treinamento do modelo. Modelos complexos são capazes de adaptar-se a dados organizados de forma elaborada, entretanto tais modelos não generalizam. O modelo deve ter um equilíbrio entre a capacidade de generalizar e a capacidade de aprender dados com estrutura elaborada.

Tal modelo é encontrado através das técnicas de seleção e avaliação de modelos. Antes de

definir seleção e avaliação de modelos, devem ser definidos o erro esperado do teste e o erro do treinamento. Sejam $X \in \mathbb{R}^p$ um vetor aleatório de entrada e $Y \in \mathbb{R}$ uma variável aleatória de saída, o modelo que prediz Y tal que X é dado pela função $f(X)$; a função $\hat{f}(X)$ é a aproximação de $f(X)$ encontrada através do aprendizado. A função de perda, que mede o erro entre Y e $\hat{f}(X)$, é denotada por $L(Y, \hat{f}(X))$, esta função pode ser a equação 2.58, 2.59 ou outra.

$$L(Y, \hat{f}(X)) = (Y - \hat{f}(X))^2 \quad (2.58)$$

$$L(Y, \hat{f}(X)) = |Y - \hat{f}(X)| \quad (2.59)$$

O erro esperado do teste ou erro esperado de generalização é dado pela equação 2.60, onde $E[\cdot]$ é o operador de esperança.

$$Err = E[L(Y, \hat{f}(X))] \quad (2.60)$$

O erro do treinamento é dado pela equação 2.61.

$$\overline{err} = \frac{1}{N} \sum_{i=1}^N L(y_i, \hat{f}(x_i)) \quad (2.61)$$

O modelo que generaliza é o que tem menor erro do teste, entretanto tal erro só estará disponível após o treinamento. Não é adequado adotar o erro do treinamento (eq. 2.61) para estimar o erro de generalização, pois quanto mais complexo o modelo, menor será o erro do treinamento e maior será o erro do teste, o que é conhecido na literatura como *overfitting*. A Figura 17, mostra a relação da complexidade do modelo com os erros de teste e treinamento.

A seleção de modelos utiliza o erro esperado do teste para definir a complexidade do modelo. Isto pode ser feito de forma analítica ou re-utilizando de forma criteriosa as amostras utilizadas durante o treinamento. O modelo com menor erro esperado do teste é avaliado com o conjunto de testes. O conjunto de teste é uma coleção de dados que foram separados dos demais e não é utilizado durante o treinamento.

Pode-se concluir do que foi dito, que existem três etapas para obter-se um classificador: o treinamento, onde o modelo é aproximado, a validação, onde é selecionado o modelo e por fim o teste, onde o erro de generalização pode ser obtido. Também, faz-se necessário a divi-

Figura 17: Esquema do comportamento dos erros com relação a complexidade do modelo (HASTIE; TIBSHIRANI; FRIEDMAN, 2003).

são dos dados em três partes, uma para o treinamento, outra para a validação e outra para o teste. A proporção entre essas três partes é incerta e depende da natureza dos dados que estão sendo usados (HASTIE; TIBSHIRANI; FRIEDMAN, 2003). Em alguns algoritmos, o treinamento e a validação confundem-se, como é o exemplo do algoritmo desenvolvido por Figueiredo e Jain (2002).

Hastie, Tibshirani e Friedman (2003) mencionaram que, caso exista número suficiente de padrões, o erro de generalização pode ser estimado diretamente do conjunto de teste, sem a necessidade do uso de técnicas analíticas ou re-utilização dos dados.

Além de comparar diferentes modelos de um mesmo tipo de classificador, o erro de generalização pode ser usado para comparar classificadores diferentes. Desta forma é possível testar diferentes abordagens de classificação para um mesmo problema.

Outra maneira de avaliar o classificador é através da matriz de confusão, uma matriz quadrada, onde as linhas representam a classe a qual um padrão pertence e as colunas representam a classe predita pelo classificador. Os valores associados aos elementos da matriz representam a quantidade de objetos classificados. Isto possibilita a compreensão de como o erro está dis-

tribuído entre as classes, ou seja, é possível visualizar a existência de falsos positivos ou falsos negativos. O caso ideal, onde não ocorreram erros, desta matriz é a matriz diagonal (COSTA; CESAR JÚNIOR, 2001).

O classificador de padrões também pode ser avaliado com relação a outros aspectos além do erro de generalização. Classificadores diferentes pode ser comparados com relação ao tempo de execução, complexidade computacional ou sensibilidade a escolha das características (COSTA; CESAR JÚNIOR, 2001).

2.3 Considerações finais

Neste capítulo foram apresentados aspectos relacionados à visão computacional, onde esta foi dividida em duas partes: processamento de imagens e reconhecimento de padrões. Foram descritos os principais espaços de cores, as principais técnicas de pré-processamento e segmentação de imagens. As técnicas de reconhecimento de padrões também foram introduzidas. Foram apresentadas as principais características de elementos relevantes à visão computacional, as técnicas de normalização e seleção de características. Também foram apresentados os principais tipos de classificadores de padrões. No próximo capítulo, serão revistos trabalhos que utilizam a visão computacional em aplicações agrícolas.

3 Visão computacional aplicada à agricultura

A visão computacional pode ser utilizada em diversas etapas da produção agrícola, como por exemplo, inspeção de produtos, coleta de dados a respeito da lavoura e colheita automática de frutos. Dentre as motivações para o emprego da visão computacional nesta área pode-se destacar:

Redução de custos - O custo de produção pode ser reduzido com o uso de técnicas precisas de aplicação de herbicidas. Normalmente, a aplicação de herbicidas é feita de forma uniforme na plantação, onde a quantidade a ser aplicada é estimada pela média da quantidade de plantas invasoras. Utilizando visão computacional para localizar e identificar as plantas invasoras, é possível aplicar o herbicida apenas sobre as plantas invasoras, o que economiza herbicida e conseqüentemente reduz o custo de produção.

Substituição da mão de obra - Além de reduzir o custo de produção, a visão computacional aplicada à agricultura pode viabilizar a automação de tarefas que antes eram realizadas somente por homens. Isto pode ser usado para substituir a mão de obra humana em países onde esta mão de obra é escassa. Exemplo disto são os sistemas de colheita automática de frutos, onde tais sistemas são dotados de câmeras de vídeo e braço robótico capaz de colher o fruto.

Aquisição de dados - A aquisição de dados a respeito da cultura pode fornecer informações importantes para o agricultor. Entretanto, coletar estes dados manualmente pode ser inviável. Além disto, quando empregados sistemas automáticos é possível colher dados de

forma mais controlada. A visão computacional tem sido aplicada para coletar tais dados. Exemplo disto são os sistemas que avaliam a incidência de plantas invasoras, sistema para contagem de frutos ou plantas e sistemas que avaliam as condições dos frutos.

Neste capítulo, são revisados trabalhos onde uma ou mais destas motivações estão presentes. Entretanto, devem ser considerados os aspectos relevantes à visão computacional. Desta forma, pretende-se compreender como as técnicas de visão computacional são aplicadas nos sistemas que operam em ambientes agrícolas. São considerados o espaço de cores, o algoritmo de segmentação e a forma como os elementos da imagem são classificados.

Os trabalhos foram separados considerando-se a aplicação da visão computacional. Na seção “localização, inspeção e colheita de frutos” são revisados os trabalhos voltados para a área de produção de frutos e na seção “localização e classificação de plantas” são revisados os trabalhos relacionados com as culturas de grãos, onde as imagens foram adquiridas próximas ao solo ou não.

3.1 Localização, inspeção e colheita de frutos

Parrish e Goksel (1977) estudaram a viabilidade de um sistema automático de colheita de frutos (maçãs) baseado em visão computacional e em um braço mecânico, como mostra a Figura 18. Os autores adotaram tal configuração com o objetivo de evitar que as maçãs fossem danificadas no processo de colheita, como ocorre quando empregados certos tipos de mecanismos. O sistema de colheita consiste em uma câmera de vídeo preto-e-branco montada sobre um mecanismo *pan-tilt* controlado por um computador. A imagem proveniente da câmera de vídeo é digitalizada e processada com o objetivo de localizar as centróides das frutas, e esta informação é usada para planejar o movimento do braço mecânico. O sistema de visão reportado neste artigo consiste das seguintes etapas: filtragem, aquisição da imagem, limiarização, digitalização, suavização e detecção das maçãs. Foi adotado um filtro vermelho com o objetivo de explorar as características cromáticas do fruto, desta forma facilitando as demais etapas. A resolução espacial da imagem digitalizada era de 144×81 *pixels*, sendo que cada *pixel* é ar-

mazenado em um *bit*. A detecção da maçã foi feita considerando-se a diferença entre os pontos extremos na vertical e na horizontal e a densidade da região, que foi calculada sobrepondo-se uma janela com tamanho igual a média dos valores extremos encontrados anteriormente. Esta janela foi centralizada sobre a centróide. A diferença dos pontos extremos e a densidade foram comparados com limiares para determinar se o elemento era uma maçã. Este sistema de visão foi capaz de identificar as maçãs, entretanto ele não foi capaz de identificar maçãs cujas centróides estavam próximas ou quando as maçãs estavam agrupadas. As maçãs ocultas pelas folhas e galhos foram desconsideradas.

Figura 18: Configuração do experimento realizado por Parrish e Goksel.

Whittaker et al. (1987) buscaram solucionar alguns dos problemas que os sistemas de visão computacional enfrentam quando operam em ambientes agrícolas. O primeiro dos problemas abordado foi o contraste entre os frutos e o resto da cena, pois alguns frutos tem cores semelhantes a das folhas e isto dificulta a segmentação dos frutos quando considerada apenas as cores. Os outros problemas encontrados foram: sombras, reflexos e, por último, localização de frutos parcialmente ocultos. A abordagem adotada pelos autores foi utilizar o detector de bordas de Sobel e a transformada de Hough para detectar círculos. A imagem adquirida pela câmera de vídeo foi filtrada com filtro verde ou vermelho. Esta imagem foi digitalizada com resolução espacial de 512×480 pixels e 256 níveis de cinza. Então, a imagem foi redimensionada para 256×240 pixels e o detector de bordas foi aplicado. A magnitude do gradiente foi limiarizada com relação

ao valor médio do gradiente, obtendo-se uma imagem binarizada. As imagens foram analisadas com a transformada de Hough com o valor do limiar setado para zero. A distribuição das alturas do acumulador foi aproximada para uma distribuição exponencial, então com base nesta distribuição foi determinado o limiar que foi aplicado ao acumulador. O autor concluiu que a transformada Hough é uma técnica aceitável para tal aplicação, entretanto devido ao uso de um computador com processador serial, o tempo de processamento foi longo. O autor afirma que tais técnicas foram capazes de operar na presença de brilhos, sombras e situações onde a fruta estava parcialmente coberta.

Slaughter e Harrell (1989) segmentaram imagens de frutas utilizando as cores como critério de homogeneidade. As imagens segmentadas foram processadas com propósito de encontrar as centróides dos elementos. Esta informação foi usada para que um braço mecânico pudesse coletar os frutos. Os autores utilizaram uma câmera de vídeo NTSC, um conversor de NTSC para RGB, três placas de aquisição de vídeo (uma placa dedicada para cada canal de cor) e um computador, conforme o esquema na Figura 19. Foram adquiridas imagens de laranjas em um pomar. Estas imagens foram selecionadas de modo que representassem as diversas situações de iluminação e fundos de cena. As imagens foram digitalizadas com resolução espacial de 384×485 *pixels* e resolução cromática de 5-bits para cada canal de cor, totalizando 32.768 cores. Estas imagens foram segmentadas em frutos e não-frutos com um classificador bayesiano. Com o propósito de reduzir o tempo de processamento, o classificador foi implementado na forma de uma tabela de busca. Os autores adotaram a distribuição normal multivariada como função de densidade de probabilidade. Os parâmetros desta função foram estimados de um conjunto de *pixels* classificados manualmente, sendo que estes *pixels* foram amostrados de uma das imagens. O classificador foi avaliado com um conjunto de testes com 13 imagens, onde 75% dos *pixels* foram classificados corretamente. A classificação e o cálculo das centróides foram implementados de forma que o sistema operou à taxa de 60Hz.

Ruiz et al. (1996) abordaram o problema da localização e caracterização de galhos e pedúnculos em laranjas. Isto faz-se importante pois galhos grandes podem causar danos a outras frutas em uma situação de transporte ou armazenamento e a ausência de pedúnculo possibilita

Figura 19: Sistema de localização de frutos proposto por Slaughter e Harrell.

a infecção da fruta. Os autores buscaram solucionar tais problemas através de um sistema de visão computacional. Também, o sistema proposto, analisa o perfil da fruta com o propósito de medir o tamanho do galho e determinar o ponto de corte deste galho, caso este tenha tamanho maior que um determinado limite. Foram adquiridas imagens de frutos com uma câmera de vídeo CCD e uma placa digitalizadora ligada a um microcomputador do tipo PC. A resolução geométrica destas imagens era de 512×512 pixels e 24-bits de resolução cromática, sendo que o espaço de cores adotado foi o RGB. Estas imagens foram segmentadas através da classificação dos pixels com um discriminador linear, que foi obtido a partir das regras de decisões bayesianas. Foi adotado como função de densidade de probabilidade a distribuição normal multivariada com covariâncias iguais para as quatro classes e médias distintas. Estes parâmetros foram estimados de um conjunto de teste com 15.877 pixels. As classes adotadas foram: fundo, casca do fruto, galho/pedúnculo e corta-galho. Este classificador foi usado para detectar as frutas sem galhos ou pedúnculos. Para isto, a soma da área classificada como galho/pedúnculo com a área classificada como corta-galho foi comparada com um limiar. Para as frutas com galhos ou pedúnculo foi estimado o ponto de entrada deste, onde foi considerada a centróide dos pixels pertencentes a classe galho/pedúnculo que estão dentro da região definida como casca do fruto. A Figura 20 mostra o esquema de um fruto, onde são mostradas as regiões do pedúnculo, casca e galho; a região onde está a entrada do galho esta dentro da elipse pontilhada. Também foram avaliadas técnicas baseadas em contorno e em esqueletização para a detecção do galho. Neste

caso foram utilizadas imagens monocromáticas do perfil da fruta, sendo que as frutas já estavam corretamente posicionadas. O classificador implementado foi testado com um conjunto de 50.427 *pixels*, que não foram usados durante o treinamento do classificador. A taxa de acerto da classificação do conjunto de testes foi de 98,86%. As técnicas baseadas em contorno e em esqueletização também mostraram-se viáveis. O autor reporta que tais técnicas não são eficientes quando os galhos possuem folhas.

Figura 20: Esquema de um fruto e regiões deste consideradas no trabalho de Ruiz et al..

Jiménez et al. (1999) adotaram imagens geradas por um sensor de distância baseado em *laser* para reconhecer e localizar frutos em uma laranjeira. As imagens deste sensor ativo não apresentam alguns problemas encontrados em imagens provenientes de câmeras de vídeo convencionais, pois, como este sensor de distância não depende da luz natural, os problemas relacionados com a baixa luminosidade, sombras e reflexos não existem. O sensor adotado gera imagens de distâncias e outra imagem com a atenuação do sinal, no caso o laser vermelho (comprimento de onda de 670nm). Os autores criaram um modelo da atenuação com o objetivo de restaurar este sinal e gerar novas imagens, as quais foram empregadas na localização dos frutos. A imagem da reflectância aparente foi usada para identificar as laranjas e a imagem de distância foi usada para localizar a laranja a partir da forma. Os resultados obtidos com os dois tipos de imagens foram integrados. O algoritmo de detecção baseado na reflectância utiliza a limiarização para segmentar a imagem. Após isto, os *pixels* espacialmente próximos uns dos outros

foram agrupados, então, as laranjas foram localizadas através de um processo de refinamento que considera a área do elemento e a informação de distância. O algoritmo de detecção de laranjas baseado na imagem de distâncias utilizou um detector de bordas criado especialmente para encontrar os frutos, então uma versão modificada da transformada de Hough foi empregada para detectar círculos. Os autores apresentam resultados parciais, dentre estes, apontam que aproximadamente 74% das frutas verdes foram localizadas, sendo que esta taxa aumenta conforme o número de frutas maduras cresce. O sistema proposto não gerou falsos positivos. Os autores comentam que o sensor adotado não foi adequado para a aplicação de colheita da frutos, pois a velocidade de aquisição dos dados é pequena (100ms entre cada aquisição).

Morimoto et al. (2000) utilizaram uma câmera de vídeo para extrair o perfil de tomates, com o propósito de avaliá-lo de forma quantitativa. Os autores buscaram a abordagem quantitativa pois as demais abordagens são baseadas em critérios subjetivos e normalmente a classificação dos tomates é feita de forma manual. Os autores avaliaram o perfil do tomate utilizando o conceito de caos, através de atratores e dimensão fractal. Os perfis foram avaliados com RNA recursivas. Os atratores são descritos por uma combinação de órbitas periódicas não estáveis que representam o perfil do tomate. A dimensão fractal foi usada como um índice para compreender as irregularidades, complexidade e periodicidade da curva que representa a forma do tomate. Os autores concluíram que tais técnicas foram capazes de quantificar as irregularidades da forma do tomate. Também sugeriram que uma combinação das três técnicas podem resultar em um sistema de classificação mais viável.

Plebe e Grasso (2001) desenvolveram um sistema de identificação e localização de laranjas para um robô de colheita de frutos. O sistema consistia em dois braços mecânicos e duas câmeras de vídeo que foram montadas no extremo destes braços. Os autores apontaram que este sistema deve lidar com as seguintes situações: grande amplitude de iluminação; elementos parcialmente ocultos; incertezas relacionadas com a forma da fruta; espaço limitado de operação, o que exige o uso de lentes grande-angular; e restrições de tempo-real. O sistema pode ser resumido segundo as etapas de processamento mostradas na Figura 21. Os autores inicialmente transformaram os *pixels*, que têm as cores representadas no espaço de cores RGB para

um espaço de cores proposto por eles. Desta forma, as laranjas foram destacadas dos demais elementos da cena. As laranjas foram encontradas quando os *pixels* foram classificados com auxílio de uma RNA. A imagem formada com o auxílio da RNA foi suavizada, limiarizada e as bordas foram detectadas, então foi feita uma análise, que considera a curvatura das bordas para encontrar os círculos que contornam os *pixels* que representam as laranjas. Este sistema foi validado com 50 imagens, onde estavam representadas 673 laranjas. O sistema foi capaz de identificar 87% das laranjas.

Figura 21: Etapas de processamento para detecção dos frutos.

Kataoka, Okamoto e Hata (2001) caracterizaram a coloração das maçãs em vários estágios de desenvolvimento com o objetivo de desenvolver um robô para a colheita destes frutos. Os autores adotaram um espectrômetro de mão Minolta CM-508i, capaz de medir comprimentos de ondas variando de 400nm até 700nm. Foram adotados os espaços de cores Munsell, $L^*a^*b^*$ e XYZ. Os autores colheram três amostras de maçãs, cada uma com seis frutos. A primeira amostra foi feita duas semanas antes da colheita dos frutos. A segunda amostra continha as frutas vermelhas. A terceira amostra continha as frutas com porções amareladas. Observando os valores das cores nos espaços de cores adotados foi possível distinguir os três grupos de frutas.

Bulanon (2001) desenvolveu um sistema de visão computacional para localizar maçãs aplicado a um robô de colheita. O autor usou uma câmera de vídeo com sensor CCD que foi conectada a uma placa digitalizadora. As imagens foram digitalizadas com resolução espacial de 240×320 *pixels* e com resolução cromática de 24-*bits*. O espaço de cores utilizado pela placa digitalizadora foi o RGB. Posteriormente, a imagem foi convertida para o modelo LCD, onde existe um canal para a intensidade da luz e outros três para as diferenças de vermelho, verde e azul. Foi adotada a limiarização ótima, que consiste em dividir o histograma em duas regiões,

tal que a divisão seja feita no vale de um histograma bimodal. Foram testadas segmentações baseadas no histograma da intensidade da luz e na diferença de vermelho. Entretanto os histogramas da intensidade da luz avaliadas não eram bimodais. O autor obteve melhores resultados quando empregada a segmentação baseada na limiarização da diferença do vermelho.

Cruvinel e Minatel (2002) desenvolveram um sistema de visão computacional para localizar e avaliar o tamanho de laranjas. Foi adotada uma câmera de vídeo Sony TR50BR e placa de aquisição de vídeo. As imagens foram digitalizadas com resolução geométrica de 256×256 pixels e 256 níveis de cinza. Os autores adotaram laranjas com diversos diâmetros, as quais foram usadas na operação de correlação, feita no espaço das frequências. O erro causado pela distância da câmera e da laranjeira foi corrigido utilizando-se um modelo de laranja com tamanho conhecido. Os autores reportaram que o sistema foi capaz de medir laranjas com diâmetro variando de 2cm até 10cm, com erro menor que 1,4%.

Aleixos et al. (2002) propuseram um sistema de visão computacional para inspeção de frutos (laranjas, limões e mandarins) em um ambiente industrial. O sistema analisava tamanho, forma, cor e defeitos externos da fruta em tempo real utilizando uma câmera multiespectral (espectro visível e infravermelho próximo) e um equipamento dotado de dois processadores de sinais digital (DSP - *digital signal processor*) para processar as imagens. A câmera multiespectral foi construída com duas câmeras de vídeo convencionais. Uma câmera foi responsável por registrar o espectro visível, que retorna uma imagem digital RGB, equipada com um filtro polarizador, que evita a ocorrência de reflexos. A outra câmera capturou imagens em preto-e-branco e foi equipada com um filtro de luz visível, que permite que apenas o infravermelho próximo passe por ele. As duas câmeras foram montadas de forma a captar a mesma cena, empregando um espelho que reflete 50% da luz para uma das câmeras, indo o restante da luminosidade para a outra câmera. O ambiente foi iluminado artificialmente. A imagem infravermelha foi usada para a análise do tamanho e da forma. Esta imagem foi limiarizada, as bordas foram detectadas e o contorno foi extraído utilizando o código de cadeia com região oito-conectada. A tangente da curva formada com o código de cadeia foi analisada para determinar se existiam laranjas encostadas uma nas outras. A imagem colorida juntamente com a imagem infravermelha foram

usadas para detectar defeitos na casca dos frutos. Os defeitos foram detectados utilizando-se um classificador bayesiano, sendo que as variáveis independentes adotadas foram os valores dos canais do RGB e o valor do infravermelho. Também, foram avaliados classificadores baseados apenas nas componentes do RGB e nas componentes vermelho, verde e infravermelha. A classificação das cores dos frutos foi feita também com um classificador bayesiano utilizando a informação do espectro visível. Os autores reportaram que o sistema foi capaz de selecionar as frutas de forma adequada. Também, sugeriram que o equipamento usado para processar as imagens seja substituído por um com o dobro da frequência de relógio, assim será possível alcançar uma taxa mínima de 10 frutas por segundo.

Gay, Berruto e Piccarolo (2002) propuseram um sistema para avaliar as cores de frutas. Este sistema considerou a coloração da fruta inteira, o que eliminou as incertezas nas avaliações feitas por sistemas pontuais. O sistema consistia de uma câmera de vídeo e uma base capaz de rotacionar. Quando a base em que o fruto estava apoiado rotacionava, um sistema disparava a câmera em intervalos regulares. As imagens obtidas foram unidas, o que resultou em uma projeção cilíndrica aproximada da fruta. Primeiro, os autores consideraram as áreas vermelhas e amarelas da maçã. Para isto, foi necessário encontrar um limiar, que separa estas duas cores, no canal de matiz do espaço de cores HSV. A primeira abordagem para obter-se o limiar foi utilizar um cartão com o referencial de cor vermelha que caracteriza a fruta madura. A segunda abordagem utilizou o julgamento de especialistas humanos. Os autores desenvolveram também um índice para caracterizar a cor da maçã. Este índice foi baseado na função acumulada do histograma do canal de matiz. Os autores pretendem utilizar este índice para avaliar se as técnicas de cultivo estão influenciando a coloração dos frutos.

Bulanon et al. (2004) desenvolveram um sistema de localização de maçãs aplicado a colheita automática. O sistema consistia em braço mecânico, garra, câmeras de vídeo, sensor de distância laser e microcomputador do tipo PC. As imagens foram adquiridas com resolução espacial de 320×240 pixels e resolução cromática de 24-bits. Estas imagens foram segmentadas em duas partes, uma com as frutas e a outra com o restante da cena. Para isto, foram utilizadas análise discriminatória e RNA. Nas duas abordagens, os pixels foram classificados utilizando-

se as componentes vermelha e verde do espaço de cores Nrgb. Após a segmentação, a imagem foi suavizada com um filtro passa baixa. As bordas foram extraídas com o detector de bordas laplaciano e, então, foram extraídas as áreas, centroídes, máximo diâmetros e mínimo diâmetros. Ambos os classificadores tiveram taxa de acerto superior a 80% em todas as condições de iluminação consideradas no trabalho. A distância até a fruta foi estimada através do método diferencial e do método binocular. No primeiro caso, a diferença de tamanho do elemento quando a câmera é deslocada é considerada para estimar a distância do elemento. No segundo caso, são usadas duas câmeras posicionadas lado a lado com os eixos óticos alinhados. Entretanto, em ambas as abordagens, não foi possível estimar a distância com um erro menor que 3%, erro máximo para a aplicação. Então, os autores adotaram um sensor de distância laser. Assim, quando as frutas fossem localizadas pelo sistema de visão, o braço mecânico posicionava-se de forma que a maior fruta estivesse no centro da imagem, então a distância era medida.

Annamalai, Lee e Burks (2004) desenvolveram um sistema de visão computacional para estimar o número de frutos em pomares de laranjas. O sistema foi composto por microcomputador tipo PC, câmera de vídeo, DGPS e encoder. A câmera foi montada 5,2m acima do solo em uma haste. A inclinação da câmera com relação a haste era de 45 graus, desta forma, o campo de visão da câmera abrange a maior parte da copa da árvore. Foram feitas 354 imagens com resolução espacial de 640×480 pixels, onde as cores foram representadas no espaço de cores HSI. A identificação dos frutos foi feita através das seguintes operações: binarização (utilizando a matiz e a saturação), limiarização (considerando-se a área dos elementos), dilatação, erosão, preenchimento e extração das características. As laranjas foram contadas considerando-se o número de elementos não conectados na imagem. Caso a área (número de pixels conectados) fosse maior que um limiar, o elemento era considerado como sendo um conjunto de frutas e foi contado como duas frutas. Este sistema de visão foi embarcado em um veículo equipado com encoder para que a distância percorrida fosse medida, assim, garantiu-se que as imagens não sobrepuham-se. A cada imagem registrada, foi executada uma leitura do DGPS, assim, cada imagem foi associada a uma coordenada geográfica. Foi constatado pelos autores que a binarização considerou apenas 58% dos pixels que representavam as frutas. Este sistema foi

testado com um conjunto de validação com 329 imagens. A regressão dos valores contados pelo sistema com os valores contados manualmente teve coeficiente de correlação R^2 igual a 0,79.

Figura 22: Elementos do sistema usado por Annamalai, Lee e Burks para contar frutas.

Stajanko, Lakota e Hocevar (2004) desenvolveram um sistema para avaliar a produção de maçãs ainda nas árvores. Os autores adotaram imagens térmicas ao invés de imagens visíveis, pois as imagens térmicas proporcionaram um maior contraste entre os frutos e as folhas, principalmente durante o período em que as frutas estavam verdes. Devido à natureza das imagens térmicas, estas foram adquiridas no final do período da tarde, pois neste período os frutos acumulam maior energia térmica, o que aumenta o contraste entre os frutos e as folhas. As imagens geradas pela câmera foram convertidas para imagens coloridas com as cores representadas pelo espaço de cores RGB. Posteriormente, estas imagens foram convertidas para o Nrgb. Foi calculado o índice da diferença normalizada dos canais verde e vermelho. Então este índice foi limiarizado. O histograma deste índice apresentou distinção entre o fundo da cena e os frutos e a

imagem foi erodida e filtrada com um filtro passa baixa. Os grupos de *pixels* quatro-conectados foram consideradas como elementos. O maior segmento dos elementos foi usado para estimar o diâmetro das frutas. As quantidades de frutas contadas manualmente e contadas automaticamente foram correlacionadas. O menor índice de correlação obtido foi $R^2 = 0,83$ no primeiro dia de medidas, o maior índice foi $R^2 = 0,88$ no último dia de medidas. O aumento do índice de correlação foi causado pelo aumento do tamanho das frutas e a mudança da coloração destas. Os diâmetros médios medidos manualmente e automaticamente foram correlacionados, o que resultou em índices de correlação variando entre 0,67 e 0,70. Estes resultados foram devidos a oclusões por folhas ou galhos, também, a diferença de temperatura na fruta (região externa mais fria que a interna) prejudicou a medida do diâmetro.

Regunathan e Lee (2005) utilizaram câmera de vídeo e sensores de ultra-som para estimar a quantidade e o tamanho de frutos em um pomar de frutas cítricas. Foram adquiridas 74 imagens com resolução espacial de 640×480 *pixels*. Foram criados um conjunto com 37 imagens para treinamento e outro com 37 imagens para testes. O tamanho dos frutos foi estimado com auxílio de um sensor de ultra-som. Foram usadas 16 imagens para o treinamento e outras 16 imagens para os teste da estimativa de tamanho. As cores das imagens eram representadas originalmente no espaço de cores RGB, entretanto foram convertidas para o espaço de cores HSL, pois segundo os autores este último espaço de cores proporcionou melhores resultados. As imagens foram segmentadas através da classificação dos *pixels* e, posteriormente, estas foram pré-processadas para a remoção de ruídos. Foram construídos três classificadores: bayesiano, baseado em RNA e baseado na discriminação linear de Fisher. Os *pixels* foram classificados considerando-se a matiz (H) e a saturação (S). As funções de densidade de probabilidade condicionais foram estimadas pelos histogramas dos valores dos *pixels*, que foram re-quantizados em 64 valores. Foram adotadas probabilidades *a priori* de 0,25 para a classe das frutas e de 0,75 para a classe de fundo de cena. A RNA era do tipo alimentada adiante com quatro camadas, a camada de entrada com dois nodos, a primeira camada escondida com 10 nodos, a segunda camada escondida com quatro nodos e a camada de saída com dois nodos. Esta RNA foi treinada com o algoritmo *backpropagation*. Para o discriminador linear de Fisher, os dados

foram projetados em uma reta. Após isto, foi encontrado um limiar que divide as duas classes. A segmentação baseada em RNA resultou em uma estimativa da quantidade de frutos com erro quadrático médio de 2,6 e a estimativa do tamanho das frutas com erro quadrático médio de 0,4cm. A reflexão não uniforme do ultra-som pelas folhas e frutos contribuiu para o erro na estimativa do tamanho. Também, frutas parcialmente ocultas, iluminação variável e frutas agrupadas prejudicaram o desempenho do sistema.

3.2 Localização e classificação de plantas

Tian e Slaughter (1998) desenvolveram um algoritmo de segmentação para imagens agrícolas, onde o resultado da segmentação é usado para detectar plantas em linhas de plantio ao ar livre, no caso pés de tomate e plantas invasoras. A Figura 23 mostra como as imagens foram adquiridas. Para atingir este objetivo, foi elaborado um algoritmo de agrupamento parcialmente supervisionado, onde um operador julga a qualidade destes agrupamentos. Caso a qualidade seja adequada o algoritmo continua. Caso contrário, novos agrupamentos devem ser encontrados. Um classificador bayesiano e uma função de densidade normal multivariada foram usados para criar a superfície de decisão. Após isto, uma tabela de busca é criada, assim, o tempo de processamento das imagens foi reduzido. Os autores adotaram esta abordagem, pois buscavam minimizar os efeitos da variação da iluminação, dos reflexos e das sombras. Inicialmente, foram realizados testes com o espaço de cores RGB. Entretanto, os autores observaram que os agrupamentos criados dependiam da intensidade da luz, então foi adotado o espaço de cores Nrgb. O algoritmo proposto foi comparado com algoritmos estáticos, que não eram adaptados as condições de iluminação. Foi observado que o algoritmo proposto tem desempenho melhor que os algoritmos estáticos na segmentação de imagens com pouca iluminação.

Tang, Tian e Steward (2000) utilizaram Algoritmo Genético (AG) para encontrar as regiões no espaço de cores que correspondem a vegetação e ao solo. Os autores adotaram AG, pois esta é uma técnica de busca adaptativa modelada segundo o conceito biológico da genética, que tem capacidade para encontrar, dentre muitas soluções, a mais adequada. A função objetivo dos

Figura 23: Esquema dos equipamentos usados durante a aquisição das imagens.

AG avalia o material genético armazenado nos cromossomos da população onde a busca é feita. Estes cromossomos são criados de forma a armazenar os dados relevantes da pesquisa a ser feita. No caso do trabalho em questão, os cromossomos armazenavam os pontos extremos da região no espaço de cores HSI que contém as cores que correspondem a vegetação. Os autores concluíram que o algoritmo de segmentação proposto tem desempenho semelhante as técnicas de agrupamento no espaço de cores.

Philipp e Rath (2002) transformaram os *pixels* representados no espaço de cores RGB de modo a binarizar uma imagem, assim destacando as folhas das plantas. Os autores adotaram uma câmera fotográfica colorida com balanço de cores automático. As imagens geradas com tal câmera tinham resolução geométrica de 2.048×1.563 *pixels*. Foram aplicadas as seguintes transformações às imagens: análise discriminatória (linear e logarítmica), transformação canônica e conversão para os espaços de cores $i1i2i3$, $i1i2i3_{new}$, HSI, HSV e Lab. Na análise discriminatória, foram usadas imagens de treino que foram manualmente segmentadas para estimar os valores médios e as matrizes de co-variâncias. A classificação resultante da análise discriminatória gerou a imagem binarizada. A transformação canônica consiste em encontrar uma transformação linear que maximize as variâncias entre os agrupamentos e minimize as variâncias dos agrupamentos. O espaço transformado foi então limiarizado manualmente e automaticamente. A limiarização automática foi feita com base nos mínimos locais do histograma. As imagens transformadas do espaço de cores RGB para os espaços HSI, HSV e Lab foram

binarizadas com a limiarização da Hamming. As imagens convertidas para o espaço de cores $i1i2i3$ e $i1i2i3_{new}$ foram limiarizadas com respeito ao canal $i3$ de forma automática e manual. Os autores concluem que a análise discriminatória gerou os melhores resultados, entretanto o custo computacional foi maior. Foi recomendado o uso dos espaços de cores $i1i2i3$ e $i1i2i3_{new}$ para aplicações que têm restrições de tempo-real.

Steward, Tian e Tang (2002), desenvolveram um aplicador localizado de herbicida baseado em visão computacional. O sistema através de uma câmera de vídeo apontada para as linhas de plantio identifica e localiza as plantas invasoras, então o veneno é borrifado sobre elas. O sistema de visão adotado foi baseado no proposto por Tian e Slaughter (1998), entretanto foi utilizado o espaço de cores HSI. Os autores constataram que o sistema de visão computacional poderia ser melhorado nos seguintes aspectos: sincronizar a captura da imagem com o sinal emitido pelo controlador do sistema, assim reduziriam o tempo entre o sinal e a captura de um novo quadro; o balanço do veículo desloca a câmera de vídeo de forma a induzir erro na localização das plantas; e a distorção causada pela lente da câmera contribuiu para o erro de localização das plantas.

Shrestha e Steward (2003) motivados pela necessidade de avaliar as técnicas de plantio de milho desenvolveram um sistema de visão computacional para determinar o número de pés de milho. Uma câmera de vídeo foi montada em um veículo agrícola a $0,60m$ acima do solo, o que resultou em um campo de visão de $0,30 \times 0,40m$; as linhas de plantio estavam espaçadas a $0,76m$. As imagens foram adquiridas com resolução espacial de $480 \times 720 \text{ pixels}$ e resolução cromática de 24-bits . O veículo percorreu com velocidade de $1m/s$ as fileiras. Estas imagens foram processadas para determinar a sobreposição em cada uma das imagens. Para isto, uma região de uma das imagens foi procurada na outra imagem, caso a região fosse encontrada, o deslocamento era calculado. Após esta etapa, a imagem foi segmentada em vegetação e fundo de cena utilizando-se uma superfície de decisão elipsoidal truncada. O espaço de cores dividido por esta superfície foi o RGB. Os pés de milho foram contados utilizando-se um conjunto de regras impostas pelos autores. O erro da estimativa da população de milho foi de 1,8.

Tang, Tian e Steward (2003) utilizaram visão computacional para classificar plantas invasoras em duas classes segundo o tipo de folha. Os autores adotaram esta abordagem pois a escolha do herbicida depende do tipo da folha e não da espécie da planta invasora. Esta abordagem simplifica o classificador de padrões. Foram plantadas várias espécies de plantas invasoras e após quatro semanas foram feitas imagens destas com uma câmera de vídeo. Estas imagens foram processadas segundo o esquema da Figura 24. As imagens digitais tinham resolução espacial de 640×480 *pixels* e resolução cromática de 24-*bits*. O espaço de cores adotado foi o RGB. As imagens foram feitas em ambiente aberto. Devido a um defeito das lentes da câmera de vídeo apenas a porção central da imagem com área de 300×250 *pixels* foi usada. Com o objetivo de minimizar a influência dos *pixels* que representam o solo na análise das folhas, a imagem foi segmentada utilizando a limiarização do índice de excesso de verde modificado. O limiar foi ajustado empiricamente. Foram utilizados descritores de texturas baseados na transformada *wavelet* de Gabor. Os autores avaliaram diversos filtros, sendo que foram adotados filtros com orientação de 90° , níveis de frequência de 4 a 7 e janela de convolução com 17×17 *pixels*. Foram amostrados aleatoriamente 150 pontos em cada imagem segmentada e foram calculados os descritores de texturas para cada um destes pontos. Então foi calculada a média dos descritores obtidos em cada uma das imagens de treinamento. Os valores obtidos foram normalizados e a norma do número complexo foi calculada. Estes valores formaram os vetores de características de treinamento. O classificador adotado foi o perceptron multicamadas treinado com o algoritmo *backpropagation*. A topologia da RNA tem quatro entradas, oito neurônios na camada escondida e dois neurônios na camada de saída. O classificador implementado foi capaz de classificar corretamente todo conjunto de teste.

Neto et al. (2003) utilizaram visão computacional para segmentar imagens de culturas e plantas invasoras. O fundo destas imagens é variado, entretanto respeita as condições de operação do sistema, ou seja, o meio oeste dos Estados Unidos. Os autores utilizaram uma câmera digital com resolução espacial de 1.280×960 *pixels* capaz de gerar imagens RGB. O tamanho dessas imagens foi reduzido para 30% com o objetivo de diminuir o tempo de processamento. As cores dos *pixels* foram convertidas para o espaço de cores HSV e foram selecionados 704

Figura 24: Etapas de processamento usadas por Tang, Tian e Steward.

pixels que foram classificados manualmente em duas classes, uma para plantas e outra para fundo de cena. Estes *pixels* selecionados foram usados no treinamento de um sistema de inferência nebulosa (SIN). O SIN foi desenvolvido inicialmente com o método de agrupamento subtrativo (*subtrative clustering*, Genfis2, disponível no Matlab 6.1) e posteriormente refinado com um sistema adaptativo nebuloso-neural (*Adaptive Neuro-Fuzzy Inference System* (ANFIS), também disponível no Matlab 6.1). Entretanto, as regras de inferências obtidas não consideram todos os valores possíveis dos *pixels*, então para solucionar este problema, os autores adotaram um algoritmo genético que ajusta os parâmetros das regras de inferência (média e desvio da função gaussiana). O algoritmo genético busca por parâmetros mais adequados considerando como função de aderência a diferença entre o excesso de verde e o excesso de vermelho em uma imagem segmentada pelo SIN. Os autores mostraram que o sistema proposto tem potencial para segmentar as imagens em questão e ainda tem capacidade de adaptar-se.

Steward et al. (2004) estudaram a distribuição das cores da vegetação em imagens de linhas de plantio para desenvolver um algoritmo de agrupamento aplicado à segmentação de imagens. Foram adquiridas 129 imagens no período da manhã e 138 imagens no período da tarde. Foram selecionadas 4 imagens de cada um dos grupos, que foram segmentadas manualmente. Não foram segmentadas manualmente outras imagens pois esta é uma tarefa tediosa. As imagens possuem resolução espacial de 640×480 *pixels* e resolução cromática de 24-*bits*. Os autores

analisaram as cores das imagens utilizando um gráfico de dispersão, onde cada ponto representa a cor de um *pixel* no espaço de cores RGB. Através deste gráfico, observaram que os *pixels* pertencentes ao fundo da cena estão agrupados em uma região cilíndrica que é colinear com o eixo da intensidade da luz. Os *pixels* pertencentes a vegetação formam um cilindro cujo eixo está em ângulo com o eixo que representa os tons verdes, sendo que este ângulo é menor que o formado com o cilindro que representa o fundo de cena. O algoritmo de agrupamento proposto foi derivado do algoritmo k-médias. Este que foi modificado para utilizar como medida de dissimilaridade a distância perpendicular entre o vetor protótipo do agrupamento e o vetor formado pelo ponto no espaço de cores, conforme ilustrado na Figura 25. Uma consequência desta abordagem foi que a influência da intensidade da luz foi reduzida. Também, os autores desconsideraram os *pixels* com valores baixos de intensidade de luz, já que estes têm pouca informação cromática. O método proposto foi usado para treinar um classificador bayesiano e este classificador foi usado para segmentar a imagem. Além do método proposto, foram empregadas outras técnicas para treinar outros três classificadores bayesianos. Estes que foram comparados com o primeiro classificador. Os classificadores foram avaliados através do índice de sucesso de segmentação (SSR - *segmentation success rate*). Este índice considera a imagem segmentada manualmente e pondera utilizando as taxas de acerto, falsos-positivos e falsos-negativos. A segmentação das imagens teve índice SSR médio de 89,6% e de 91,1% para dias nublados e ensolarados, respectivamente. Quando comparado com as demais técnicas de segmentação avaliadas, o algoritmo proposto teve desempenho superior para imagens feitas em dias ensolarados e foi o segundo melhor para imagens feitas em dias nublados.

Jafari et al. (2004) segmentaram imagens de culturas de beterrabas com objetivo de localizar plantas invasoras. Foram adquiridas 300 imagens sob várias condições de iluminação. Estas imagens tinham resolução espacial de 1.600×1.200 *pixels* e campo de visão de 70×60 cm. A resolução cromática adotada era de 24-bits. Destas imagens foram selecionadas 125 regiões, que foram redimensionadas para 8×8 *pixels*. Os 8000 *pixels* resultantes foram classificados e usados na análise discriminatória. Os autores construíram 16 funções de discriminação, duas funções para cada uma das sete espécies de plantas invasoras. Metade destas funções foi trei-

Figura 25: Distâncias entre vetor representando um *pixel* e vetores protótipos.

nada para situações com pouca iluminação e a outra para o caso contrário. Em outra abordagem os autores utilizaram apenas 4 funções de discriminação. Duas funções para identificar folhas de beterrabas e duas para identificar todas as sete plantas invasoras, onde duas das funções foram treinadas com imagens com pouca iluminação e as outras para o caso contrário. Foi incluído ao algoritmo de segmentação um limiar para a luminosidade. Assim, o algoritmo decide qual conjunto de funções usar. Por fim, o algoritmo uniu o resultado de todas as funções utilizando o operador lógico “ou”. As funções de discriminação tiveram melhor taxa de acerto no caso em que as imagens tinham melhor luminosidade. A abordagem que utiliza quatro funções de discriminação teve melhor taxa de acerto que a outra abordagem.

Noble e Brown (2004) buscaram através da visão computacional propor um sistema de taxonomia de plantas. Para isto, os autores propõem avaliar as características espectrais e morfológicas das plantas considerando-se a planta inteira, não apenas as folhas. Como consequência disto, pretendem desenvolver um arcabouço para identificação automática de plantas. Os autores desenvolveram um espectrômetro dotado de uma câmera CCD com resolução espectral de 10-bits e capaz de registrar imagens em 115 bandas, onde o comprimento de ondas varia

entre 400nm e 1.000nm. Também, foram montadas duas câmeras de vídeo de forma que sejam captadas imagens da parte superior e da parte lateral da planta.

Orlando, Pinto e Queiroz (2004) desenvolveram um sistema de visão computacional para identificar milho e plantas daninhas. Os autores utilizaram descritores de textura e um classificador bayesiano. Foram adotadas duas câmeras de vídeo, uma capaz de registrar imagens coloridas e o infravermelho próximo e outra câmera imagens em tons de cinza. As imagens usadas neste trabalho foram adquiridas no período noturno, onde o ambiente, casa de vegetação, foi iluminado com uma lâmpada com potência de 900W. A câmera colorida foi posicionada a 1,32m, 1,58m e 2,04m das plantas. A câmera preto-e-branca foi posicionada a 1,35m, 1,61m e 2,04m das plantas. As imagens geradas pela câmera colorida foram digitalizadas com resolução espacial de 1.392×1.039 pixels. As imagens geradas pela câmera preto-e-branco foram digitalizadas com resolução espacial de 768×494 pixels. A partir das imagens adquiridas pela câmera colorida foram geradas três imagens: uma somente com o canal verde do RGB, outra com o excesso de verde e a última com o infravermelho próximo, sendo que estas imagens foram quantizadas em 32, 64, 128 e 256 níveis. Foram amostradas regiões de interesse com tamanhos diferentes de cada uma das imagem, entretanto, posicionadas na mesma região. Foram calculadas as matrizes de co-ocorrência, para cada uma destas regiões. Os descritores calculados a partir dessas matrizes foram: momento angular, média, variância, entropia, correlação, momento do produto e momento inverso da diferença. Os descritores formaram 300 vetores de características, sendo que 200 foram escolhidos aleatoriamente para treinar o classificador, os demais foram usados para testar o classificador. Os autores concluíram que o classificador teve melhor taxa de acerto quando utilizadas regiões com tamanho de 68×68 pixels; não houve muita influência da quantização; e a maior altura da câmera colaborou para o aumento da taxa de acerto.

Dainese et al. (2004) utilizaram imagens para localizar as áreas de incidência de plantas invasoras em uma plantação de milho. As imagens foram adquiridas através de uma câmera fotográfica embarcada em um aeromodelo. Foram adquiridas 1.794 imagens com resolução espacial de 2.560×1.920 pixels, onde cada pixel corresponde a uma área de 2×2 cm. A clas-

sificação dos *pixels* em plantas invasoras foi implementada através de uma RNA. A quantidade de *pixels* classificados como plantas invasoras foi avaliada e a partir disto foram construídos os mapas temáticos, que foram usados na aplicação localizada de herbicidas.

Neto, aes e Jorge (2004) avaliaram o desempenho de um classificador baseado em RNA implementado no *software* AGGeoImagem (AGX Tecnologia Ltda.) e dos classificadores Maxver, Maxver-ICM, distância euclidiana e Bhattacharya implementados no *software* Spring do INPE (Instituto Nacional de Pesquisas Espaciais). Os autores utilizaram tais classificadores para segmentar uma imagem de cultura de soja, que foi adquirida com uma câmera embarcada em um avião, que vôou a 100m de altura desta cultura. Esta imagem tinha resolução espacial de 1.030×1.423 *pixels*, totalizando 1.465.690 *pixels*. Os autores a segmentaram manualmente em três classes distintas: cultura, entrelinha e invasora. Foram amostrados dois conjuntos de segmentos, um que foi utilizado pelo *software* AGGeoImagem e outro pelo Spring. Estes dois conjuntos foram formados por 87 amostras da classe cultura, 118 da classe entrelinhas e 43 da classe invasoras. A avaliação dos resultados foi feita com base na área classificada corretamente, Para isto, foi empregada a imagem segmentada manualmente. Os resultados apresentados mostram que a RNA adotada pelo *software* AGGeoImagem teve melhor índice de classificações corretas.

3.3 Considerações finais

Foram revisados os artigos que tratam sobre visão computacional aplicada à agricultura. Os trabalhos mostram aplicações voltadas para diversas áreas, deste o reconhecimento de plantas invasoras a partir de imagens aéreas até o reconhecimento de frutos e folhas em imagens adquiridas próximas as plantas. Nestes trabalhos os autores utilizam diversos espaços de cores, sendo que até mesmo o espaço de cores RGB é empregado, mesmo tendo limitações. Os algoritmos de segmentação utilizados nestes trabalhos são na maioria baseados na classificação supervisionada dos *pixels* e posterior processamento da imagem para a remoção de ruídos. Alguns dos autores, devido às restrições de tempo-real, adotaram algoritmos de segmentação mais simples.

Em alguns trabalhos, a segmentação e a identificação do segmento confundem-se de forma a eliminar etapas intermediárias. Isto traz vantagem para as aplicações que devem processar as imagens rapidamente, entretanto tal abordagem torna o sistema específico para aquela aplicação. No próximo capítulo, a abordagem para o reconhecimento de cenas adotada neste trabalho é apresentada.

4 *Desenvolvimento*

4.1 Introdução

A arquitetura usada para reconhecer os elementos da cena agrícola envolvendo imagens de pomares de laranjeiras tem duas partes principais: a segmentação da imagem e a classificação destes segmentos, conforme a Figura 26. Neste trabalho, tal arquitetura é explorada quando as imagens são segmentadas e, então, os experimentos são realizados com tipos diferentes de vetores de características e classificadores de padrões. A seguir são descritos os materiais e métodos usados nestes experimentos.

Figura 26: Arquitetura para o reconhecimento de cenas.

4.2 Caracterização das imagens

Neste trabalho são usadas imagens de laranjeiras, as quais foram adquiridas em diferentes dias e horários, durante a época em que as frutas estavam maduras. A distância da câmera com relação às árvores é livre; também, a distância da câmera até o solo é livre. A resolução espacial destas imagens é de 2.048×1.536 *pixels* e a resolução cromática é de 24-*bits*. As imagens foram armazenadas em arquivos do tipo JPEG. Um conjunto de 658 imagens forma o banco de

imagens, que é dividido em três grupos principais: um que mostra as árvores desde o solo até o topo, outro que mostra apenas folhas e frutos e, o último, que mostra as fileiras de árvores, o solo e o céu.

O primeiro grupo mostra grande parte das árvores (fig. 27), logo, devido à resolução das imagens, os frutos são representados por poucos *pixels*. Podem ser encontrados frutos parcialmente ocultos por folhas e galhos e, também, podem ser encontrados frutos sob condições extremas de iluminação. Tanto os frutos como as folhas refletem a luz de modo a gerar reflexos, ou seja, regiões com a intensidade da luz muito alta. Alguns frutos tem como fundo outros elementos ao invés das folhas e galhos das árvores. A forma irregular das árvores, devido ao crescimento desordenado dos galhos, influencia a iluminação da copa de modo a criar regiões sombreadas e regiões iluminadas. A proximidade das árvores e o crescimento irregular dificultam a identificação das fronteiras entre as plantas. A fronteira entre árvore e solo confunde-se, pois a vegetação do solo mistura-se com as folhas e galhos das árvores. O solo nessas imagens é parcialmente coberto por vegetação rasteira e quando ele não está coberto apresenta coloração avermelhada. Existem regiões do solo iluminadas e pouco iluminadas. O céu é claro e sem nuvens, onde os tons de cores variam entre o branco, quando muito claro, e o azul.

O segundo grupo mostra folhas, frutos e galhos. Neste caso, as imagens foram adquiridas mais próximas às árvores, assim, folhas, frutos e galhos estão representados por uma quantidade maior de *pixels*, como pode ser visto na Figura 28. As frutas apresentam mais detalhes, onde é possível observar alguns defeitos destas. Devido ao tamanho das frutas estas apresentam gradações de cores. Os frutos também estão sujeitos a oclusões causadas pelos outros elementos da cena. As sombras e reflexos estão presentes nestas imagens, devido a iluminação não difusa. Entre os galhos e folhas das árvores é possível ver o céu, que tem cor variando do branco para o azul.

O último grupo é caracterizado por uma visão geral das linhas de plantio, onde é possível observar o corredor cercado pelas árvores, como pode ver visto na Figura 29. O corredor é coberto por vegetação rasteira e em algumas regiões o solo está exposto. Não é possível observar

Figura 27: Exemplos de imagens do grupo que mostra a maior parte da árvore.

Figura 28: Exemplos de imagens do grupo que mostra folhas, frutos e galhos.

com clareza as fronteiras entre as árvores. Nas árvores mais próximas à câmera é possível ver alguns frutos, entretanto estes são representados por poucos *pixels*.

Figura 29: Exemplos de imagens do grupo que mostra as linhas de plantio.

4.3 Ferramentas computacionais

Os algoritmos usados neste trabalho foram implementados para o ambiente Octave (EATON et al., 2006), um ambiente para computação numérica que disponibiliza ao usuário uma linguagem de programação de alto nível. Esta linguagem é muito semelhante à usada no Matlab (*The MathWorks, Inc.*).

Os algoritmos que processam, segmentam e extraem as características dos elementos foram implementados em C++ como módulos do Octave. As RNA foram construídas, treinadas e testadas com os módulos para Octave da biblioteca Fann (*Fast Artificial Neural Network*) (NISSEN et al., 2006). Os classificadores bayesianos e as estimativas das funções distribuição de probabilidade foram implementados com o *toolbox* desenvolvido por Paalanen et al. (2006).

A linguagem do Octave foi usada para integrar estes módulos possibilitando a realização dos experimentos propostos. O Octave fornece também ao usuário ferramentas matemáticas para trabalhar com os dados obtidos após os experimentos portanto, o Octave, módulos e *toolbox* juntos constituem um ambiente adequado para trabalhar com visão computacional.

A interface gráfica para classificar manualmente os segmentos foi implementada na forma de um sítio dinâmico da *web*. Os programas deste sítio foram implementados em PHP e Javascript e as páginas foram construídas com HTML e SVG. PHP é um pré-processador para a construção de sítios dinâmicos que disponibiliza ao usuário uma linguagem de programação semelhante a linguagem C. Os programas escritos em PHP são embutidos no código HTML ou no código SVG. Os códigos processados pelo PHP são enviados ao cliente através do servidor *web* Apache. A linguagem de marcação SVG é empregada para a construção de gráficos vetoriais, semelhante ao HTML, pois ambas são baseadas no XML. Javascript é uma linguagem de *script* que funciona na parte cliente da aplicação, podendo ser usada para melhorar a interatividade do sítio.

4.4 Métodos

Neste trabalho foi adotada uma arquitetura modular para o reconhecimento de cenas, pois buscou-se desenvolver um sistema que pudesse ser adaptado para outras aplicações, sejam estas voltadas para o cultivo de citros ou para outras culturas. Devido a esta abordagem, a segmentação e a classificação dos segmentos são duas etapas claramente distintas, ao contrário do adotado normalmente nos trabalhos da área agrícola.

Primeiro a imagem é segmentada com um algoritmo projetado para segmentar vários tipos de imagens de forma não supervisionada. O usuário não fornece informação a respeito do que deve ser segmentado; somente a imagem é fornecida ao algoritmo. O uso de um algoritmo não supervisionado aumenta a flexibilidade do sistema de modo a proporcionar capacidade de adaptação a situações semelhantes para a qual o sistema foi proposto. Também, facilita a expansão do sistema para outros campos de atuação.

Após a segmentação, a classificação dos segmentos é feita de forma automática. Entretanto, entre estas duas etapas é necessário descrever os segmentos de forma que estes possam ser reconhecidos pelo classificador. O processo de obter as características dos segmentos é uma conexão entre a segmentação e o classificador de padrões. Desta forma é possível, caso seja necessário, adaptar o algoritmo de segmentação sem necessariamente alterar o classificador; a situação inversa também é válida.

As características obtidas dos segmentos podem ser reconhecidas de várias formas: critério imposto, classificação por exemplos ou critério aberto. A primeira abordagem é adequada quando é conhecido o que torna um segmento membro de uma classe. O reconhecimento de padrões por critério aberto é adequado quando explora-se os segmentos em busca de agrupamentos desconhecidos. A classificação por exemplos é adequado para situações onde não há certeza sobre o que faz um segmento pertencer a uma determinada classe.

Neste trabalho o objetivo foi identificar os elementos de cenas agrícolas, especificamente em um pomar de laranjas. Devido às condições desses ambientes (iluminação variável, oclusões, mudança na tonalidade das folhas, frutos etc), a caracterização de um elemento torna-se mais complexa. Por isso, os autores dos vários trabalhos mencionados buscam desenvolver algoritmos robustos com relação a estes aspectos. Apesar destas dificuldades, é possível extrair exemplos suficientes de forma que a maioria dessas situações sejam contempladas. Com a disponibilidade de exemplos pode-se empregar um classificador baseado em exemplos.

As etapas que compõem o presente trabalho, portanto, compreendem: segmentação das imagens, cálculo das características dos segmentos, classificação dos segmentos e, por último, é gerada a imagem com as classes. A Figura 30 ilustra tais etapas.

Figura 30: Etapas de processamento para obter-se os segmentos classificados.

Como foi adotada a classificação supervisionada, alguns segmentos das imagens devem ser classificados manualmente. Foi desenvolvido para este trabalho uma interface gráfica que auxilia nesta tarefa. Tal interface é apresentada a seguir, juntamente com as demais técnicas empregadas.

4.4.1 Segmentação das imagens

Cenas naturais exigem que o algoritmo de segmentação considere a cor dos elementos pois, como foi visto, vários elementos da cena agrícola podem ser distinguidos pela cor, como por exemplo os frutos. Além da cor, a textura dos elementos também é importante, pois imagens de cenas naturais podem ser formadas por regiões de cor não homogênea. Imagens com regiões de cor homogênea podem ser segmentadas usando-se um algoritmo para formar agrupamentos no espaço de cores (MOREIRA; COSTA, 1996; COMANICIU; MEER, 1997; TIAN; SLAUGHTER, 1998). Uma das maneiras de segmentar imagens com texturas é considerar a disposição espacial dos *pixels* usando uma técnica de crescimento de região, onde um critério de homogeneidade é definido e os *pixels* que satisfazem este critério são agrupados à região (GONZALEZ; WINTZ, 1987). Além disso, para segmentar imagens com texturas é importante considerar diferentes escalas da imagens. Faz-se necessário, portanto, escolher um algoritmo de segmentação adequado para imagens de cenas naturais em cores e com texturas. Este algoritmo deve ser automático, ou seja, não exigir ajustes dos parâmetros para cada imagem, pois assim não será necessária a interferência do usuário. Também, o algoritmo deve considerar as texturas de forma simples. O algoritmo JSEG foi escolhido, pois tem tais características. Os autores do JSEG reportam na literatura da área, que o algoritmo segmenta adequadamente imagens de cenas naturais.

O algoritmo JSEG segmenta as imagens em três etapas: quantização do espaço de cores, crescimento de regiões e junção das regiões com cores semelhantes, como mostrado na Figura 31. Na primeira etapa, o espaço de cores é quantizado com pouca degradação usando o algoritmo perceptivo de quantização (DENG et al., 1999). O objetivo desta etapa é definir as regiões da imagem utilizando um mínimo de cores. Cada cor é associada a uma classe. A imagem original tem os *pixels* substituídos pelas classes, o que dá origem ao mapa de classes que será

usado na próxima etapa.

Figura 31: Etapas de processamento do algoritmo de segmentação JSEG. Figura adaptada (DENG; MANJUNATH; SHIN, 1999).

Antes de realizar o crescimento das regiões, a J-imagem deve ser criada. Os valores dos *pixels* da J-imagem serão usados como critério de similaridade pelo algoritmo de crescimento de região. Os valores dos *pixels* da J-imagem são chamados de valores J. Estes valores são calculados a partir de uma janela posicionada sobre o mapa de classes, onde o valor J a ser calculado é o do pixel no centro da janela. Para calcular um valor J, primeiro define-se Z como o conjunto de todos os pontos do mapa de classes, então faz-se $z = (x, y)$ com $z \in Z$ e m é a média de todos os elementos em Z . C é o número de classes obtido na quantização. Então,

Z é classificado em C classes. Os Z_i são os elementos de Z que pertencem à classes i , onde $i = 1, \dots, C$; m_i são as médias dos elementos em Z_i . O valor de J é calculado com a equação 4.1, onde $S_T = \sum_{z \in Z} \|z - m\|^2$ e $S_W = \sum_{i=1}^C \sum_{z \in Z} \|z - m_i\|^2$.

$$J = \frac{S_B}{S_W} = \frac{(S_T - S_W)}{S_W} \quad (4.1)$$

São usados diversos tamanhos de janelas; janelas maiores detectam as fronteira de regiões com texturas. Janelas menores detectam mudanças de cores e/ou de intensidade da luz. Cada tamanho de janela está associado a uma escala de análise da imagem. O conceito de J-imagem juntamente com as diversas escalas torna possível a segmentação de regiões com texturas.

As regiões da J-imagem com os menores valores são chamadas de vales. Os menores valores são encontrados com uma heurística proposta pelos autores, na qual são considerados vales regiões com valores J menor que um limiar. Este limiar leva em consideração a média mais uma fração do desvio padrão dos valores J em uma região. Assim é possível determinar os pontos iniciais do crescimento de forma eficiente. Então, o algoritmo agrega as regiões que são mais semelhantes aos vales. O fim do algoritmo ocorre quando não há mais *pixels* para serem agregados às regiões.

A J-imagem é recalculada para cada uma das novas regiões com uma janela menor que a usada anteriormente. Após o uso da menor janela o algoritmo agrupa as regiões com cores semelhantes. O algoritmo utiliza como característica dos segmentos o histograma das cores quantizadas que foram obtidas anteriormente. A distância euclidiana é usada para criar uma tabela que contém as distâncias entre as características dos segmentos vizinhos. As regiões com distância menor que um limiar são agrupadas, então, a tabela de distâncias é recalculada e as demais regiões são agrupadas. Este processo é repetido até que não existam regiões com distância menor que o limiar.

Este algoritmo necessita de apenas três parâmetros para funcionar: o primeiro é o limiar do algoritmo de quantização das cores, que está relacionado com a quantidade de cores que serão usadas; o segundo é o número de escalas, este influência como o JSEG trata os detalhes

das imagens e o último é o limiar usado pelo algoritmo para agrupar as regiões com cores semelhantes.

Como a segmentação da imagem é um processo subjetivo, escolher os parâmetros ótimos é uma tarefa difícil, por isto os parâmetros e a resolução da imagem foram escolhidos manualmente neste trabalho com o auxílio da inspeção visual das imagens segmentadas. Os parâmetros e a resolução que resultam na segmentação das regiões de folhas, céu e frutos foram adotados. Neste processo, os frutos determinam os parâmetros e a resolução, pois estes podem ser os menores elementos que devem ser segmentados.

O valor escolhido para o limiar da quantização é o 10. A escala inicial é a dois e a final é a um, que correspondem respectivamente às janelas com 17×17 *pixels* e com 9×9 *pixels*. A resolução espacial das imagens é de 2.048×1.536 *pixels*. Optou-se por não executar o algoritmo de fusão de regiões, pois os segmentos serão classificados posteriormente, o que resultará na fusão dos segmentos que pertencem a mesma classe.

Devido à resolução espacial adotada e à limitação da quantidade de memória do micro-computador usado neste trabalho foi necessário segmentar as imagens por partes. As imagens foram divididas em partes com tamanho de 512×384 *pixels*, as quais foram submetidas ao algoritmo de segmentação. Os segmentos vizinhos que estão nas bordas das partes são unidos após a classificação dos segmentos.

4.4.2 Classificação manual dos segmentos

Ao construir um classificador de padrões é necessário utilizar um conjunto de dados para avaliar seu desempenho. Além disto, alguns classificadores exigem um conjunto de dados que será usado no treinamento. Neste trabalho foram extraídos das imagens segmentos que foram classificados manualmente, tarefa esta viabilizada com um programa computacional dotado de interface gráfica.

A interface gráfica foi construída utilizando-se das tecnologias para a *web*, sendo composta da parte cliente, que funciona através do navegador *web* do usuário, e da parte servidora, que

utiliza o servidor *web* Apache e o pré-processador PHP. A parte servidora é responsável por gerar a página onde é apresentada a imagem segmentada. Também a parte servidora é responsável por coletar os segmentos classificados e devolver ao usuário um arquivo texto com estas informações. A parte cliente utiliza HTML, SVG e Javascript para possibilitar ao usuário selecionar um segmento e classificá-lo. Assim que o segmento é classificado, esta informação é enviada ao servidor através de um método disponível pelo navegador na linguagem Javascript.

Após a segmentação foram selecionados 8.775 segmentos de 40 imagens. Tais segmentos foram classificados manualmente com o auxílio da interface gráfica (Figura 32) nas classes: folhas, céu e frutos. Foram selecionadas apenas 40 imagens dentre as 658 imagens, pois, mesmo com esta interface gráfica, classificar os segmentos é uma tarefa trabalhosa. Entretanto tais imagens representam de forma adequada os três tipos de imagem existentes no banco de imagens, ou seja, existem imagens com várias condições de iluminação.

Figura 32: Interface gráfica para selecionar e classificar segmentos.

Estes segmentos foram separados em dois conjuntos: o primeiro é o conjunto de treinamento, com 7.936 segmentos, e o segundo é o conjunto de teste, com 839 segmentos que são selecionados aleatoriamente. Os conjuntos de teste e de treinamento não possuem intersecção.

4.4.3 Características dos segmentos

Muitos dos sistemas de visão computacional necessitam caracterizar imagens ou objetos presentes nas imagens manipuladas pelos mesmos. Neste trabalho no entanto, são usados os elementos segmentados da imagem e não a imagem como um todo, pois o objetivo é identificar os elementos que compõem a cena. Como foi visto, os elementos são representados por um ou mais descritores, os quais originam o vetor de características. Os descritores escolhidos devem descrever as propriedades relevantes dos elementos.

O uso das cores para descrever os elementos é bastante comum em sistemas de visão computacional agrícolas, pois é comum encontrar distintas cores para distintas partes de uma planta, então, a cor pode descrever adequadamente os elementos de interesse, como por exemplo, as frutas (NETO et al., 2003), (STEWART et al., 2004), (ANNAMALAI; LEE; BURKS, 2004), (PLEBE; GRASSO, 2001). Também é possível usar a textura como característica (TANG; TIAN; STEWART, 2003).

Os descritores adotados neste trabalho são os histogramas de cada eixo do espaço de cores. Esta abordagem é computacionalmente mais viável que o histograma tridimensional e apresenta as vantagens dos histogramas descritas anteriormente. Além disto, no caso desta aplicação, o histograma representa os valores de todos os componentes de cores do elemento, evitando que esta informação seja perdida, como ocorre em descritores que sintetizam esta informação em poucos valores. Exemplos disto são as medidas de tendência central, onde os valores menos representativos não tem peso sobre a característica. Apesar do vetor de características não considerar a informação de cor como um todo, este é um vetor de características adequado para representar o conteúdo pictórico dos segmentos (MANJUNATH et al., 2001).

Para completar a definição do descritor adotado neste trabalho é necessário escolher o espaço de cores e a quantidade de categorias dos histogramas. Cada espaço de cores tem suas qualidades, por isto é necessário escolher o mais adequado para a aplicação em questão. Neste trabalho, as imagens estão sujeitas às influências da iluminação, além disto, estão presentes sombras e reflexos. É conhecido que os espaços de cores que separam a informação cromática

da luminosidade são mais robustos a estas situações. Dentre estes espaços de cores o HSV mostra-se adequado a esta aplicação. Também, foi adotado o espaço de cores RGB, o que torna possível comparar os classificadores que utilizam os vetores de características derivados deste espaço com os derivados do espaço de cores HSV.

A quantidade de categorias influencia a quantidade de memória necessária para armazenar os vetores de características e, também, o tempo de treinamento e da classificação. Como existe interesse em caracterizar os segmentos de forma adequada e um menor interesse na velocidade geral do sistema, optou-se por escolher o número de categorias que corresponde a resolução dos valores das cores que é de 256 valores. Diferentemente do adotado por Manjunath et al. (2001), optou-se por utilizar histogramas com a mesma quantidade de categorias para todos os canais, não havendo perda de informação. Então, os vetores de características terão 768 dimensões.

4.4.4 Normalização e extração das características

O conjunto de treinamento foi particionado de modo a gerar cinco conjuntos de treinamento. Cada conjunto de treinamento possui vetores que distam da centróide da classe uma porcentagem da distância euclidiana entre a centróide e o vetor mais distante. As porcentagens usadas são 20%, 30%, 50%, 70% e 100%. Com isto, pretendeu-se avaliar o desempenho do classificador quanto este está sujeito a conjuntos de treinamento onde os vetores estão mais dispersos ou não.

A distribuição dos vetores nas classes para cada porcentagem é mostrada na tabela 2, para o caso dos vetores de características originados do espaço de cores RGB. Para o caso do espaço de cores HSV, os valores são apresentados na tabela 3.

Tabela 2: Distribuição dos vetores nas classes para o caso RGB.

	laranjas	folhas	céu	total
20%	1110	5602	35	6747
30%	1278	5997	117	7392
50%	1349	6283	225	7857
70%	1363	6297	261	7921
100%	1364	6297	275	7936

Além da dispersão dos vetores no espaço de características, o classificador deve lidar com

Tabela 3: Distribuição dos vetores nas classes para o caso HSV.

	laranjas	folhas	céu	total
20%	566	5405	31	6002
30%	1155	6029	89	7273
50%	1331	6277	209	7817
70%	1363	6297	255	7915
100%	1364	6297	275	7936

a dimensionalidade. Os descritores adotados originam vetores de características com 768 dimensões. Tal quantidade de dimensões pode dificultar o treinamento dos classificadores, devido à “maldição da dimensionalidade”. “Maldição da dimensionalidade” é o nome dado às conseqüência do aumento exponencial do volume do espaço, quando o número de dimensões aumenta. Do ponto de vista do aprendizado de máquina, isto significa que será necessário um conjunto de treinamento maior, ou seja, o conjunto de treinamento cresce exponencialmente com o número de dimensões (HASTIE; TIBSHIRANI; FRIEDMAN, 2003).

Tal fato levou à utilização da ACP (análise de componentes principais) para reduzir o número de dimensões. A transformação realizada pela ACP é feita no conjunto de treinamento, o qual já teve os vetores mais distantes eliminados. A mesma matriz de transformação empregada no conjunto de treinamento é então usada para transformar o conjunto de testes. A Figura 33 mostra de modo esquemático como a transformação dos conjuntos foi realizada.

Após a ACP, os dados são normalizados com a equação 2.43, onde o conjunto de treinamento transformado pela ACP é usado para calcular o valor da média e do desvio padrão. O conjunto de teste transformado também é normalizado utilizando-se a média e o desvio padrão encontrados anteriormente. A normalização adotada apenas modifica a média e o desvio padrão dos dados, ou seja, a distância entre os elementos é modificada mas as demais relações topológicas são mantidas.

4.4.5 Classificação automática dos segmentos

Até este ponto, foram definidos os vetores de características e o modo como eles foram transformados e normalizados. Após a normalização foram obtidos dez conjuntos de treinamento, onde cinco são baseados no espaço de cores RGB e os outros no HSV. Cada um destes

Figura 33: Esquema da transformação realizadas nos conjuntos de treinamento e teste.

conjuntos é usado no treinamento dos classificadores de padrões, sendo que são construídos classificadores capazes de classificar vetores com diferentes números de dimensões. São avaliados vetores de características com até 20 dimensões, assim é possível determinar qual o número ideal de dimensões para estas condições. Além destes fatores, são avaliados os desempenhos de diferentes abordagens de classificação: a abordagem que utiliza RNA e a abordagem estatística que usa o teorema de Bayes.

Classificadores de padrões baseados em RNA são robustos com relação a ruídos, conseguem extrapolar os dados em um determinado domínio, são rápidos, pois o custo computacional da classificação é baixo, e têm capacidade para aprender superfícies de decisão não-lineares (HAYKIN, 1999). Estas qualidades são interessantes para este trabalho, pois a dispersão dos vetores no espaço de característica não é conhecida e, por consequência disto, as superfícies de decisão também não são conhecidas. Entre as diversas arquiteturas de RNA existentes, as redes alimentadas adiante são adequadas para classificar padrões. Dentre estas redes, o perceptron multicamadas pode ser treinado para classificar estes tipos de dados, sendo que o tempo de treinamento desta arquitetura de RNA é muito alto.

A abordagem estatística utiliza o teorema de Bayes para calcular a probabilidade de um determinado padrão pertencer a uma classe. Esta abordagem fornece um valor que relaciona um vetor a uma classe; este valor é dado na forma de probabilidade. Isto possibilita ao sistema tomar uma decisão mais criteriosa com relação a classificação. Também, devido a isto é possível associar um custo a cada decisão. Esta abordagem exige que a função distribuição de probabilidade e a probabilidade *a priori* sejam conhecidas. Caso não sejam conhecidas, devem ser estimadas.

A seguir as três técnicas de classificação são apresentadas.

Classificador baseado em redes neurais artificiais

Neste trabalho, cada tipo de vetor de características é classificado por uma RNA de topologia adequada, ou seja, a quantidade de entradas das redes deve ser compatível com o número de dimensões. Além disso, são treinadas RNA com o iRprop para os diversos conjuntos de treinamento e espaços de cores, o que resulta em 190 tipos de RNA. Todas as topologias dessas redes tem uma camada escondida com 10 neurônios e a camada de saída tem três neurônios, cada um representando uma das classes de segmentos, como mostra a Figura 34.

Figura 34: Esquema da topologia das RNA.

Todos os 190 tipos de topologias foram treinados três vezes com os padrões de treinamento

até o erro quadrático médio (EQM) ser menor que 0,0001 ou o número de iterações do algoritmo ser igual a 200.000. Os padrões de treino foram embaralhados antes de cada treinamento. A função de ativação dos neurônios é a tangente hiperbólica com o parâmetro igual a 0,9. Os pesos sinápticos dos neurônios foram iniciados com valores aleatórios. Os demais parâmetros do algoritmo de treinamento usam os valores padrão da biblioteca FANN.

Classificador baseado no teorema de Bayes

Estes classificadores utilizam o teorema de Bayes para calcular a probabilidade de um vetor de características pertencer a uma classe. Para isto é necessário estimar as probabilidades *a priori* e as FDCP.

O algoritmo de Figueiredo-Jain foi usado para estimar as FDCP de cada classe a partir dos conjuntos de treinamentos. Como é feito para os classificadores baseados em RNA, são estimadas FDCP para cada uma das quantidades de dimensões, ou seja, de duas até 20 dimensões, de cada um dos conjuntos de treinamento, sendo que para cada um destes casos, as FDCP são estimadas três vezes. Então, a classificação do conjunto de testes é feita com a equação 2.55, a classificação que resultar na maior taxa de acerto é escolhida e as duas outras são descartadas. Os parâmetros do algoritmo de Figueiredo-Jain são os padrões do *toolbox* de Paalanen et al. (2006).

Classificador Ingênuo de Bayes

O treinamento e a avaliação deste classificador são feitos da mesma forma que no classificador baseado no teorema de Bayes. Entretanto a FDP é estimada a partir das FDP de cada uma das características.

4.4.6 Avaliação dos classificadores

Os algoritmos de treinamento adotados buscam aproximar a solução ideal, entretanto as estratégias para atingir tal meta resultam em soluções diferentes cada vez que o algoritmo é executado. Por isto, todos os classificadores foram treinados três vezes, evitando desta forma que os resultados destes treinamentos fossem equivocados.

Toda vez que um classificador foi treinado, este foi avaliado com o conjunto de teste. Após o conjunto de teste ser classificado, a taxa de acerto foi calculada. Entre os três classificadores treinados, o que obteve melhor taxa de acerto para o conjunto de teste foi escolhido. O classificador escolhido foi comparado com os demais, sendo considerados o número de dimensões, conjunto de treinamento, tipo de classificador e espaços de cores.

Além da taxa de acerto, este trabalho adotou as matrizes de confusão. Também os resultados dos classificadores foram avaliados de forma qualitativa, através do mapa de classes.

Taxa de acerto

A taxa de acerto pode ser definida como o número de segmentos classificados corretamente sobre o total de segmentos. São calculadas duas taxas de acerto para cada um dos classificadores. A primeira é a taxa de acerto calculada a partir do conjunto de treinamento e a segunda é calculada a partir do conjunto de testes, adequada para avaliar a capacidade de generalização do classificador.

Matrizes de confusão

A taxa de acerto fornece o desempenho global do classificador. Entretanto, é necessário determinar a influencia de cada uma das classe sobre a taxa de acerto. Tal análise é possível através das matrizes de confusão, pois estas mostram a quantidade de padrões classificados corretamente e incorretamente para cada uma das classes.

Mapa de classes

Como este trabalho lida com a classificação de segmentos em imagens, a visualização dos resultados através de imagens é interessante, entretanto esta abordagem é adequada apenas para avaliação qualitativa do funcionamento total do sistema (segmentação e classificação) e não para a avaliação quantitativa, como a feita através das taxas de acerto e das matrizes de confusão.

Estes mapas são construídos atribuindo-se aos *pixels* dos segmentos uma cor que representa uma classe. Os classificadores usados para gerar os mapas de classes são os que apresentam melhores taxas de acerto para a classificação do conjunto de testes, desta forma foram selecionados seis classificadores (três para cada espaço de cores, onde cada um dos três corresponde a um tipo de classificadores). Os valores produzidos pelos classificadores foram avaliados segundo dois critérios: primeiro os valores são comparados com um limiar para evitar a presença de segmentos desconhecidos, no caso dos classificadores bayesianos (convencional e ingênuo) é adotado o valor 0,999, e no caso das RNA o valor é de 0,85; o segundo critério escolhe a classe que tem o maior valor dentre as três classes. Quando todos os segmentos estão coloridos é possível visualizar a forma e a região ocupada por cada elemento da cena. Também, após este processo, a super-segmentação é eliminada.

4.5 Considerações finais

Neste capítulo foram apresentados os materiais e métodos, onde foram mostrados os aspectos que compõem a arquitetura de reconhecimento de imagens adotada neste trabalho. No capítulo seguinte, os resultados obtidos utilizando tal abordagem são apresentados.

5 *Resultados experimentais*

Neste capítulo são expostos e discutidos os resultados obtidos durante as várias etapas deste trabalho. Devido à grande quantidade de tabelas e figuras, estas foram colocadas nos apêndices. Tais tabelas e figuras são referenciadas no texto com uma letra maiúscula seguida por um número. A letra representa o apêndice e o número identifica a tabela ou figura.

5.1 Segmentação

O JSEG foi testado inicialmente com imagens com resolução espacial de 512×384 *pixels*, o que resultou na segmentação das folhas e céu. Um exemplo disto é mostrado na Figura 35. Como pode ser observado, no caso desta imagem, os frutos, que são representados por poucos *pixels*, não foram segmentados, pois esta quantidade de *pixels* não é detectável quando empregada a menor escala de análise.

Nota-se também na Figura 35, que as regiões onde as folhas estavam mais escuras, devido à sombra, são separadas em outro segmento das demais folhas. O fato do algoritmo de segmentação criar segmentos distintos para uma mesma região sob intensidades de luz diferentes foi também constatado pelos autores do algoritmo.

Apesar disto, segmentos de um mesmo elemento, que são iluminados de forma não uniforme, devem ser atribuídos à mesma classe, assim, o classificador de padrões deverá compensar esta característica do algoritmo de segmentação. Isto é um exemplo do equilíbrio que deve existir entre o algoritmo de segmentação e a classificação de padrões. Em um dos extremos, existe um algoritmo de segmentação que define as fronteiras dos segmentos adequadamente e o clas-

Figura 35: Imagem com 512×384 *pixels* segmentada com o JSEG.

sificador de segmentos deve refinar a segmentação e, no outro, um algoritmo de segmentação que gera os segmentos da forma mais adequada possível e, conseqüentemente, deixa o trabalho do classificador mais simples, pois este não deverá lidar com a mesma quantidade de ruídos que o caso anterior.

Uma das formas de localizar os frutos mantendo a resolução da imagem é posicionar a câmera mais próxima dos frutos ou utilizar lente com maior distância focal, assim o fruto seria representado por mais *pixels*. Alguns autores adotam a primeira abordagem e instalam a câmera em um braço mecânico (PLEBE; GRASSO, 2001). A segunda abordagem exige que a câmera possa ser apontada para várias direções e, também, a teleobjetiva deve ser ajustada manualmente ou de forma automática (PARRISH; GOKSEL, 1977). Devido a estes fatos, optou-se por adotar a resolução de 2.048×1.536 *pixels*, assim a maioria dos elementos da cena serão representados por *pixels* suficientes.

Os resultados obtidos na segmentação das imagens com maior resolução foram mais satisfatórios, pois, neste caso, a maioria dos frutos foram separados dos demais elementos da cena. A Figura 36 mostra uma imagem segmentada, onde é possível observar os frutos, folhas e céu segmentados. A Figura 36 também ilustra a relação entre a quantidade de *pixels* em um elemento da cena e os segmentos encontrados, pois é possível observar que, conforme o tamanho

das folhas e frutos diminuem, estes são agrupados em um mesmo segmento. Quando os elementos da cena possuem tamanho suficiente, o algoritmo de segmentação cria até mais que um segmento no mesmo elemento, ou seja ocorre a super-segmentação.

Figura 36: Imagem com 2.048×1.536 *pixels* segmentada com o JSEG.

A Figura 37 é outro exemplo de imagem segmentada, onde é possível notar a super-segmentação dos elementos desta cena, o que fica claro quando observados os frutos que apresentam vários tons de cores. A super-segmentação é uma característica do algoritmo de segmentação JSEG que foi observada por seus autores, os quais propuseram uma solução para tal problema, entretanto, neste trabalho, tal solução não foi adotada, pois depende de um parâmetro que deve ser ajustado manualmente. Posteriormente, estes segmentos são unidos na etapa de classificação.

Também pode-se observar que, quando as folhas e flores são representadas por uma quantidade suficiente de *pixels*, estas são segmentadas. O algoritmo também foi capaz de segmentar as manchas dos frutos. Tais fatos podem viabilizar a construção de aplicações que localizem flores e defeitos em frutos, entretanto, as imagens devem ter resolução grande e tais elementos devem representar uma porção significativa da imagem, como é o caso da Figura 37.

As imagens apresentadas nesta seção mostram outra característica do algoritmo de segmen-

Figura 37: Outra imagem com 2.048×1.536 *pixels* segmentada com o JSEG.

tação: é possível observar nas regiões das fronteiras do céu com as folhas, onde é possível ver o fundo da imagem entre as folhas e galhos, que o algoritmo de segmentação tende a agrupar os galhos e folhas junto com o céu. Por fim, observa-se que as regiões próximas ao solo não foram segmentadas de forma adequada, pois em alguns casos os galhos e folhas confundem-se com a vegetação rasteira.

O algoritmo de segmentação JSEG foi capaz de segmentar as imagens utilizadas neste trabalho de forma satisfatória, considerando que tais imagens são de cenas naturais.

5.2 Normalização e extração de características

Os dados foram particionados com a intenção de eliminar os vetores de características mais distantes das centróides das classes, assim o classificador lidará com classes onde os vetores de características estão menos dispersos. Observando as tabelas que mostram a distribuição destes vetores nos cinco conjuntos de dados (tabelas 2 e 3), nota-se que o número de vetores cresce entre o primeiro, segundo e terceiro grupos, depois o crescimento entre os grupos é menor. Então pode-se esperar que os resultados produzidos pelos classificadores treinados com

os conjuntos 70% e 100% de ambos espaços de cores apresentem taxas de acerto semelhantes.

As ACP foram feitas para cada um dos grupos e foram obtidos os vetores de características transformados. O gráfico na Figura 38 mostra a razão em forma de porcentagem entre a soma dos auto-valores até a dimensão indicada e a soma de todos os auto-valores dos conjuntos de treinamento para o caso RGB. O gráfico na Figura 39 mostra o mesmo para o caso HSV. Nestes dois gráficos, as curvas dos três maiores conjuntos estão sobrepostas. Quanto maior a porcentagem indicada para uma dimensão, mais representativo (maior variância) é o vetor de características com aquela quantidade de dimensões.

Figura 38: Representatividade da quantidade de dimensões - RGB

Quando observados os dois gráficos sobrepostos, a maioria das curvas de energia são semelhantes, principalmente no início e no final das curvas. Como a “maldição da dimensionalidade” obriga-nos a escolher poucas dimensões, então é interessante observar a porção inicial destas curvas, como mostrado no gráfico da Figura 40. Neste gráfico, observa-se que, para as primeiras componentes, as curvas relacionadas com o RGB apresentam maior porcentagem que a maioria das curvas do HSV. Também, observa-se que todas as curvas apresentam valores menores que 90%.

Figura 39: Representatividade da quantidade de dimensões - HSV

Figura 40: Detalhe das curvas da representatividade da quantidade de dimensões.

Após a ACP e a normalização é possível obter a projeção do conjunto de dados em duas dimensões. Os gráficos 41, 42, 43, 44 e 45 mostram estas projeções para os conjuntos de treinamento cujos vetores de características são derivados do espaço de cores RGB. Os gráficos 46, 47, 48, 49 e 50 mostram as projeções para o caso HSV. Onde a cor verde representa a classe folhas, o vermelho representa a classe frutos e o azul representa a classe céu.

Figura 41: Conjunto de treinamento RGB 20%.

Figura 42: Conjunto de treinamento RGB 30%.

Figura 43: Conjunto de treinamento RGB 50%.

Figura 44: Conjunto de treinamento RGB 70%.

Figura 45: Conjunto de treinamento RGB 100%.

Figura 46: Conjunto de treinamento HSV 20%.

Figura 47: Conjunto de treinamento HSV 30%.

Figura 48: Conjunto de treinamento HSV 50%.

Figura 49: Conjunto de treinamento HSV 70%.

Figura 50: Conjunto de treinamento HSV 100%.

Os gráficos 51, 52, 53, 54 e 55 mostram as projeções dos conjuntos de teste para o caso RGB. E os gráficos 56, 57, 58, 59 e 60 mostram as projeções dos conjuntos de teste para o caso HSV.

Figura 51: Conjunto de teste RGB 20%.

Figura 52: Conjunto de teste RGB 30%.

Figura 53: Conjunto de teste RGB 50%.

Figura 54: Conjunto de teste RGB 70%.

Figura 55: Conjunto de teste RGB 100%.

Figura 56: Conjunto de teste HSV 20%.

Figura 57: Conjunto de teste HSV 30%.

Figura 58: Conjunto de teste HSV 50%.

Figura 59: Conjunto de teste HSV 70%.

Figura 60: Conjunto de teste HSV 100%.

Nos gráficos acima é possível notar que as classes estão próximas umas das outras, sendo que alguns vetores de características estão em regiões onde existem mais vetores de outra classe. Como as classes estão sobrepostas, não é possível encontrar facilmente os agrupamentos. O gráfico 46 é uma exceção, pois neste caso existem poucos vetores nas classes. Os gráficos de dispersão dos conjuntos de teste mostram que tais conjuntos são semelhantes aos conjuntos de treinamento, para o caso bidimensional.

5.3 Classificação dos segmentos

5.3.1 Baseado em redes neurais artificiais

A medida usada para avaliar os resultados dos treinamentos e dos testes das RNA foi a taxa de acerto. Também foi observado o número de iterações do algoritmo de treinamento. Este último valor indica o quão complexo é o aprendizado, ou seja, indica se o algoritmo de treinamento tem dificuldade em ajustar os pesos de forma que o erro seja minimizado. A quantidade de iterações não indica necessariamente que a taxa de acerto é baixa.

Neste trabalho, todos os classificadores baseados em RNA, para os casos RGB e HSV, foram treinados com o máximo de iterações, o que pode ser um indicativo que os vetores de características estão dispersos de forma complexa no espaço, dificultando o aprendizado por estas topologias de rede, ou, este fato pode ser uma evidência que a quantidade de exemplos não é suficiente.

Observando as matrizes de confusão destes classificadores (tabelas de 13 até 202) nota-se que o algoritmo não foi capaz de aprender a classe céu em 20 casos para o RGB e 22 casos para o HSV. Também observando as matrizes de confusão nota-se que, conforme o número de dimensões aumenta, o número de segmentos classificados como céu aumenta. O número de frutos classificados corretamente aumenta para as quantidades maiores de dimensões, pois para poucas dimensões os frutos tendem a serem classificados como folhas, principalmente para o caso RGB. Também pode-se notar que segmentos da classe folhas são classificados como frutos, entretanto, em alguns casos esta quantidade de segmentos está abaixo da mesma quantidade em alguns dos melhores classificadores bayesianos para o espaço de cores HSV.

Comparando o caso RGB com o HSV, nota-se para o caso HSV, que foram obtidos melhores resultados para a classe céu, onde o máximo de segmentos classificados corretamente para o caso RGB foi de 23 com dois falsos positivos (tabela 104) e para o caso HSV foi de 27 com um falso positivo (tabela 193). Também existem menos segmentos da classe frutos classificados como folhas para poucas dimensões, mostrando que, para o HSV, os classificadores baseados

em RNA conseguem distinguir melhor a classe frutas da classe folhas.

As tabelas 11 e 12 mostram os EQM dos conjuntos de treinamento, onde estes valores podem ser considerados altos, quando comparados com o EQM escolhido para terminar o treinamento. Nota-se que as médias dos EQM do caso HSV tendem a ficar abaixo das médias do caso RGB. As médias com relação as dimensões, para ambos os casos, tendem a diminuir e as médias com relação aos conjuntos de treinamento tendem a aumentar, o que mostra que com o aumento do número de neurônios e de dimensões, o classificador aprende mais e que com o aumento do tamanho do conjunto de treinamento, o classificador tende a ter mais dificuldade em aprender, considerando que neste caso são acrescentados aos conjuntos de treinamento os vetores mais distantes das centroídes das respectivas classes.

Apesar dos classificadores que suportam vetores de características com mais dimensões e que foram treinados com os menores conjuntos terem aprendido melhor, isto não implica em uma maior taxa de acerto para o conjunto de testes, pois o conjunto de teste contém vetores que estão mais dispersos no espaço de características. As tabelas 5 e 6 mostram os melhores resultados obtidos com a classificação dos conjuntos de treinamento. O melhor classificador para o caso RGB é o com 18 dimensões treinado com o conjunto 100%, onde a taxa de acerto foi de 0,94279. E o melhor classificador para o caso HSV é o com 20 dimensões treinado com o conjunto 50%, onde a taxa de acerto foi de 0,95471.

Nota-se nas tabelas 5 e 6, que as médias das taxas de acerto para os classificadores que usam menos dimensões são menores que as médias dos classificadores que usam mais dimensões. As médias com relação aos conjuntos de treinamento são maiores para os conjuntos próximos ao conjunto 50%. As médias para o caso HSV tendem a serem maiores que as médias para o caso RGB.

5.3.2 Baseado no teorema de Bayes

A tabela 4 mostra as probabilidades *a priori* estimadas dos conjuntos de treinamento, onde é possível observar que as folhas apresentam maior probabilidade de ocorrer, devido ao fato

que o algoritmo de segmentação super-segmenta as regiões com folhas. Logo, existem mais segmentos deste tipo. Para o caso da classe céu ocorre o contrário: o algoritmo de segmentação gera poucos segmentos.

Tabela 4: Probabilidades *a priori* estimadas dos conjuntos de treinamento.

		20%	30%	50%	70%	100%
RGB	laranjas	0,1645	0,17289	0,17169	0,17207	0,17188
	folhas	0,83029	0,81128	0,79967	0,79498	0,79347
	céu	0,0051875	0,015828	0,028637	0,032950	0,034652
HSV	laranjas	0,094302	0,15881	0,17027	0,17220	0,17188
	folhas	0,90053	0,82896	0,80299	0,79558	0,79347
	céu	0,0051649	0,012237	0,026737	0,032217	0,034652

As tabelas de 203 até 368 mostram que o número de segmentos da classe céu classificados corretamente aumenta com a quantidade de dimensões e com o tamanho do conjunto de treinamento. Tanto para o caso RGB, como para o caso HSV, o número de segmentos da classe frutos classificados como folhas tende a ser menor para os classificadores que usam mais dimensões. Entretanto, para o caso HSV menos segmentos da classe frutos são classificados incorretamente. Nota-se que a classe das folhas tem a mais baixa taxa de falsos negativos e as classes céu e frutos tem as maiores taxas de falsos negativos. Para o caso RGB, os melhores classificadores (com taxa de acerto próximas a 94%), tendem a classificar melhor os segmentos da classe céu que os segmentos da classe frutos. Para o caso HSV, os classificadores treinados com os conjuntos 20% e 30% tem maior taxa de falsos negativos para a classe céu. Os demais classificadores tem maior taxa de falsos negativos para a classe frutos nos casos com mais dimensões, podendo-se concluir que os segmentos com frutos e céu são os mais complexos de serem classificados.

Os melhores resultados obtidos na classificação dos conjuntos de teste pelos classificadores treinados para o caso RGB e HSV estão listados nas tabelas 7 e 8, respectivamente. Os resultados no caso RGB (tabela 7) mostram que a taxa de acerto cresce conforme o tamanho do conjunto cresce, principalmente para os três conjuntos menores, ou seja, do conjunto de treinamento 20% até o 50%, pois os classificadores treinados com os conjuntos menores não tem conhecimento suficiente para classificar os vetores de teste que estão mais distantes das centroídes das classes. Também nota-se, para o caso RGB, que o crescimento da taxa de acerto diminui conforme o número de dimensões aumenta. Isto é devido à ACP, pois as menores dimensões

concentram a maior variabilidade. O valor máximo, que é 0,94398, ocorre para o conjunto 70% com 17 dimensões.

Para o caso HSV (tabela 8), os classificadores bayesianos tiveram comportamento semelhante ao caso RGB, onde observa-se um crescimento da taxa de acerto quando o número de dimensões aumenta e um crescimento da taxa média de acerto do conjunto 20% até o 50%. A taxa máxima de acerto para o caso HSV é de 0,95471, que ocorre para o conjunto 30% e 17 dimensões.

Os classificadores bayesianos dependem da FDCP e sua estimativa depende da quantidade de vetores e da quantidade de dimensões. Entretanto, quando o número de dimensões aumenta faz-se necessário mais vetores, como mostrado na Figura 61. Quando isto não ocorre, o algoritmo de Figueiredo-Jain não consegue estimar a FDCP. Isto é o que ocorre para as entradas das tabelas 7 e 8 que não possuem valor. O gráfico na Figura 61 mostra o tamanho estimado do conjunto de treinamento fornecido pelo *toolbox* de Paalanen et al. (2006).

Figura 61: Quantidade de parâmetros necessário ao modelo de misturas e tamanho estimado do conjunto de treinamento.

5.3.3 Classificador Ingênuo de Bayes

As tabelas 9 e 10 mostram as melhores taxas de acertos, dentre três, para cada um dos classificadores treinados para o caso RGB e para o caso HSV, respectivamente. Os valores das probabilidades *a priori* são os mesmos listados na tabela 4.

Para o caso RGB (tabela 9), nota-se comportamento semelhante ao dos classificadores bayesianos convencionais, pois conforme a dispersão das classes aumentam, há um crescimento nas taxas de acerto médio, até o conjunto 50%. As taxas para os três últimos conjuntos são semelhantes. O comportamento dos classificadores com relação ao número de dimensões é diferente dos classificadores anteriores, para os conjuntos 20% e 30%, onde observa-se que as taxas de acerto caem conforme o número de dimensões aumenta. Isto pode ser visualizado no gráfico da Figura 62.

Figura 62: Taxas média de acerto para os classificadores bayesianos ingênuo treinados com os conjuntos 20% e 30%.

O comportamento das curvas relacionadas com os conjuntos de treinamento 20% e 30% está associado principalmente às classes folhas e frutos, pois os classificadores treinados com estes conjuntos tendem a classificar os segmentos da classe frutos como sendo da classe folhas, como pode ser observado nas matrizes de confusão nas tabelas de 369 até 406. Então, com o aumento do número de dimensões, os segmentos passam a ser classificados como sendo da

classe frutos, de forma que a taxa de acerto cresce e depois diminui. Para os demais conjuntos de treinamento (ver tabelas de 407 até 463), isto ocorre menos e a taxa de acerto não diminui como para os dois menores conjuntos de treinamento. Para a classe céu, a taxa de acerto tende a aumentar com o número de dimensões, sendo que para os conjuntos de treinamento maiores esta taxa é maior.

Os classificadores treinado com os dois conjuntos menores no caso HSV, tiveram desempenho menor para as duas últimas dimensões. Isto ocorre pelos mesmos motivos mencionados no caso RGB, entretanto o fato de utilizar o HSV amenizou tal problema. Para os demais conjuntos, a taxa de acerto cresce com o número de dimensões, onde o crescimento é maior nas primeiras dimensões. As taxas de acerto médio dos conjuntos de treinamento foram semelhantes.

As matrizes de confusão de 464 até 558 mostram que, para o caso HSV, o número de segmentos da classe frutos classificados corretamente tende a aumentar com o número de dimensões para todos os conjuntos de treinamento. O número de segmentos classificados corretamente como folhas tende a diminuir com o aumento do número de dimensões, principalmente para os dois conjuntos de treinamento menores e o número de segmentos classificados corretamente como céu tende a aumentar tanto com o aumento no número de dimensões como com o aumento do tamanho do conjunto de treinamento.

Tanto para o caso RGB como para o HSV é possível notar nas matrizes de confusão que as classes céu e frutos foram as que mais contribuíram para diminuir a taxa de acerto. Apesar deste comportamento semelhante, os classificadores treinados com os conjuntos derivados do espaço de cores HSV tendem a serem melhores para as médias com relação a quantidade de dimensões que os treinados com os conjuntos derivados do RGB.

5.3.4 Comparações entre os classificadores

Através das tabelas apresentadas e do gráfico na Figura 63 é possível concluir que os classificadores bayesianos para o caso HSV tem desempenho melhor que os demais classificadores. O gráfico da Figura 63 mostra os valores médios da taxa de acerto com relação ao número de di-

mensões. Os conjuntos de treinamento 20% e 30% são desprezados, pois para os classificadores bayesianos eles não apresentam todas as taxa de acertos.

Apesar de apresentarem desempenhos diferentes, os três tipos de classificadores testados neste trabalho apresentaram comportamentos semelhantes, pois a taxa de acerto da classe céu tende a melhorar com o aumento do número de dimensões. Também, para poucas dimensões, os segmentos da classe frutos são classificados como sendo da classe folhas e, por fim, as taxas de falsos negativos das classes frutos e céu são maiores que a da classe folhas, o que evidencia, para este caso, que estas classes são as mais complexas.

Figura 63: Taxas média de acerto para os três maiores conjuntos de treinamento.

Segundo o gráfico na Figura 63, os classificadores bayesianos que usam as FDCP tem um desempenho superior aos classificadores ingênuos de Bayes, com exceção dos classificadores bayesianos treinados com os conjuntos RGB com menos que três dimensões. Isto mostra que admitir a hipótese da independência entre as variáveis não é adequada para este trabalho, pois a FDCP foi capaz de aprender a interação entre as variáveis, o que resultou em um classificador melhor.

Apesar das taxas de acertos dos classificadores baseados em RNA, para o caso HSV, estarem próximas ao do classificador bayesiano para o mesmo caso, as RNA apresentaram comportamento mais instável, pois as taxas de acerto variam mais, como pode ser observado no gráfico

da Figura 63. Isto não indica que RNA são inadequadas para tal aplicação, mas indica que as topologias e conjuntos de treinamento devem ser ajustados de forma a obter-se resultados melhores.

Os classificadores que tiveram mais problemas com o conjunto de treinamento foram os baseados em RNA e os bayesianos. Para o caso das RNA, vários classificadores não aprenderam a classe céu. Para o caso dos classificadores bayesianos, não foi possível estimar as FDCP para as quantidades maiores de dimensões, pois a quantidade de vetores da classe céu nos conjuntos de treinamento 20% e 30% é baixa. Os classificadores de Bayes ingênuo não apresentaram este problema, pois o número de vetores na classe céu é suficiente para estimar a FDP das variáveis unidimensionais.

Com relação ao espaço de cores, os três tipos de classificadores apresentaram comportamentos semelhantes para cada espaço de cor. No caso RGB, a taxa de acerto com relação ao número de dimensões cresceu pouco quando comparada com o caso HSV. É possível inferir disto que a dispersão dos vetores para o caso HSV é adequada com poucas dimensões e melhora pouco com o número de dimensões, e para o caso RGB a dispersão não é adequada para poucas dimensões e melhora gradativamente conforme o número de dimensões aumenta.

5.4 Mapas de classes

As Figuras de 65 a 70 são exemplos de mapas de classes para cada um dos tipos de classificadores e espaços de cores, onde a cor verde representa a classe folhas, o azul representa a classe céu, o laranja representa a classe frutos e o preto representa os segmentos que tem probabilidades ou saídas da RNA abaixo do limiar. Estes mapas de classes foram gerados a partir da imagem na Figura 64. No apêndice F, estão outros exemplos como os apresentados aqui.

Figura 64: Imagem 1.

Figura 65: Mapa de classe 1 – Bayes – HSV

Figura 66: Mapa de classe 1 – Bayes – RGB

Figura 67: Mapa de classe 1 – Bayes ingênuo – HSV

Figura 68: Mapa de classe 1 – Bayes ingênuo – RGB

Figura 69: Mapa de classe 1 – RNA – HSV

Figura 70: Mapa de classe 1 – RNA – RGB

Os mapas de classes apresentados nesta seção e no apêndice F mostram que os classificadores bayesianos são os que produzem melhores resultados, pois é possível visualizar as três

classes de forma adequada, principalmente para as imagens mais próximas às árvores. Os mapas de classes obtidos com RNA tiveram desempenho semelhante, entretanto, como foi observado anteriormente, as RNA tiveram dificuldade em aprender a classe céu, logo, tal fato pode ser observado nos mapas de classes (Figuras 69 e 70). Os mapas de classes obtidos a partir dos classificadores de Bayes ingênuo não são tão adequados quanto os demais, pois nestes mapas vários segmentos não foram classificados (regiões em cor preta) e os segmentos da classe céu, no caso HSV, e da classe frutos, no caso RGB, não foram classificados corretamente.

O grupo de imagens que mostra predominantemente os frutos e folhas apresentou os melhores mapas de classes, como pode ser observado no apêndice F nas imagens 2, 3 e 4. Os mapas obtidos com os classificador de Bayes podem ser considerados os melhores, pois mostram as regiões de folhas, frutos e céu coerentemente com a imagem original, onde existem poucos segmentos não classificados e poucos segmentos classificados incorretamente.

O grupo que mostra as árvores desde o solo até o topo (imagens 5, 6, 10, 11, 13, 14, 15, 18 e 20) apresenta resultados semelhantes ao do grupo anterior. Entretanto, nota-se que quando os frutos são pequenos (imagens 10, 11, 13, 14, 15, 18 e 20), estes não são identificados corretamente. Nestas imagens, as regiões de solo, que não deveriam ser classificadas, foram atribuídas a alguma classe, como é o caso da imagem 15. Na imagem 18, nota-se que os tons de cores são diferentes dos tons de cores das demais imagens, o que resultou em vários segmentos classificados como frutos (Figura 184) e em vários segmentos não classificados (todos os mapas).

Os mapas obtidos das imagens do grupo que mostra as linhas de plantio (imagens 7, 8, 9, 12, 16, 17 e 19) foram os que apresentaram piores resultados, pois os segmentos desconhecidos foram classificados em alguma das classes, como é o caso das regiões com solo nú ou com vegetação rasteira.

Com relação aos segmentos não classificados (segmentos pretos), concluí-se que tais segmentos estão presentes principalmente nos casos onde os classificadores apresentaram pior desempenho.

Os mapas de classes foram criados de forma que o problema de super segmentação do

JSEG foi reduzido. Nota-se, em alguns casos, as fronteiras entre os segmentos, pois estas são formadas devido a estratégia de dividir a imagem e então segmentá-la.

5.5 Considerações finais

Neste capítulo foram apresentados os resultados dos vários experimentos realizados: avaliação do algoritmo JSEG, normalização, extração de característica e classificação dos vetores. Também os vários tipos de classificadores foram comparados. Por fim, foram apresentados os mapas de classes. No próximo capítulo, são apresentadas as conclusões deste trabalho baseadas em tais resultados.

6 *Conclusões*

6.1 Considerações finais e conclusões

Neste trabalho, técnicas de visão computacional foram exploradas com o objetivo de reconhecer os principais elementos presentes em cenas de pomares de laranjeiras. Foi adotada uma arquitetura modular que utiliza um algoritmo de segmentação automático e um classificador de padrões.

Devido a isto, as técnicas de visão computacional foram estudadas, onde foram consideradas as técnicas de processamento de imagens, as técnicas de segmentação de imagens e, também, as técnicas de reconhecimento de padrões. Dentro deste contexto foi feita a revisão bibliográfica dos trabalhos da área agrícola.

Com o objetivo de avaliar a arquitetura adotada, foi construída uma base de imagens proveniente do domínio da aplicação em questão. Tal base é adequada, pois apresenta várias imagens onde os elementos estão sob diferentes condições de iluminação. Através da observação desta base, foi possível estabelecer os requisitos para o algoritmo de segmentação.

O algoritmo de segmentação JSEG foi escolhido e testado. Este algoritmo apresentou as características necessárias para segmentar imagens de cenas pomares de laranjeiras. Do ponto de vista prático, o algoritmo JSEG mostrou-se adequado, pois foram obtidos segmentos de diversas imagens que corresponderam ao propósito deste trabalho. Entretanto, este algoritmo foi implementado de forma que, ao ser executado, fosse exigido muito do computador (memória e processador), o que resultou na necessidade de dividir as imagens. Devido à implementação deste algoritmo ter o maior tempo de execução dentre as demais, tal implementação não pode

ser usada para aplicações com restrições temporais. Entretanto, caso esta seja melhorada ou substituída será possível então considerar tais aplicações.

Após a segmentação, os vetores de características foram extraídos. Os tipos de vetores de características considerados se mostraram simples de serem calculados e adequados, como pode ser observado pelos resultados obtidos com a classificação e com os mapas de classes. Os vetores derivados do espaço de cores HSV mostraram-se melhores, mesmo quando usadas poucas dimensões, pois as taxas de acerto dos classificadores foram superiores às taxas do caso RGB. Já os vetores derivados do espaço de cores RGB mostraram-se menos adequados, possivelmente, devido ao fato deste não distinguir a informação cromática da luminosidade.

O algoritmo de Figueiredo-Jain mostrou-se adequado para a construção do classificador baseado no teorema de Bayes, pois este foi capaz de estimar as FDCP, o que resultou nos melhores classificadores avaliados neste trabalho. A característica deste algoritmo que se destacou foi a capacidade de selecionar o modelo (parâmetros da mistura), o que facilitou a construção criteriosa de classificadores. Em oposição a isto, estão os classificadores baseados em RNA, que não mostraram-se práticos, pois não possuem mecanismos para selecionar o modelo mais adequado. Por fim, o classificador ingênuo de Bayes não apresentou resultados bons quando comparados com os demais classificadores. Isto mostra que a hipótese de independência das características não é adequada para os dados utilizados neste trabalho.

Foram construídos mapas de classes para os três grupos de imagens presentes no banco de imagens. Estes mapas de classes refletiram os resultados obtidos com os classificadores e, ainda, foram um ferramenta adequada para visualizar o comportamento dos classificadores com relação a cada um dos grupos de imagens. Com isto, concluí-se que os classificadores tiveram melhor desempenho com as imagens onde os frutos e folhas são maiores e, também, tais classificadores não conseguem lidar com segmentos de classes desconhecidas.

A arquitetura para reconhecimento de cenas de pomares de laranjeiras, quando composta pelo o algoritmo JSEG, vetores de características derivados do espaço de cores HSV, ACP e o classificador bayesiano com FDCP estimadas com o algoritmo de Figueiredo-Jain, mostra-se

adequada, pois foi possível reconhecer os elementos presentes nas cenas extraídas de pomares de laranjeiras.

6.2 Trabalhos futuros

Diante dos resultados obtidos e das conclusões, são propostas as seguintes atividades de continuidade ao presente trabalho:

- Reimplementar o algoritmo JSEG, de modo que este execute mais rápido e utilize menos memória;
- Estudar e implementar outros algoritmos de redução de dimensionalidade, com o propósito de melhorar a taxa de classificação;
- Avaliar outros descritores, principalmente os descritores de texturas;
- Substituir a etapa de classificação de padrões por um algoritmo de aprendizado, que possibilite ao sistema aprender novas classes conforme estas são apresentadas pelos usuário, semelhante ao proposto em (LI; WANG, 2006; CARNEIRO et al., 2007);
- Considerar a paralelização dos algoritmos adotados.

APÊNDICE A – Melhores resultados dos testes dos classificadores

Tabela 5: Taxas de acerto dos conjuntos de teste RGB para os classificadores baseado em RNA.

Dimensões	20%	30%	50%	70%	100%	média	desvio
2	0,82241	0,81168	0,80810	0,80810	0,79976	0,81001	0,0081973
3	0,84863	0,85221	0,83909	0,80810	0,85221	0,84005	0,0186447
4	0,81406	0,87962	0,86532	0,88439	0,77354	0,84338	0,0479921
5	0,84386	0,89273	0,90346	0,82598	0,88081	0,86937	0,0330587
6	0,89869	0,90822	0,90822	0,85816	0,78427	0,87151	0,0529717
7	0,90346	0,91657	0,91657	0,91299	0,77950	0,88582	0,0596746
8	0,89988	0,91776	0,77831	0,92014	0,89869	0,88296	0,0593284
9	0,92372	0,92014	0,91180	0,87485	0,91895	0,90989	0,0200614
10	0,88081	0,91299	0,77235	0,92014	0,87128	0,87151	0,0591725
11	0,84744	0,91299	0,87843	0,87008	0,87604	0,87700	0,0235592
12	0,87723	0,90584	0,91538	0,88796	0,90703	0,89869	0,0156088
13	0,87604	0,87962	0,89631	0,89273	0,88796	0,88653	0,0085700
14	0,87604	0,87008	0,91538	0,91180	0,92253	0,89917	0,0242310
15	0,79142	0,92014	0,91180	0,90584	0,90942	0,88772	0,0540929
16	0,85816	0,91538	0,93683	0,92849	0,93683	0,91514	0,0330351
17	0,85340	0,91180	0,91299	0,93325	0,91299	0,90489	0,0301458
18	0,85816	0,88081	0,93802	0,83909	0,94279	0,89178	0,0468143
19	0,86293	0,89869	0,92372	0,94160	0,92253	0,90989	0,0303594
20	0,86889	0,89988	0,94041	0,91299	0,83075	0,89058	0,0421938
média	0,86343	0,89511	0,88802	0,88614	0,87410		
desvio	0,032463	0,027885	0,051901	0,041579	0,055312		

Tabela 6: Taxas de acerto dos conjuntos de teste HSV para os classificadores baseado em RNA.

Dimensões	20%	30%	50%	70%	100%	média	desvio
2	0,90465	0,91895	0,89988	0,87128	0,88915	0,89678	0,017831
3	0,90942	0,92133	0,90465	0,89869	0,92729	0,91228	0,011817
4	0,90822	0,93445	0,93921	0,90346	0,86174	0,90942	0,030920
5	0,90703	0,91895	0,93206	0,86532	0,86651	0,89797	0,030581
6	0,90465	0,92968	0,93564	0,89511	0,93445	0,91990	0,018721
7	0,90942	0,93206	0,93087	0,90107	0,90465	0,91561	0,014777
8	0,91657	0,92133	0,93921	0,93683	0,93683	0,93015	0,010411
9	0,89988	0,93087	0,93921	0,94160	0,94636	0,93159	0,018591
10	0,92133	0,91776	0,94517	0,94636	0,94756	0,93564	0,014767
11	0,92610	0,92372	0,94041	0,94279	0,94756	0,93611	0,010580
12	0,92253	0,92729	0,94756	0,94756	0,94636	0,93826	0,012312
13	0,91895	0,93206	0,94517	0,94756	0,95113	0,93897	0,013310
14	0,90822	0,94517	0,94875	0,94756	0,89035	0,92801	0,027004
15	0,90703	0,94398	0,93564	0,94636	0,93921	0,93445	0,015880
16	0,91180	0,94636	0,94994	0,94994	0,87962	0,92753	0,031234
17	0,91418	0,94636	0,95352	0,92849	0,94398	0,93731	0,015826
18	0,91776	0,94636	0,95113	0,94398	0,94279	0,94041	0,013057
19	0,91180	0,94041	0,94279	0,95113	0,94279	0,93778	0,015086
20	0,91299	0,91776	0,95471	0,93564	0,94398	0,93302	0,017546
média	0,91224	0,93131	0,93871	0,92635	0,92328		
desvio	0,0068723	0,0107360	0,0145886	0,0278862	0,0304866		

Tabela 7: Taxas de acerto dos conjuntos de teste RGB para os classificadores bayesianos.

Dimensões	20%	30%	50%	70%	100%
2	0,81883	0,80334	0,80453	0,79976	0,79857
3	0,86174	0,85340	0,85936	0,85816	0,85578
4	0,89392	0,89392	0,88796	0,89631	0,89511
5	0,89631	0,90107	0,92133	0,91418	0,90584
6	0,90584	0,91657	0,91895	0,92610	0,91657
7	0,90465	0,91538	0,92253	0,92491	0,91657
8	0,91180	0,92729	0,92372	0,92372	0,92133
9	0,91299	0,92610	0,92968	0,93087	0,93445
10	0,92014	0,92610	0,93087	0,92253	0,92849
11	–	0,92849	0,93087	0,93325	0,93445
12	–	0,92372	0,93445	0,93087	0,94041
13	–	0,91538	0,93445	0,92968	0,92968
14	–	0,92729	0,93921	0,93445	0,92729
15	–	0,92372	0,92729	0,93683	0,93325
16	–	0,92491	0,93564	0,92372	0,93206
17	–	0,91299	0,93325	0,94398	0,91657
18	–	0,91776	0,91418	0,93445	0,93325
19	–	0,91418	0,92729	0,92610	0,93445
20	–	0,91418	0,92610	0,93087	0,93802
média	0,89180	0,90873	0,91588	0,91688	0,91538
desvio	0,032147	0,030868	0,032873	0,033931	0,034483

Tabela 8: Taxas de acerto dos conjuntos de teste HSV para os classificadores bayesianos.

Dimensões	20%	30%	50%	70%	100%
2	0,91180	0,92014	0,89392	0,88915	0,88796
3	0,90346	0,93445	0,94160	0,93445	0,94041
4	0,93683	0,92729	0,94279	0,93921	0,94279
5	0,93445	0,92968	0,94041	0,94041	0,94517
6	0,93087	0,92729	0,93564	0,94160	0,94636
7	0,93206	0,93564	0,94279	0,94517	0,93564
8	0,93087	0,93445	0,94279	0,95113	0,94279
9	0,93206	0,93802	0,94279	0,94517	0,94160
10	–	0,93683	0,94517	0,94875	0,94160
11	–	0,94160	0,95352	0,94875	0,94994
12	–	0,93802	0,94756	0,95113	0,95113
13	–	0,93325	0,93802	0,94756	0,95232
14	–	0,94398	0,94756	0,94398	0,94279
15	–	0,94756	0,94160	0,94279	0,94756
16	–	0,94875	0,94160	0,94517	0,94636
17	–	0,95471	0,94517	0,94875	0,94994
18	–	–	0,94636	0,94517	0,94636
19	–	–	0,94875	0,95232	0,94756
20	–	–	0,95113	0,94994	0,94279
média	0,92655	0,93698	0,94153	0,94266	0,94216
desvio	0,012053	0,0089074	0,012319	0,013745	0,013765

Tabela 9: Taxas de acerto dos conjuntos de teste RGB para os classificadores ingênuos de Bayes.

Dimensões	20%	30%	50%	70%	100%
2	0,78427	0,79023	0,79261	0,79142	0,79380
3	0,82718	0,79499	0,80215	0,79023	0,79142
4	0,80215	0,79619	0,82360	0,81168	0,80930
5	0,82837	0,79738	0,83552	0,83194	0,81406
6	0,84505	0,81883	0,84863	0,85101	0,84982
7	0,85101	0,88796	0,86651	0,85697	0,85816
8	0,84386	0,89154	0,86770	0,86532	0,86532
9	0,84982	0,88200	0,88677	0,88915	0,89154
10	0,84505	0,88200	0,89988	0,89035	0,88677
11	0,84505	0,88796	0,89035	0,88677	0,88915
12	0,83194	0,88915	0,90226	0,89631	0,89869
13	0,82718	0,88081	0,89511	0,89631	0,89988
14	0,81883	0,86532	0,90584	0,90226	0,89869
15	0,82002	0,87604	0,90822	0,90107	0,90346
16	0,82002	0,87485	0,89511	0,90703	0,90346
17	0,81168	0,85340	0,89750	0,92014	0,90703
18	0,80572	0,86174	0,90346	0,91538	0,91418
19	0,79261	0,85578	0,90822	0,91180	0,91418
20	0,78665	0,85459	0,90584	0,91538	0,92133
média	0,82297	0,85478	0,87554	0,87529	0,87422
desvio	0,021323	0,036266	0,037330	0,041907	0,042704

Tabela 10: Taxas de acerto dos conjuntos de teste HSV para os classificadores ingênuos de Bayes.

Dimensões	20%	30%	50%	70%	100%
2	0,89392	0,90822	0,86651	0,85340	0,86651
3	0,89392	0,91180	0,90584	0,89869	0,90942
4	0,91061	0,91299	0,90822	0,90226	0,91776
5	0,90584	0,90822	0,90703	0,90346	0,90822
6	0,90465	0,91061	0,89750	0,89869	0,90107
7	0,90584	0,90703	0,89988	0,89869	0,91061
8	0,90584	0,91299	0,90226	0,90822	0,90226
9	0,90346	0,91418	0,90465	0,91657	0,90703
10	0,90226	0,91418	0,90942	0,92014	0,90822
11	0,90226	0,91299	0,90942	0,91895	0,90465
12	0,90346	0,91538	0,90822	0,91895	0,90822
13	0,91299	0,91061	0,90822	0,91180	0,90346
14	0,90822	0,90942	0,90703	0,91538	0,91061
15	0,91180	0,91180	0,90942	0,91299	0,91418
16	0,90584	0,91061	0,90942	0,91299	0,91538
17	0,90346	0,89988	0,90942	0,91538	0,91538
18	0,90584	0,90107	0,90703	0,91180	0,91061
19	0,89392	0,89511	0,90465	0,91061	0,91180
20	0,88319	0,89631	0,90703	0,91180	0,91061
média	0,90302	0,90860	0,90427	0,90741	0,90716
desvio	0,0072523	0,0060912	0,0097403	0,0148286	0,0108215

APÊNDICE B – EQM dos treinamentos dos melhores classificadores baseados em RNA

Tabela 11: EQM dos treinamentos dos melhores classificadores baseados em RNA – caso RGB

Dimensões	20%	30%	50%	70%	100%	média	desvio
2	0,217469	0,239823	0,258377	0,270988	0,269999	0,251331	0,0227133
3	0,165264	0,191925	0,214522	0,254261	0,199790	0,205152	0,0327653
4	0,238773	0,154468	0,180577	0,171509	0,285563	0,206178	0,0545334
5	0,135294	0,130205	0,139095	0,251891	0,180098	0,167317	0,0512723
6	0,102286	0,115911	0,132195	0,236722	0,289948	0,175412	0,0831156
7	0,103171	0,096419	0,114051	0,130756	0,290301	0,146939	0,0811850
8	0,075532	0,089753	0,299347	0,118191	0,118661	0,140297	0,0908335
9	0,077436	0,086056	0,151969	0,197025	0,109844	0,124466	0,0498049
10	0,084162	0,096088	0,261550	0,104201	0,195834	0,148367	0,0772490
11	0,111975	0,079563	0,178745	0,189810	0,191307	0,150280	0,0512940
12	0,082764	0,078140	0,131381	0,169228	0,134194	0,119141	0,0383713
13	0,071311	0,135671	0,166974	0,166721	0,162832	0,140702	0,0409188
14	0,083158	0,137328	0,147311	0,144571	0,115122	0,125498	0,0268323
15	0,214820	0,096811	0,141254	0,142193	0,142376	0,147491	0,0424111
16	0,100900	0,088548	0,100089	0,087890	0,095862	0,094658	0,0061858
17	0,100487	0,096302	0,133653	0,089418	0,138656	0,111703	0,0227371
18	0,095511	0,127236	0,090098	0,243063	0,100943	0,131370	0,0640457
19	0,094124	0,118536	0,128725	0,091203	0,134645	0,113447	0,0198549
20	0,088296	0,116904	0,093178	0,135231	0,239647	0,134651	0,0616607
média	0,11804	0,11977	0,16122	0,16815	0,17872		
desvio	0,052003	0,040906	0,058929	0,060320	0,067327		

Tabela 12: EQM dos treinamentos dos melhores classificadores baseados em RNA – caso HSV

Dimensões	20%	30%	50%	70%	100%	média	desvio
2	0,066324	0,104211	0,141317	0,186092	0,161605	0,131910	0,047368
3	0,058933	0,103459	0,146185	0,158887	0,127747	0,119042	0,039548
4	0,065481	0,096102	0,096647	0,153695	0,194050	0,121195	0,051722
5	0,067140	0,096678	0,103935	0,192416	0,214742	0,134982	0,064602
6	0,067840	0,076538	0,079728	0,159273	0,088759	0,094428	0,037014
7	0,066600	0,075309	0,097633	0,156192	0,156622	0,110471	0,043434
8	0,050724	0,073683	0,094887	0,096881	0,109974	0,085230	0,023266
9	0,065528	0,084278	0,081964	0,094633	0,088100	0,082901	0,010831
10	0,050141	0,094631	0,083356	0,089405	0,084815	0,080470	0,017517
11	0,047630	0,072163	0,072085	0,113397	0,116046	0,084264	0,029562
12	0,041688	0,089172	0,082546	0,082657	0,078104	0,074833	0,018945
13	0,046817	0,085506	0,056522	0,097335	0,075919	0,072420	0,020691
14	0,062282	0,065370	0,060237	0,073441	0,186523	0,089570	0,054431
15	0,062464	0,061922	0,080235	0,096726	0,119980	0,084265	0,024605
16	0,056410	0,054221	0,063407	0,076115	0,193256	0,088682	0,059079
17	0,056263	0,055007	0,057538	0,120661	0,110726	0,080039	0,032749
18	0,054818	0,070406	0,050998	0,111992	0,107454	0,079133	0,028900
19	0,054563	0,074477	0,101503	0,064619	0,105213	0,080075	0,022428
20	0,053639	0,097980	0,065271	0,115785	0,105061	0,087547	0,026734
média	0,057647	0,080585	0,085052	0,117905	0,127615		
desvio	0,0079334	0,0156798	0,0262088	0,0386431	0,0434696		

APÊNDICE C – Matrizes de confusão dos testes do classificador baseado em RNA

C.1 Testes dos classificadores treinados com o conjunto RGB – 20%

Tabela 13: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	43	106	14	73,62%
folhas	11	636	1	1,852%
céu	8	9	11	60,71%
falsos +	30,65%	15,31%	57,69%	82,24%

Tabela 14: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	84	65	14	48,47%
folhas	34	613	1	5,401%
céu	5	8	15	46,43%
falsos +	31,71%	10,64%	50%	84,86%

Tabela 15: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	50	113	0	69,33%
folhas	15	633	0	2,315%
céu	22	6	0	100%
falsos +	42,53%	15,82%	0%	81,41%

Tabela 16: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	108	55	0	33,74%
folhas	48	600	0	7,407%
céu	19	9	0	100%
falsos +	38,29%	9,639%	0%	84,39%

Tabela 17: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	118	36	9	27,61%
folhas	25	622	1	4,012%
céu	4	10	14	50%
falsos +	19,73%	6,886%	41,67%	89,87%

Tabela 18: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	33	8	25,15%
folhas	24	623	1	3,858%
céu	3	12	13	53,57%
falsos +	18,12%	6,737%	40,91%	90,35%

Tabela 19: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	121	31	11	25,77%
folhas	29	618	1	4,63%
céu	4	8	16	42,86%
falsos +	21,43%	5,936%	42,86%	89,99%

Tabela 20: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	36	2	23,31%
folhas	14	634	0	2,16%
céu	8	4	16	42,86%
falsos +	14,97%	5,935%	11,11%	92,37%

Tabela 21: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	36	8	26,99%
folhas	44	604	0	6,79%
céu	4	8	16	42,86%
falsos +	28,74%	6,79%	33,33%	88,08%

Tabela 22: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	112	51	0	31,29%
folhas	49	599	0	7,562%
céu	4	24	0	100%
falsos +	32,12%	11,13%	0%	84,74%

Tabela 23: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	41	0	25,15%
folhas	50	598	0	7,716%
céu	5	7	16	42,86%
falsos +	31,07%	7,43%	0%	87,72%

Tabela 24: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	32	4	22,09%
folhas	58	590	0	8,951%
céu	4	6	18	35,71%
falsos +	32,8%	6,051%	18,18%	87,6%

Tabela 25: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	33	5	23,31%
folhas	54	594	0	8,333%
céu	6	6	16	42,86%
falsos +	32,43%	6,161%	23,81%	87,6%

Tabela 26: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	55	108	0	66,26%
folhas	39	609	0	6,019%
céu	1	27	0	100%
falsos +	42,11%	18,15%	0%	79,14%

Tabela 27: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	117	46	0	28,22%
folhas	45	603	0	6,944%
céu	17	11	0	100%
falsos +	34,64%	8,636%	0%	85,82%

Tabela 28: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	113	50	0	30,67%
folhas	45	603	0	6,944%
céu	21	7	0	100%
falsos +	36,87%	8,636%	0%	85,34%

Tabela 29: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	48	0	29,45%
folhas	43	605	0	6,636%
céu	16	12	0	100%
falsos +	33,91%	9,023%	0%	85,82%

Tabela 30: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	44	0	26,99%
folhas	43	605	0	6,636%
céu	15	13	0	100%
falsos +	32,77%	8,61%	0%	86,29%

Tabela 31: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 20% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	117	46	0	28,22%
folhas	36	612	0	5,556%
céu	17	11	0	100%
falsos +	31,18%	8,52%	0%	86,89%

C.2 Testes dos classificadores treinados com o conjunto RGB – 30%

Tabela 32: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	39	115	9	76,07%
folhas	16	631	1	2,623%
céu	2	15	11	60,71%
falsos +	31,58%	17,08%	47,62%	81,17%

Tabela 33: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	87	67	9	46,63%
folhas	33	614	1	5,247%
céu	3	11	14	50%
falsos +	29,27%	11,27%	41,67%	85,22%

Tabela 34: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	104	50	9	36,2%
folhas	25	622	1	4,012%
céu	11	5	12	57,14%
falsos +	25,71%	8,124%	45,45%	87,96%

Tabela 35: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	110	47	6	32,52%
folhas	25	623	0	3,858%
céu	3	9	16	42,86%
falsos +	20,29%	8,247%	27,27%	89,27%

Tabela 36: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	34	5	23,93%
folhas	27	621	0	4,167%
céu	0	11	17	39,29%
falsos +	17,88%	6,757%	22,73%	90,82%

Tabela 37: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	37	7	26,99%
folhas	15	633	0	2,315%
céu	2	9	17	39,29%
falsos +	12,5%	6,775%	29,17%	91,66%

Tabela 38: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	38	3	25,15%
folhas	20	628	0	3,086%
céu	1	7	20	28,57%
falsos +	14,69%	6,686%	13,04%	91,78%

Tabela 39: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	28	3	19,02%
folhas	26	622	0	4,012%
céu	1	9	18	35,71%
falsos +	16,98%	5,615%	14,29%	92,01%

Tabela 40: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	33	4	22,7%
folhas	26	622	0	4,012%
céu	2	8	18	35,71%
falsos +	18,18%	6,184%	18,18%	91,3%

Tabela 41: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	34	1	21,47%
folhas	27	621	0	4,167%
céu	3	8	17	39,29%
falsos +	18,99%	6,335%	5,556%	91,3%

Tabela 42: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	30	1	19,02%
folhas	38	610	0	5,864%
céu	2	8	18	35,71%
falsos +	23,26%	5,864%	5,263%	90,58%

Tabela 43: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	112	51	0	31,29%
folhas	22	626	0	3,395%
céu	17	11	0	100%
falsos +	25,83%	9,012%	0%	87,96%

Tabela 44: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	110	53	0	32,52%
folhas	28	620	0	4,321%
céu	18	10	0	100%
falsos +	29,49%	9,224%	0%	87,01%

Tabela 45: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	34	0	20,86%
folhas	25	623	0	3,858%
céu	3	5	20	28,57%
falsos +	17,83%	5,891%	0%	92,01%

Tabela 46: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	30	0	18,4%
folhas	32	616	0	4,938%
céu	6	3	19	32,14%
falsos +	22,22%	5,085%	0%	91,54%

Tabela 47: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	35	0	21,47%
folhas	30	618	0	4,63%
céu	5	4	19	32,14%
falsos +	21,47%	5,936%	0%	91,18%

Tabela 48: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	44	0	26,99%
folhas	28	620	0	4,321%
céu	16	12	0	100%
falsos +	26,99%	8,284%	0%	88,08%

Tabela 49: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	41	0	25,15%
folhas	16	632	0	2,469%
céu	18	10	0	100%
falsos +	21,79%	7,467%	0%	89,87%

Tabela 50: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 30% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	121	42	0	25,77%
folhas	14	634	0	2,16%
céu	18	10	0	100%
falsos +	20,92%	7,58%	0%	89,99%

C.3 Testes dos classificadores treinados com o conjunto RGB – 50%

Tabela 51: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	43	119	1	73,62%
folhas	24	623	1	3,858%
céu	6	10	12	57,14%
falsos +	41,1%	17,15%	14,29%	80,81%

Tabela 52: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	64	89	10	60,74%
folhas	20	628	0	3,086%
céu	9	7	12	57,14%
falsos +	31,18%	13,26%	45,45%	83,91%

Tabela 53: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	88	73	2	46,01%
folhas	21	625	2	3,549%
céu	11	4	13	53,57%
falsos +	26,67%	10,97%	23,53%	86,53%

Tabela 54: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	121	42	0	25,77%
folhas	28	620	0	4,321%
céu	8	3	17	39,29%
falsos +	22,93%	6,767%	0%	90,35%

Tabela 55: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	39	1	24,54%
folhas	27	621	0	4,167%
céu	7	3	18	35,71%
falsos +	21,66%	6,335%	5,263%	90,82%

Tabela 56: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	35	2	22,7%
folhas	22	624	2	3,704%
céu	1	8	19	32,14%
falsos +	15,44%	6,447%	17,39%	91,66%

Tabela 57: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	7	156	0	95,71%
folhas	2	646	0	0,3086%
céu	0	28	0	100%
falsos +	22,22%	22,17%	0%	77,83%

Tabela 58: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	42	1	26,38%
folhas	19	628	1	3,086%
céu	4	7	17	39,29%
falsos +	16,08%	7,238%	10,53%	91,18%

Tabela 59: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	0	163	0	100%
folhas	0	648	0	0%
céu	0	28	0	100%
falsos +	0%	22,77%	0%	77,23%

Tabela 60: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	94	67	2	42,33%
folhas	24	624	0	3,704%
céu	5	4	19	32,14%
falsos +	23,58%	10,22%	9,524%	87,84%

Tabela 61: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	40	0	24,54%
folhas	25	623	0	3,858%
céu	4	2	22	21,43%
falsos +	19,08%	6,316%	0%	91,54%

Tabela 62: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	99	62	2	39,26%
folhas	12	635	1	2,006%
céu	4	6	18	35,71%
falsos +	13,91%	9,673%	14,29%	89,63%

Tabela 63: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	113	48	2	30,67%
folhas	14	633	1	2,315%
céu	5	1	22	21,43%
falsos +	14,39%	7,185%	12%	91,54%

Tabela 64: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	42	2	26,99%
folhas	20	626	2	3,395%
céu	4	4	20	28,57%
falsos +	16,78%	6,845%	16,67%	91,18%

Tabela 65: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	30	0	18,4%
folhas	13	635	0	2,006%
céu	3	7	18	35,71%
falsos +	10,74%	5,506%	0%	93,68%

Tabela 66: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	117	44	2	28,22%
folhas	17	630	1	2,778%
céu	3	6	19	32,14%
falsos +	14,6%	7,353%	13,64%	91,3%

Tabela 67: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	35	0	21,47%
folhas	11	637	0	1,698%
céu	2	4	22	21,43%
falsos +	9,22%	5,769%	0%	93,8%

Tabela 68: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	121	40	2	25,77%
folhas	12	633	3	2,315%
céu	2	5	21	25%
falsos +	10,37%	6,637%	19,23%	92,37%

Tabela 69: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 50% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	28	0	17,18%
folhas	14	634	0	2,16%
céu	2	6	20	28,57%
falsos +	10,6%	5,09%	0%	94,04%

C.4 Testes dos classificadores treinados com o conjunto RGB – 70%

Tabela 70: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	26	130	7	84,05%
folhas	10	637	1	1,698%
céu	6	7	15	46,43%
falsos +	38,1%	17,7%	34,78%	80,81%

Tabela 71: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	51	112	0	68,71%
folhas	22	626	0	3,395%
céu	25	2	1	96,43%
falsos +	47,96%	15,41%	0%	80,81%

Tabela 72: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	91	71	1	44,17%
folhas	16	632	0	2,469%
céu	4	5	19	32,14%
falsos +	18,02%	10,73%	5%	88,44%

Tabela 73: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	44	118	1	73,01%
folhas	15	633	0	2,315%
céu	3	9	16	42,86%
falsos +	29,03%	16,71%	5,882%	82,6%

Tabela 74: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	71	91	1	56,44%
folhas	15	632	1	2,469%
céu	4	7	17	39,29%
falsos +	21,11%	13,42%	10,53%	85,82%

Tabela 75: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	114	46	3	30,06%
folhas	16	632	0	2,469%
céu	3	5	20	28,57%
falsos +	14,29%	7,467%	13,04%	91,3%

Tabela 76: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	34	1	21,47%
folhas	24	624	0	3,704%
céu	1	7	20	28,57%
falsos +	16,34%	6,165%	4,762%	92,01%

Tabela 77: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	83	79	1	49,08%
folhas	17	631	0	2,623%
céu	3	5	20	28,57%
falsos +	19,42%	11,75%	4,762%	87,49%

Tabela 78: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	39	1	24,54%
folhas	20	628	0	3,086%
céu	3	4	21	25%
falsos +	15,75%	6,408%	4,545%	92,01%

Tabela 79: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	84	77	2	48,47%
folhas	22	625	1	3,549%
céu	1	6	21	25%
falsos +	21,5%	11,72%	12,5%	87,01%

Tabela 80: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	100	60	3	38,65%
folhas	22	625	1	3,549%
céu	1	7	20	28,57%
falsos +	18,7%	9,682%	16,67%	88,8%

Tabela 81: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	101	58	4	38,04%
folhas	21	627	0	3,241%
céu	2	5	21	25%
falsos +	18,55%	9,13%	16%	89,27%

Tabela 82: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	110	52	1	32,52%
folhas	14	634	0	2,16%
céu	6	1	21	25%
falsos +	15,38%	7,715%	4,545%	91,18%

Tabela 83: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	113	49	1	30,67%
folhas	21	627	0	3,241%
céu	6	2	20	28,57%
falsos +	19,29%	7,522%	4,762%	90,58%

Tabela 84: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	36	0	22,09%
folhas	17	631	0	2,623%
céu	0	7	21	25%
falsos +	11,81%	6,38%	0%	92,85%

Tabela 85: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	30	0	18,4%
folhas	18	629	1	2,932%
céu	3	4	21	25%
falsos +	13,64%	5,128%	4,545%	93,33%

Tabela 86: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	44	0	26,99%
folhas	63	585	0	9,722%
céu	3	25	0	100%
falsos +	35,68%	10,55%	0%	83,91%

Tabela 87: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	14	634	0	2,16%
céu	1	4	23	17,86%
falsos +	10,14%	4,948%	4,167%	94,16%

Tabela 88: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 70% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	112	43	8	31,29%
folhas	11	634	3	2,16%
céu	0	8	20	28,57%
falsos +	8,943%	7,445%	35,48%	91,3%

C.5 Testes dos classificadores treinados com o conjunto RGB – 100%

Tabela 89: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	31	129	3	80,98%
folhas	21	627	0	3,241%
céu	4	11	13	53,57%
falsos +	44,64%	18,25%	18,75%	79,98%

Tabela 90: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	73	88	2	55,21%
folhas	24	624	0	3,704%
céu	6	4	18	35,71%
falsos +	29,13%	12,85%	10%	85,22%

Tabela 91: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	7	156	0	95,71%
folhas	5	642	1	0,9259%
céu	0	28	0	100%
falsos +	41,67%	22,28%	100%	77,35%

Tabela 92: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	92	70	1	43,56%
folhas	20	628	0	3,086%
céu	4	5	19	32,14%
falsos +	20,69%	10,67%	5%	88,08%

Tabela 93: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	22	141	0	86,5%
folhas	12	636	0	1,852%
céu	1	27	0	100%
falsos +	37,14%	20,9%	0%	78,43%

Tabela 94: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	23	140	0	85,89%
folhas	17	631	0	2,623%
céu	1	27	0	100%
falsos +	43,9%	20,93%	0%	77,95%

Tabela 95: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	118	44	1	27,61%
folhas	29	619	0	4,475%
céu	4	7	17	39,29%
falsos +	21,85%	7,612%	5,556%	89,87%

Tabela 96: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	37	1	23,31%
folhas	22	626	0	3,395%
céu	3	5	20	28,57%
falsos +	16,67%	6,287%	4,762%	91,9%

Tabela 97: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	86	76	1	47,24%
folhas	17	631	0	2,623%
céu	1	13	14	50%
falsos +	17,31%	12,36%	6,667%	87,13%

Tabela 98: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	89	73	1	45,4%
folhas	20	627	1	3,241%
céu	0	9	19	32,14%
falsos +	18,35%	11,57%	9,524%	87,6%

Tabela 99: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	118	43	2	27,61%
folhas	20	628	0	3,086%
céu	10	3	15	46,43%
falsos +	20,27%	6,825%	11,76%	90,7%

Tabela 100: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	98	64	1	39,88%
folhas	21	626	1	3,395%
céu	2	5	21	25%
falsos +	19,01%	9,928%	8,696%	88,8%

Tabela 101: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	36	2	23,31%
folhas	22	626	0	3,395%
céu	2	3	23	17,86%
falsos +	16,11%	5,865%	8%	92,25%

Tabela 102: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	114	49	0	30,06%
folhas	18	630	0	2,778%
céu	9	0	19	32,14%
falsos +	19,15%	7,216%	0%	90,94%

Tabela 103: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	31	2	20,25%
folhas	14	634	0	2,16%
céu	2	4	22	21,43%
falsos +	10,96%	5,232%	8,333%	93,68%

Tabela 104: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	47	1	29,45%
folhas	19	628	1	3,086%
céu	5	0	23	17,86%
falsos +	17,27%	6,963%	8%	91,3%

Tabela 105: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	28	0	17,18%
folhas	14	634	0	2,16%
céu	5	1	22	21,43%
falsos +	12,34%	4,374%	0%	94,28%

Tabela 106: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	117	42	4	28,22%
folhas	12	634	2	2,16%
céu	1	4	23	17,86%
falsos +	10%	6,765%	20,69%	92,25%

Tabela 107: Matriz de confusão do classificador baseado em RNA, conjunto RGB – 100% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	103	60	0	36,81%
folhas	54	594	0	8,333%
céu	5	23	0	100%
falsos +	36,42%	12,26%	0%	83,08%

C.6 Testes dos classificadores treinados com o conjunto HSV – 20%

Tabela 108: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	112	48	3	31,29%
folhas	17	631	0	2,623%
céu	2	10	16	42,86%
falsos +	14,5%	8,418%	15,79%	90,46%

Tabela 109: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	112	49	2	31,29%
folhas	12	635	1	2,006%
céu	1	11	16	42,86%
falsos +	10,4%	8,633%	15,79%	90,94%

Tabela 110: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	117	46	0	28,22%
folhas	3	645	0	0,463%
céu	18	10	0	100%
falsos +	15,22%	7,989%	0%	90,82%

Tabela 111: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	116	47	0	28,83%
folhas	3	645	0	0,463%
céu	16	12	0	100%
falsos +	14,07%	8,381%	0%	90,7%

Tabela 112: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	48	0	29,45%
folhas	4	644	0	0,6173%
céu	13	15	0	100%
falsos +	12,88%	8,911%	0%	90,46%

Tabela 113: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	44	0	26,99%
folhas	4	644	0	0,6173%
céu	13	15	0	100%
falsos +	12,5%	8,393%	0%	90,94%

Tabela 114: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	112	42	9	31,29%
folhas	7	641	0	1,08%
céu	0	12	16	42,86%
falsos +	5,882%	7,77%	36%	91,66%

Tabela 115: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	48	0	29,45%
folhas	8	640	0	1,235%
céu	13	15	0	100%
falsos +	15,44%	8,962%	0%	89,99%

Tabela 116: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	112	42	9	31,29%
folhas	4	644	0	0,6173%
céu	0	11	17	39,29%
falsos +	3,448%	7,604%	34,62%	92,13%

Tabela 117: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	39	9	29,45%
folhas	2	645	1	0,463%
céu	0	11	17	39,29%
falsos +	1,709%	7,194%	37,04%	92,61%

Tabela 118: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	33	4	22,7%
folhas	15	632	1	2,469%
céu	1	11	16	42,86%
falsos +	11,27%	6,509%	23,81%	92,25%

Tabela 119: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	112	40	11	31,29%
folhas	4	643	1	0,7716%
céu	0	12	16	42,86%
falsos +	3,448%	7,482%	42,86%	91,9%

Tabela 120: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	43	0	26,38%
folhas	6	642	0	0,9259%
céu	12	16	0	100%
falsos +	13,04%	8,417%	0%	90,82%

Tabela 121: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	43	0	26,38%
folhas	7	641	0	1,08%
céu	14	14	0	100%
falsos +	14,89%	8,166%	0%	90,7%

Tabela 122: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	40	0	24,54%
folhas	6	642	0	0,9259%
céu	10	18	0	100%
falsos +	11,51%	8,286%	0%	91,18%

Tabela 123: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	38	0	23,31%
folhas	6	642	0	0,9259%
céu	10	18	0	100%
falsos +	11,35%	8,023%	0%	91,42%

Tabela 124: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	35	0	21,47%
folhas	6	642	0	0,9259%
céu	10	18	0	100%
falsos +	11,11%	7,626%	0%	91,78%

Tabela 125: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	36	0	22,09%
folhas	10	638	0	1,543%
céu	17	11	0	100%
falsos +	17,53%	6,861%	0%	91,18%

Tabela 126: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 20% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	38	0	23,31%
folhas	7	641	0	1,08%
céu	19	9	0	100%
falsos +	17,22%	6,831%	0%	91,3%

C.7 Testes dos classificadores treinados com o conjunto HSV – 30%

Tabela 127: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	40	0	24,54%
folhas	14	634	0	2,16%
céu	5	9	14	50%
falsos +	13,38%	7,174%	0%	91,9%

Tabela 128: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	39	1	24,54%
folhas	14	634	0	2,16%
céu	1	11	16	42,86%
falsos +	10,87%	7,31%	5,882%	92,13%

Tabela 129: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	32	1	20,25%
folhas	10	637	1	1,698%
céu	2	9	17	39,29%
falsos +	8,451%	6,047%	10,53%	93,44%

Tabela 130: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	34	10	26,99%
folhas	11	636	1	1,852%
céu	1	11	16	42,86%
falsos +	9,16%	6,608%	40,74%	91,9%

Tabela 131: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	31	2	20,25%
folhas	12	635	1	2,006%
céu	2	11	15	46,43%
falsos +	9,722%	6,204%	16,67%	92,97%

Tabela 132: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	15	633	0	2,315%
céu	2	10	16	42,86%
falsos +	11,33%	5,804%	5,882%	93,21%

Tabela 133: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	31	6	22,7%
folhas	17	631	0	2,623%
céu	2	10	16	42,86%
falsos +	13,1%	6,101%	27,27%	92,13%

Tabela 134: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	31	2	20,25%
folhas	13	634	1	2,16%
céu	1	10	17	39,29%
falsos +	9,722%	6,074%	15%	93,09%

Tabela 135: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	117	37	9	28,22%
folhas	10	637	1	1,698%
céu	2	10	16	42,86%
falsos +	9,302%	6,871%	38,46%	91,78%

Tabela 136: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	33	2	21,47%
folhas	12	634	2	2,16%
céu	0	15	13	53,57%
falsos +	8,571%	7,038%	23,53%	92,37%

Tabela 137: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	116	37	10	28,83%
folhas	3	645	0	0,463%
céu	0	11	17	39,29%
falsos +	2,521%	6,926%	37,04%	92,73%

Tabela 138: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	34	6	24,54%
folhas	6	642	0	0,9259%
céu	4	7	17	39,29%
falsos +	7,519%	6,003%	26,09%	93,21%

Tabela 139: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	7	641	0	1,08%
céu	0	10	18	35,71%
falsos +	4,965%	5,596%	5,263%	94,52%

Tabela 140: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	137	25	1	15,95%
folhas	7	641	0	1,08%
céu	2	12	14	50%
falsos +	6,164%	5,457%	6,667%	94,4%

Tabela 141: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	137	24	2	15,95%
folhas	6	642	0	0,9259%
céu	0	13	15	46,43%
falsos +	4,196%	5,449%	11,76%	94,64%

Tabela 142: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	137	23	3	15,95%
folhas	4	644	0	0,6173%
céu	2	13	13	53,57%
falsos +	4,196%	5,294%	18,75%	94,64%

Tabela 143: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	139	20	4	14,72%
folhas	6	641	1	1,08%
céu	6	8	14	50%
falsos +	7,947%	4,185%	26,32%	94,64%

Tabela 144: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	25	4	17,79%
folhas	7	641	0	1,08%
céu	6	8	14	50%
falsos +	8,844%	4,896%	22,22%	94,04%

Tabela 145: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 30% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	32	0	19,63%
folhas	9	639	0	1,389%
céu	16	12	0	100%
falsos +	16,03%	6,442%	0%	91,78%

C.8 Testes dos classificadores treinados com o conjunto HSV – 50%

Tabela 146: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	109	53	1	33,13%
folhas	17	631	0	2,623%
céu	1	12	15	46,43%
falsos +	14,17%	9,339%	6,25%	89,99%

Tabela 147: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	105	47	11	35,58%
folhas	10	637	1	1,698%
céu	0	11	17	39,29%
falsos +	8,696%	8,345%	41,38%	90,46%

Tabela 148: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	35	0	21,47%
folhas	9	639	0	1,389%
céu	5	2	21	25%
falsos +	9,859%	5,473%	0%	93,92%

Tabela 149: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	18	628	2	3,086%
céu	2	5	21	25%
falsos +	13,07%	5,136%	12,5%	93,21%

Tabela 150: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	30	1	19,02%
folhas	16	630	2	2,778%
céu	1	4	23	17,86%
falsos +	11,41%	5,12%	11,54%	93,56%

Tabela 151: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	32	1	20,25%
folhas	13	634	1	2,16%
céu	2	9	17	39,29%
falsos +	10,34%	6,074%	10,53%	93,09%

Tabela 152: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	9	638	1	1,543%
céu	4	3	21	25%
falsos +	9,155%	5,341%	8,696%	93,92%

Tabela 153: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	12	636	0	1,852%
céu	3	6	19	32,14%
falsos +	10,14%	5,216%	5%	93,92%

Tabela 154: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	7	641	0	1,08%
céu	3	2	23	17,86%
falsos +	7,194%	5,178%	4,167%	94,52%

Tabela 155: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	17	631	0	2,623%
céu	3	1	24	14,29%
falsos +	12,99%	4,394%	4%	94,04%

Tabela 156: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	30	1	19,02%
folhas	10	638	0	1,543%
céu	1	2	25	10,71%
falsos +	7,692%	4,776%	3,846%	94,76%

Tabela 157: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	26	2	17,18%
folhas	14	634	0	2,16%
céu	3	1	24	14,29%
falsos +	11,18%	4,085%	7,692%	94,52%

Tabela 158: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	23	4	16,56%
folhas	13	635	0	2,006%
céu	3	0	25	10,71%
falsos +	10,53%	3,495%	13,79%	94,87%

Tabela 159: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	39	1	24,54%
folhas	11	637	0	1,698%
céu	0	3	25	10,71%
falsos +	8,209%	6,186%	3,846%	93,56%

Tabela 160: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	138	24	1	15,34%
folhas	12	636	0	1,852%
céu	3	2	23	17,86%
falsos +	9,804%	3,927%	4,167%	94,99%

Tabela 161: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	141	21	1	13,5%
folhas	11	637	0	1,698%
céu	3	3	22	21,43%
falsos +	9,032%	3,631%	4,348%	95,35%

Tabela 162: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	27	1	17,18%
folhas	9	639	0	1,389%
céu	0	4	24	14,29%
falsos +	6,25%	4,627%	4%	95,11%

Tabela 163: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	33	4	22,7%
folhas	8	640	0	1,235%
céu	1	2	25	10,71%
falsos +	6,667%	5,185%	13,79%	94,28%

Tabela 164: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 50% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	138	25	0	15,34%
folhas	8	640	0	1,235%
céu	1	4	23	17,86%
falsos +	6,122%	4,335%	0%	95,47%

C.9 Testes dos classificadores treinados com o conjunto HSV – 70%

Tabela 165: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	103	60	0	36,81%
folhas	20	628	0	3,086%
céu	15	13	0	100%
falsos +	25,36%	10,41%	0%	87,13%

Tabela 166: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	48	0	29,45%
folhas	10	638	0	1,543%
céu	15	12	1	96,43%
falsos +	17,86%	8,596%	0%	89,87%

Tabela 167: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	38	0	23,31%
folhas	15	633	0	2,315%
céu	13	15	0	100%
falsos +	18,3%	7,726%	0%	90,35%

Tabela 168: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	104	59	0	36,2%
folhas	26	622	0	4,012%
céu	2	26	0	100%
falsos +	21,21%	12,02%	0%	86,53%

Tabela 169: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	43	0	26,38%
folhas	17	631	0	2,623%
céu	21	7	0	100%
falsos +	24,05%	7,342%	0%	89,51%

Tabela 170: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	39	0	23,93%
folhas	16	632	0	2,469%
céu	21	7	0	100%
falsos +	22,98%	6,785%	0%	90,11%

Tabela 171: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	34	1	21,47%
folhas	12	636	0	1,852%
céu	1	5	22	21,43%
falsos +	9,22%	5,778%	4,348%	93,68%

Tabela 172: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	9	639	0	1,389%
céu	3	3	22	21,43%
falsos +	8,511%	5,333%	4,348%	94,16%

Tabela 173: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	13	635	0	2,006%
céu	0	2	26	7,143%
falsos +	8,904%	4,655%	3,704%	94,64%

Tabela 174: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	39	2	25,15%
folhas	4	644	0	0,6173%
céu	0	3	25	10,71%
falsos +	3,175%	6,122%	7,407%	94,28%

Tabela 175: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	35	0	21,47%
folhas	6	642	0	0,9259%
céu	0	3	25	10,71%
falsos +	4,478%	5,588%	0%	94,76%

Tabela 176: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	34	1	21,47%
folhas	4	644	0	0,6173%
céu	1	4	23	17,86%
falsos +	3,759%	5,572%	4,167%	94,76%

Tabela 177: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	29	0	17,79%
folhas	9	639	0	1,389%
céu	5	1	22	21,43%
falsos +	9,459%	4,484%	0%	94,76%

Tabela 178: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	8	640	0	1,235%
céu	2	1	25	10,71%
falsos +	7,194%	5,045%	3,846%	94,64%

Tabela 179: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	33	0	20,25%
folhas	6	642	0	0,9259%
céu	2	1	25	10,71%
falsos +	5,797%	5,03%	0%	94,99%

Tabela 180: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	111	36	16	31,9%
folhas	6	642	0	0,9259%
céu	0	2	26	7,143%
falsos +	5,128%	5,588%	38,1%	92,85%

Tabela 181: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	31	6	22,7%
folhas	8	640	0	1,235%
céu	1	1	26	7,143%
falsos +	6,667%	4,762%	18,75%	94,4%

Tabela 182: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	27	0	16,56%
folhas	10	638	0	1,543%
céu	3	1	24	14,29%
falsos +	8,725%	4,204%	0%	95,11%

Tabela 183: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 70% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	34	2	22,09%
folhas	5	643	0	0,7716%
céu	11	2	15	46,43%
falsos +	11,19%	5,302%	11,76%	93,56%

C.10 Testes dos classificadores treinados com o conjunto HSV – 100%

Tabela 184: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	99	63	1	39,26%
folhas	16	632	0	2,469%
céu	1	12	15	46,43%
falsos +	14,66%	10,61%	6,25%	88,92%

Tabela 185: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	36	1	22,7%
folhas	14	633	1	2,315%
céu	3	6	19	32,14%
falsos +	11,89%	6,222%	9,524%	92,73%

Tabela 186: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	44	0	26,99%
folhas	44	604	0	6,79%
céu	3	25	0	100%
falsos +	28,31%	10,25%	0%	86,17%

Tabela 187: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	112	51	0	31,29%
folhas	33	615	0	5,093%
céu	23	5	0	100%
falsos +	33,33%	8,346%	0%	86,65%

Tabela 188: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	12	635	1	2,006%
céu	3	5	20	28,57%
falsos +	10,42%	5,646%	9,091%	93,44%

Tabela 189: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	43	0	26,38%
folhas	9	639	0	1,389%
céu	12	16	0	100%
falsos +	14,89%	8,453%	0%	90,46%

Tabela 190: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	36	1	22,7%
folhas	10	638	0	1,543%
céu	3	3	22	21,43%
falsos +	9,353%	5,761%	4,348%	93,68%

Tabela 191: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	26	1	16,56%
folhas	17	631	0	2,623%
céu	0	1	27	3,571%
falsos +	11,11%	4,103%	3,571%	94,64%

Tabela 192: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	32	0	19,63%
folhas	8	640	0	1,235%
céu	3	1	24	14,29%
falsos +	7,746%	4,903%	0%	94,76%

Tabela 193: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	37	4	25,15%
folhas	2	646	0	0,3086%
céu	0	1	27	3,571%
falsos +	1,613%	5,556%	12,9%	94,76%

Tabela 194: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	32	0	19,63%
folhas	10	638	0	1,543%
céu	1	2	25	10,71%
falsos +	7,746%	5,06%	0%	94,64%

Tabela 195: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	27	2	17,79%
folhas	8	640	0	1,235%
céu	3	1	24	14,29%
falsos +	7,586%	4,192%	7,692%	95,11%

Tabela 196: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	44	0	26,99%
folhas	20	628	0	3,086%
céu	1	27	0	100%
falsos +	15%	10,16%	0%	89,03%

Tabela 197: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	39	4	26,38%
folhas	5	642	1	0,9259%
céu	2	0	26	7,143%
falsos +	5,512%	5,727%	16,13%	93,92%

Tabela 198: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	47	1	29,45%
folhas	35	611	2	5,71%
céu	1	15	12	57,14%
falsos +	23,84%	9,212%	20%	87,96%

Tabela 199: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	35	3	23,31%
folhas	5	643	0	0,7716%
céu	2	2	24	14,29%
falsos +	5,303%	5,441%	11,11%	94,4%

Tabela 200: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	36	3	23,93%
folhas	7	641	0	1,08%
céu	2	0	26	7,143%
falsos +	6,767%	5,318%	10,34%	94,28%

Tabela 201: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	36	4	24,54%
folhas	6	642	0	0,9259%
céu	0	2	26	7,143%
falsos +	4,651%	5,588%	13,33%	94,28%

Tabela 202: Matriz de confusão do classificador baseado em RNA, conjunto HSV – 100% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	32	5	22,7%
folhas	7	641	0	1,08%
céu	1	2	25	10,71%
falsos +	5,97%	5,037%	16,67%	94,4%

APÊNDICE D – Matrizes de confusão dos testes do classificador bayesiano

D.1 Testes dos classificadores treinados com o conjunto RGB – 20%

Tabela 203: Matriz de confusão do classificador bayesiano, conjunto RGB – 20% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	43	108	12	73,62%
folhas	12	635	1	2,006%
céu	10	9	9	67,86%
falsos +	33,85%	15,56%	59,09%	81,88%

Tabela 204: Matriz de confusão do classificador bayesiano, conjunto RGB – 20% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	90	60	13	44,79%
folhas	26	622	0	4,012%
céu	7	10	11	60,71%
falsos +	26,83%	10,12%	54,17%	86,17%

Tabela 205: Matriz de confusão do classificador bayesiano, conjunto RGB – 20% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	109	42	12	33,13%
folhas	19	628	1	3,086%
céu	7	8	13	53,57%
falsos +	19,26%	7,375%	50%	89,39%

Tabela 206: Matriz de confusão do classificador bayesiano, conjunto RGB – 20% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	28	11	23,93%
folhas	33	614	1	5,247%
céu	4	10	14	50%
falsos +	22,98%	5,828%	46,15%	89,63%

Tabela 207: Matriz de confusão do classificador bayesiano, conjunto RGB – 20% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	30	5	21,47%
folhas	31	617	0	4,784%
céu	1	12	15	46,43%
falsos +	20%	6,373%	25%	90,58%

Tabela 208: Matriz de confusão do classificador bayesiano, conjunto RGB – 20% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	32	6	23,31%
folhas	30	618	0	4,63%
céu	4	8	16	42,86%
falsos +	21,38%	6,079%	27,27%	90,46%

Tabela 209: Matriz de confusão do classificador bayesiano, conjunto RGB – 20% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	33	6	23,93%
folhas	23	625	0	3,549%
céu	2	10	16	42,86%
falsos +	16,78%	6,437%	27,27%	91,18%

Tabela 210: Matriz de confusão do classificador bayesiano, conjunto RGB – 20% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	36	7	26,38%
folhas	20	628	0	3,086%
céu	2	8	18	35,71%
falsos +	15,49%	6,548%	28%	91,3%

Tabela 211: Matriz de confusão do classificador bayesiano, conjunto RGB – 20% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	27	2	17,79%
folhas	29	619	0	4,475%
céu	0	9	19	32,14%
falsos +	17,79%	5,496%	9,524%	92,01%

D.2 Testes dos classificadores treinados com o conjunto RGB – 30%

Tabela 212: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	32	120	11	80,37%
folhas	16	632	0	2,469%
céu	5	13	10	64,29%
falsos +	39,62%	17,39%	52,38%	80,33%

Tabela 213: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	86	66	11	47,24%
folhas	33	615	0	5,093%
céu	0	13	15	46,43%
falsos +	27,73%	11,38%	42,31%	85,34%

Tabela 214: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	111	45	7	31,9%
folhas	23	624	1	3,704%
céu	1	12	15	46,43%
falsos +	17,78%	8,37%	34,78%	89,39%

Tabela 215: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	35	4	23,93%
folhas	36	612	0	5,556%
céu	2	6	20	28,57%
falsos +	23,46%	6,279%	16,67%	90,11%

Tabela 216: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	31	5	22,09%
folhas	27	621	0	4,167%
céu	1	6	21	25%
falsos +	18,06%	5,623%	19,23%	91,66%

Tabela 217: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	31	5	22,09%
folhas	27	621	0	4,167%
céu	0	8	20	28,57%
falsos +	17,53%	5,909%	20%	91,54%

Tabela 218: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	26	5	19,02%
folhas	21	626	1	3,395%
céu	0	8	20	28,57%
falsos +	13,73%	5,152%	23,08%	92,73%

Tabela 219: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	29	8	22,7%
folhas	16	631	1	2,623%
céu	0	8	20	28,57%
falsos +	11,27%	5,539%	31,03%	92,61%

Tabela 220: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	27	8	21,47%
folhas	18	628	2	3,086%
céu	0	7	21	25%
falsos +	12,33%	5,136%	32,26%	92,61%

Tabela 221: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	30	5	21,47%
folhas	17	629	2	2,932%
céu	3	3	22	21,43%
falsos +	13,51%	4,985%	24,14%	92,85%

Tabela 222: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	27	6	20,25%
folhas	22	623	3	3,858%
céu	0	6	22	21,43%
falsos +	14,47%	5,03%	29,03%	92,37%

Tabela 223: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	30	11	25,15%
folhas	23	623	2	3,858%
céu	1	4	23	17,86%
falsos +	16,44%	5,175%	36,11%	91,54%

Tabela 224: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	25	6	19,02%
folhas	22	624	2	3,704%
céu	2	4	22	21,43%
falsos +	15,38%	4,441%	26,67%	92,73%

Tabela 225: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	27	12	23,93%
folhas	16	629	3	2,932%
céu	0	6	22	21,43%
falsos +	11,43%	4,985%	40,54%	92,37%

Tabela 226: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	25	12	22,7%
folhas	20	627	1	3,241%
céu	0	5	23	17,86%
falsos +	13,7%	4,566%	36,11%	92,49%

Tabela 227: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	37	11	29,45%
folhas	17	628	3	3,086%
céu	2	3	23	17,86%
falsos +	14,18%	5,988%	37,84%	91,3%

Tabela 228: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	26	11	22,7%
folhas	26	620	2	4,321%
céu	3	1	24	14,29%
falsos +	18,71%	4,173%	35,14%	91,78%

Tabela 229: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	20	9	17,79%
folhas	39	607	2	6,327%
céu	2	0	26	7,143%
falsos +	23,43%	3,19%	29,73%	91,42%

Tabela 230: Matriz de confusão do classificador bayesiano, conjunto RGB – 30% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	37	11	29,45%
folhas	17	627	4	3,241%
céu	3	0	25	10,71%
falsos +	14,81%	5,572%	37,5%	91,42%

D.3 Testes dos classificadores treinados com o conjunto RGB – 50%

Tabela 231: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	42	115	6	74,23%
folhas	28	615	5	5,093%
céu	1	9	18	35,71%
falsos +	40,85%	16,78%	37,93%	80,45%

Tabela 232: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	82	77	4	49,69%
folhas	30	617	1	4,784%
céu	1	5	22	21,43%
falsos +	27,43%	11,73%	18,52%	85,94%

Tabela 233: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	110	53	0	32,52%
folhas	31	614	3	5,247%
céu	6	1	21	25%
falsos +	25,17%	8,084%	12,5%	88,8%

Tabela 234: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	29	2	19,02%
folhas	26	622	0	4,012%
céu	3	6	19	32,14%
falsos +	18,01%	5,327%	9,524%	92,13%

Tabela 235: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	39	1	24,54%
folhas	21	624	3	3,704%
céu	1	3	24	14,29%
falsos +	15,17%	6,306%	14,29%	91,9%

Tabela 236: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	32	3	21,47%
folhas	23	621	4	4,167%
céu	0	3	25	10,71%
falsos +	15,23%	5,335%	21,88%	92,25%

Tabela 237: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	27	3	18,4%
folhas	24	617	7	4,784%
céu	1	2	25	10,71%
falsos +	15,82%	4,489%	28,57%	92,37%

Tabela 238: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	28	2	18,4%
folhas	20	626	2	3,395%
céu	0	7	21	25%
falsos +	13,07%	5,295%	16%	92,97%

Tabela 239: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	28	3	19,02%
folhas	19	627	2	3,241%
céu	0	6	22	21,43%
falsos +	12,58%	5,144%	18,52%	93,09%

Tabela 240: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	137	24	2	15,95%
folhas	24	622	2	4,012%
céu	0	6	22	21,43%
falsos +	14,91%	4,601%	15,38%	93,09%

Tabela 241: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	30	2	19,63%
folhas	20	627	1	3,241%
céu	0	2	26	7,143%
falsos +	13,25%	4,856%	10,34%	93,44%

Tabela 242: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	26	2	17,18%
folhas	23	621	4	4,167%
céu	0	0	28	0%
falsos +	14,56%	4,019%	17,65%	93,44%

Tabela 243: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	138	23	2	15,34%
folhas	23	622	3	4,012%
céu	0	0	28	0%
falsos +	14,29%	3,566%	15,15%	93,92%

Tabela 244: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	29	4	20,25%
folhas	24	620	4	4,321%
céu	0	0	28	0%
falsos +	15,58%	4,468%	22,22%	92,73%

Tabela 245: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	29	4	20,25%
folhas	18	628	2	3,086%
céu	0	1	27	3,571%
falsos +	12,16%	4,559%	18,18%	93,56%

Tabela 246: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	31	4	21,47%
folhas	18	628	2	3,086%
céu	0	1	27	3,571%
falsos +	12,33%	4,848%	18,18%	93,33%

Tabela 247: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	112	42	9	31,29%
folhas	15	627	6	3,241%
céu	0	0	28	0%
falsos +	11,81%	6,278%	34,88%	91,42%

Tabela 248: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	27	6	20,25%
folhas	24	620	4	4,321%
céu	0	0	28	0%
falsos +	15,58%	4,173%	26,32%	92,73%

Tabela 249: Matriz de confusão do classificador bayesiano, conjunto RGB – 50% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	30	9	23,93%
folhas	15	625	8	3,549%
céu	0	0	28	0%
falsos +	10,79%	4,58%	37,78%	92,61%

D.4 Testes dos classificadores treinados com o conjunto RGB – 70%

Tabela 250: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	33	126	4	79,75%
folhas	22	624	2	3,704%
céu	9	5	14	50%
falsos +	48,44%	17,35%	30%	79,98%

Tabela 251: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	77	83	3	52,76%
folhas	25	623	0	3,858%
céu	2	6	20	28,57%
falsos +	25,96%	12,5%	13,04%	85,82%

Tabela 252: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	108	54	1	33,74%
folhas	22	622	4	4,012%
céu	3	3	22	21,43%
falsos +	18,8%	8,395%	18,52%	89,63%

Tabela 253: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	38	0	23,31%
folhas	24	623	1	3,858%
céu	1	8	19	32,14%
falsos +	16,67%	6,876%	5%	91,42%

Tabela 254: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	32	3	21,47%
folhas	20	625	3	3,549%
céu	0	4	24	14,29%
falsos +	13,51%	5,446%	20%	92,61%

Tabela 255: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	137	24	2	15,95%
folhas	28	616	4	4,938%
céu	0	5	23	17,86%
falsos +	16,97%	4,496%	20,69%	92,49%

Tabela 256: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	32	0	19,63%
folhas	22	623	3	3,858%
céu	1	6	21	25%
falsos +	14,94%	5,749%	12,5%	92,37%

Tabela 257: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	27	2	17,79%
folhas	19	622	7	4,012%
céu	0	3	25	10,71%
falsos +	12,42%	4,601%	26,47%	93,09%

Tabela 258: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	36	0	22,09%
folhas	15	631	2	2,623%
céu	0	12	16	42,86%
falsos +	10,56%	7,069%	11,11%	92,25%

Tabela 259: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	26	2	17,18%
folhas	24	623	1	3,858%
céu	0	3	25	10,71%
falsos +	15,09%	4,448%	10,71%	93,33%

Tabela 260: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	30	2	19,63%
folhas	21	625	2	3,549%
céu	0	3	25	10,71%
falsos +	13,82%	5,015%	13,79%	93,09%

Tabela 261: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	34	2	22,09%
folhas	19	626	3	3,395%
céu	0	1	27	3,571%
falsos +	13,01%	5,295%	15,62%	92,97%

Tabela 262: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	31	3	20,86%
folhas	18	627	3	3,241%
céu	0	0	28	0%
falsos +	12,24%	4,711%	17,65%	93,44%

Tabela 263: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	137	21	5	15,95%
folhas	24	622	2	4,012%
céu	0	1	27	3,571%
falsos +	14,91%	3,416%	20,59%	93,68%

Tabela 264: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	30	3	20,25%
folhas	28	617	3	4,784%
céu	0	0	28	0%
falsos +	17,72%	4,637%	17,65%	92,37%

Tabela 265: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	25	3	17,18%
folhas	17	630	1	2,778%
céu	0	1	27	3,571%
falsos +	11,18%	3,963%	12,9%	94,4%

Tabela 266: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	25	4	17,79%
folhas	23	624	1	3,704%
céu	0	2	26	7,143%
falsos +	14,65%	4,147%	16,13%	93,44%

Tabela 267: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	30	5	21,47%
folhas	25	621	2	4,167%
céu	0	0	28	0%
falsos +	16,34%	4,608%	20%	92,61%

Tabela 268: Matriz de confusão do classificador bayesiano, conjunto RGB – 70% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	138	21	4	15,34%
folhas	32	615	1	5,093%
céu	0	0	28	0%
falsos +	18,82%	3,302%	15,15%	93,09%

D.5 Testes dos classificadores treinados com o conjunto RGB – 100%

Tabela 269: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	34	126	3	79,14%
folhas	25	622	1	4,012%
céu	9	5	14	50%
falsos +	50%	17,4%	22,22%	79,86%

Tabela 270: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	83	77	3	49,08%
folhas	30	618	0	4,63%
céu	6	5	17	39,29%
falsos +	30,25%	11,71%	15%	85,58%

Tabela 271: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	101	61	1	38,04%
folhas	17	629	2	2,932%
céu	1	6	21	25%
falsos +	15,13%	9,626%	12,5%	89,51%

Tabela 272: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	40	0	24,54%
folhas	26	617	5	4,784%
céu	0	8	20	28,57%
falsos +	17,45%	7,218%	20%	90,58%

Tabela 273: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	32	2	20,86%
folhas	26	619	3	4,475%
céu	0	7	21	25%
falsos +	16,77%	5,927%	19,23%	91,66%

Tabela 274: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	27	619	2	4,475%
céu	0	11	17	39,29%
falsos +	16,88%	6,07%	15%	91,66%

Tabela 275: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	30	0	18,4%
folhas	25	621	2	4,167%
céu	0	9	19	32,14%
falsos +	15,82%	5,909%	9,524%	92,13%

Tabela 276: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	139	21	3	14,72%
folhas	25	620	3	4,321%
céu	0	3	25	10,71%
falsos +	15,24%	3,727%	19,35%	93,44%

Tabela 277: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	19	628	1	3,086%
céu	2	8	18	35,71%
falsos +	13,64%	5,564%	10%	92,85%

Tabela 278: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	25	3	17,18%
folhas	20	624	4	3,704%
céu	0	3	25	10,71%
falsos +	12,9%	4,294%	21,88%	93,44%

Tabela 279: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	138	25	0	15,34%
folhas	21	626	1	3,395%
céu	0	3	25	10,71%
falsos +	13,21%	4,281%	3,846%	94,04%

Tabela 280: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	33	3	22,09%
folhas	19	628	1	3,086%
céu	0	3	25	10,71%
falsos +	13,01%	5,422%	13,79%	92,97%

Tabela 281: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	30	3	20,25%
folhas	26	620	2	4,321%
céu	0	0	28	0%
falsos +	16,67%	4,615%	15,15%	92,73%

Tabela 282: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	26	3	17,79%
folhas	23	622	3	4,012%
céu	0	1	27	3,571%
falsos +	14,65%	4,16%	18,18%	93,33%

Tabela 283: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	34	2	22,09%
folhas	17	628	3	3,086%
céu	0	1	27	3,571%
falsos +	11,81%	5,279%	15,62%	93,21%

Tabela 284: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	108	45	10	33,74%
folhas	12	633	3	2,315%
céu	0	0	28	0%
falsos +	10%	6,637%	31,71%	91,66%

Tabela 285: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	28	4	19,63%
folhas	21	625	2	3,549%
céu	0	1	27	3,571%
falsos +	13,82%	4,434%	18,18%	93,33%

Tabela 286: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	29	4	20,25%
folhas	20	626	2	3,395%
céu	0	0	28	0%
falsos +	13,33%	4,427%	17,65%	93,44%

Tabela 287: Matriz de confusão do classificador bayesiano, conjunto RGB – 100% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	138	21	4	15,34%
folhas	25	622	1	4,012%
céu	0	1	27	3,571%
falsos +	15,34%	3,416%	15,62%	93,8%

D.6 Testes dos classificadores treinados com o conjunto HSV – 20%

Tabela 288: Matriz de confusão do classificador bayesiano, conjunto HSV – 20% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	118	45	0	27,61%
folhas	17	631	0	2,623%
céu	1	11	16	42,86%
falsos +	13,24%	8,151%	0%	91,18%

Tabela 289: Matriz de confusão do classificador bayesiano, conjunto HSV – 20% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	110	52	1	32,52%
folhas	13	634	1	2,16%
céu	2	12	14	50%
falsos +	12%	9,169%	12,5%	90,35%

Tabela 290: Matriz de confusão do classificador bayesiano, conjunto HSV – 20% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	32	1	20,25%
folhas	5	643	0	0,7716%
céu	7	8	13	53,57%
falsos +	8,451%	5,857%	7,143%	93,68%

Tabela 291: Matriz de confusão do classificador bayesiano, conjunto HSV – 20% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	28	2	18,4%
folhas	11	637	0	1,698%
céu	1	13	14	50%
falsos +	8,276%	6,047%	12,5%	93,44%

Tabela 292: Matriz de confusão do classificador bayesiano, conjunto HSV – 20% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	29	3	19,63%
folhas	13	635	0	2,006%
céu	0	13	15	46,43%
falsos +	9,028%	6,204%	16,67%	93,09%

Tabela 293: Matriz de confusão do classificador bayesiano, conjunto HSV – 20% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	28	3	19,02%
folhas	10	638	0	1,543%
céu	1	15	12	57,14%
falsos +	7,692%	6,314%	20%	93,21%

Tabela 294: Matriz de confusão do classificador bayesiano, conjunto HSV – 20% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	138	24	1	15,34%
folhas	17	631	0	2,623%
céu	0	16	12	57,14%
falsos +	10,97%	5,961%	7,692%	93,09%

Tabela 295: Matriz de confusão do classificador bayesiano, conjunto HSV – 20% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	30	1	19,02%
folhas	11	637	0	1,698%
céu	2	13	13	53,57%
falsos +	8,966%	6,324%	7,143%	93,21%

D.7 Testes dos classificadores treinados com o conjunto HSV – 30%

Tabela 296: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	39	0	23,93%
folhas	15	633	0	2,315%
céu	3	10	15	46,43%
falsos +	12,68%	7,185%	0%	92,01%

Tabela 297: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	32	1	20,25%
folhas	11	637	0	1,698%
céu	2	9	17	39,29%
falsos +	9,091%	6,047%	5,556%	93,44%

Tabela 298: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	38	2	24,54%
folhas	10	638	0	1,543%
céu	3	8	17	39,29%
falsos +	9,559%	6,725%	10,53%	92,73%

Tabela 299: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	13	635	0	2,006%
céu	1	11	16	42,86%
falsos +	9,79%	6,48%	5,882%	92,97%

Tabela 300: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	20	628	0	3,086%
céu	3	9	16	42,86%
falsos +	14,65%	5,564%	5,882%	92,73%

Tabela 301: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	14	634	0	2,16%
céu	2	9	17	39,29%
falsos +	10,67%	5,514%	5,556%	93,56%

Tabela 302: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	14	634	0	2,16%
céu	5	7	16	42,86%
falsos +	12,42%	5,232%	5,882%	93,44%

Tabela 303: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	13	635	0	2,006%
céu	3	7	18	35,71%
falsos +	10,67%	5,224%	5,263%	93,8%

Tabela 304: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	15	633	0	2,315%
céu	3	6	19	32,14%
falsos +	11,84%	5,097%	5%	93,68%

Tabela 305: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	11	637	0	1,698%
céu	0	9	19	32,14%
falsos +	7,586%	5,49%	5%	94,16%

Tabela 306: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	15	633	0	2,315%
céu	4	4	20	28,57%
falsos +	12,42%	4,812%	4,762%	93,8%

Tabela 307: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	27	1	17,18%
folhas	19	629	0	2,932%
céu	4	5	19	32,14%
falsos +	14,56%	4,841%	5%	93,33%

Tabela 308: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	26	1	16,56%
folhas	13	635	0	2,006%
céu	0	7	21	25%
falsos +	8,725%	4,94%	4,545%	94,4%

Tabela 309: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	26	1	16,56%
folhas	12	636	0	1,852%
céu	1	4	23	17,86%
falsos +	8,725%	4,505%	4,167%	94,76%

Tabela 310: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	26	1	16,56%
folhas	11	637	0	1,698%
céu	0	5	23	17,86%
falsos +	7,483%	4,641%	4,167%	94,87%

Tabela 311: Matriz de confusão do classificador bayesiano, conjunto HSV – 30% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	144	18	1	11,66%
folhas	13	635	0	2,006%
céu	1	5	22	21,43%
falsos +	8,861%	3,495%	4,348%	95,47%

D.8 Testes dos classificadores treinados com o conjunto HSV – 50%

Tabela 312: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	103	59	1	36,81%
folhas	16	632	0	2,469%
céu	2	11	15	46,43%
falsos +	14,88%	9,972%	6,25%	89,39%

Tabela 313: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	32	1	20,25%
folhas	9	638	1	1,543%
céu	3	3	22	21,43%
falsos +	8,451%	5,201%	8,333%	94,16%

Tabela 314: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	35	1	22,09%
folhas	7	641	0	1,08%
céu	3	2	23	17,86%
falsos +	7,299%	5,457%	4,167%	94,28%

Tabela 315: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	32	1	20,25%
folhas	12	635	1	2,006%
céu	2	2	24	14,29%
falsos +	9,722%	5,082%	7,692%	94,04%

Tabela 316: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	30	1	19,02%
folhas	19	628	1	3,086%
céu	3	0	25	10,71%
falsos +	14,29%	4,559%	7,407%	93,56%

Tabela 317: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	29	0	17,79%
folhas	12	635	1	2,006%
céu	3	3	22	21,43%
falsos +	10,07%	4,798%	4,348%	94,28%

Tabela 318: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	10	637	1	1,698%
céu	3	0	25	10,71%
falsos +	9,155%	4,925%	7,407%	94,28%

Tabela 319: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	31	1	19,63%
folhas	12	636	0	1,852%
céu	3	1	24	14,29%
falsos +	10,27%	4,79%	4%	94,28%

Tabela 320: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	32	1	20,25%
folhas	11	637	0	1,698%
céu	2	0	26	7,143%
falsos +	9,091%	4,783%	3,704%	94,52%

Tabela 321: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	139	23	1	14,72%
folhas	10	636	2	1,852%
céu	3	0	25	10,71%
falsos +	8,553%	3,49%	10,71%	95,35%

Tabela 322: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	28	0	17,18%
folhas	12	635	1	2,006%
céu	3	0	25	10,71%
falsos +	10%	4,223%	3,846%	94,76%

Tabela 323: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	18	629	1	2,932%
céu	3	0	25	10,71%
falsos +	13,64%	4,407%	7,407%	93,8%

Tabela 324: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	31	1	19,63%
folhas	9	639	0	1,389%
céu	3	0	25	10,71%
falsos +	8,392%	4,627%	3,846%	94,76%

Tabela 325: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	32	1	20,25%
folhas	13	635	0	2,006%
céu	3	0	25	10,71%
falsos +	10,96%	4,798%	3,846%	94,16%

Tabela 326: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	31	1	19,63%
folhas	13	634	1	2,16%
céu	3	0	25	10,71%
falsos +	10,88%	4,662%	7,407%	94,16%

Tabela 327: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	27	1	17,18%
folhas	14	633	1	2,315%
céu	2	1	25	10,71%
falsos +	10,6%	4,236%	7,407%	94,52%

Tabela 328: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	26	1	16,56%
folhas	12	633	3	2,315%
céu	0	3	25	10,71%
falsos +	8,108%	4,381%	13,79%	94,64%

Tabela 329: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	10	637	1	1,698%
céu	0	3	25	10,71%
falsos +	6,944%	4,641%	7,407%	94,87%

Tabela 330: Matriz de confusão do classificador bayesiano, conjunto HSV – 50% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	144	18	1	11,66%
folhas	20	628	0	3,086%
céu	2	0	26	7,143%
falsos +	13,25%	2,786%	3,704%	95,11%

D.9 Testes dos classificadores treinados com o conjunto HSV – 70%

Tabela 331: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	103	59	1	36,81%
folhas	20	628	0	3,086%
céu	1	12	15	46,43%
falsos +	16,94%	10,16%	6,25%	88,92%

Tabela 332: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	37	1	23,31%
folhas	10	637	1	1,698%
céu	4	2	22	21,43%
falsos +	10,07%	5,769%	8,333%	93,44%

Tabela 333: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	12	636	0	1,852%
céu	2	3	23	17,86%
falsos +	9,79%	5,357%	4,167%	93,92%

Tabela 334: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	30	1	19,02%
folhas	14	632	2	2,469%
céu	1	2	25	10,71%
falsos +	10,2%	4,819%	10,71%	94,04%

Tabela 335: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	32	0	19,63%
folhas	13	634	1	2,16%
céu	1	2	25	10,71%
falsos +	9,655%	5,09%	3,846%	94,16%

Tabela 336: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	11	635	2	2,006%
céu	1	2	25	10,71%
falsos +	8,276%	4,655%	10,71%	94,52%

Tabela 337: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	8	639	1	1,389%
céu	2	0	26	7,143%
falsos +	6,993%	4,341%	7,143%	95,11%

Tabela 338: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	35	0	21,47%
folhas	8	639	1	1,389%
céu	1	1	26	7,143%
falsos +	6,569%	5,333%	3,704%	94,52%

Tabela 339: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	32	0	19,63%
folhas	11	637	0	1,698%
céu	0	0	28	0%
falsos +	7,746%	4,783%	0%	94,87%

Tabela 340: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	29	0	17,79%
folhas	13	634	1	2,16%
céu	0	0	28	0%
falsos +	8,844%	4,374%	3,448%	94,87%

Tabela 341: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	28	0	17,18%
folhas	13	635	0	2,006%
céu	0	0	28	0%
falsos +	8,784%	4,223%	0%	95,11%

Tabela 342: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	33	0	20,25%
folhas	9	638	1	1,543%
céu	1	0	27	3,571%
falsos +	7,143%	4,918%	3,571%	94,76%

Tabela 343: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	15	631	2	2,623%
céu	0	0	28	0%
falsos +	10,14%	4,394%	9,677%	94,4%

Tabela 344: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	27	0	16,56%
folhas	21	627	0	3,241%
céu	0	0	28	0%
falsos +	13,38%	4,128%	0%	94,28%

Tabela 345: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	36	0	22,09%
folhas	9	639	0	1,389%
céu	1	0	27	3,571%
falsos +	7,299%	5,333%	0%	94,52%

Tabela 346: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	32	1	20,25%
folhas	10	638	0	1,543%
céu	0	0	28	0%
falsos +	7,143%	4,776%	3,448%	94,87%

Tabela 347: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	137	25	1	15,95%
folhas	18	629	1	2,932%
céu	0	1	27	3,571%
falsos +	11,61%	3,969%	6,897%	94,52%

Tabela 348: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	10	638	0	1,543%
céu	0	0	28	0%
falsos +	6,993%	4,348%	3,448%	95,23%

Tabela 349: Matriz de confusão do classificador bayesiano, conjunto HSV – 70% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	12	636	0	1,852%
céu	0	0	28	0%
falsos +	8,276%	4,361%	3,448%	94,99%

D.10 Testes dos classificadores treinados com o conjunto HSV – 100%

Tabela 350: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	102	60	1	37,42%
folhas	19	629	0	2,932%
céu	2	12	14	50%
falsos +	17,07%	10,27%	6,667%	88,8%

Tabela 351: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	9	638	1	1,543%
céu	2	4	22	21,43%
falsos +	7,857%	5,481%	8,333%	94,04%

Tabela 352: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	9	639	0	1,389%
céu	1	4	23	17,86%
falsos +	7,194%	5,473%	4,167%	94,28%

Tabela 353: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	31	0	19,02%
folhas	10	636	2	1,852%
céu	0	3	25	10,71%
falsos +	7,042%	5,075%	7,407%	94,52%

Tabela 354: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	29	0	17,79%
folhas	13	634	1	2,16%
céu	0	2	26	7,143%
falsos +	8,844%	4,662%	3,704%	94,64%

Tabela 355: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	34	1	21,47%
folhas	16	631	1	2,623%
céu	1	1	26	7,143%
falsos +	11,72%	5,255%	7,143%	93,56%

Tabela 356: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	26	1	16,56%
folhas	18	629	1	2,932%
céu	1	1	26	7,143%
falsos +	12,26%	4,116%	7,143%	94,28%

Tabela 357: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	31	0	19,02%
folhas	14	632	2	2,469%
céu	1	1	26	7,143%
falsos +	10,2%	4,819%	7,143%	94,16%

Tabela 358: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	14	633	1	2,315%
céu	0	0	28	0%
falsos +	9,79%	4,955%	6,667%	94,16%

Tabela 359: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	32	0	19,63%
folhas	10	638	0	1,543%
céu	0	0	28	0%
falsos +	7,092%	4,776%	0%	94,99%

Tabela 360: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	27	0	16,56%
folhas	13	634	1	2,16%
céu	0	0	28	0%
falsos +	8,725%	4,085%	3,448%	95,11%

Tabela 361: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	31	0	19,02%
folhas	8	639	1	1,389%
céu	0	0	28	0%
falsos +	5,714%	4,627%	3,448%	95,23%

Tabela 362: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	36	0	22,09%
folhas	12	636	0	1,852%
céu	0	0	28	0%
falsos +	8,633%	5,357%	0%	94,28%

Tabela 363: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	32	1	20,25%
folhas	10	637	1	1,698%
céu	0	0	28	0%
falsos +	7,143%	4,783%	6,667%	94,76%

Tabela 364: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	137	26	0	15,95%
folhas	19	629	0	2,932%
céu	0	0	28	0%
falsos +	12,18%	3,969%	0%	94,64%

Tabela 365: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	29	0	17,79%
folhas	13	635	0	2,006%
céu	0	0	28	0%
falsos +	8,844%	4,367%	0%	94,99%

Tabela 366: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	30	0	18,4%
folhas	15	633	0	2,315%
céu	0	0	28	0%
falsos +	10,14%	4,525%	0%	94,64%

Tabela 367: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	31	1	19,63%
folhas	12	636	0	1,852%
céu	0	0	28	0%
falsos +	8,392%	4,648%	3,448%	94,76%

Tabela 368: Matriz de confusão do classificador bayesiano, conjunto HSV – 100% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	31	1	19,63%
folhas	14	632	2	2,469%
céu	0	0	28	0%
falsos +	9,655%	4,676%	9,677%	94,28%

APÊNDICE E – Matrizes de confusão dos testes do classificador de Bayes ingênuo

E.1 Testes dos classificadores treinados com o conjunto RGB – 20%

Tabela 369: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	4	148	11	97,55%
folhas	0	647	1	0,1543%
céu	5	16	7	75%
falsos +	55,56%	20,22%	63,16%	78,43%

Tabela 370: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	48	100	15	70,55%
folhas	13	634	1	2,16%
céu	10	6	12	57,14%
falsos +	32,39%	14,32%	57,14%	82,72%

Tabela 371: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	47	101	15	71,17%
folhas	33	614	1	5,247%
céu	8	8	12	57,14%
falsos +	46,59%	15,08%	57,14%	80,21%

Tabela 372: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	71	79	13	56,44%
folhas	35	612	1	5,556%
céu	7	9	12	57,14%
falsos +	37,17%	12,57%	53,85%	82,84%

Tabela 373: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	81	67	15	50,31%
folhas	31	616	1	4,938%
céu	8	8	12	57,14%
falsos +	32,5%	10,85%	57,14%	84,51%

Tabela 374: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	93	58	12	42,94%
folhas	39	608	1	6,173%
céu	5	10	13	53,57%
falsos +	32,12%	10,06%	50%	85,1%

Tabela 375: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	93	57	13	42,94%
folhas	45	602	1	7,099%
céu	4	11	13	53,57%
falsos +	34,51%	10,15%	51,85%	84,39%

Tabela 376: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	103	49	11	36,81%
folhas	50	597	1	7,87%
céu	6	9	13	53,57%
falsos +	35,22%	8,855%	48%	84,98%

Tabela 377: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	104	48	11	36,2%
folhas	56	591	1	8,796%
céu	6	8	14	50%
falsos +	37,35%	8,655%	46,15%	84,51%

Tabela 378: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	109	44	10	33,13%
folhas	62	585	1	9,722%
céu	9	4	15	46,43%
falsos +	39,44%	7,583%	42,31%	84,51%

Tabela 379: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	114	43	6	30,06%
folhas	78	569	1	12,19%
céu	11	2	15	46,43%
falsos +	43,84%	7,329%	31,82%	83,19%

Tabela 380: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	116	39	8	28,83%
folhas	84	563	1	13,12%
céu	12	1	15	46,43%
falsos +	45,28%	6,633%	37,5%	82,72%

Tabela 381: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	117	39	7	28,22%
folhas	92	555	1	14,35%
céu	12	1	15	46,43%
falsos +	47,06%	6,723%	34,78%	81,88%

Tabela 382: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	36	8	26,99%
folhas	93	554	1	14,51%
céu	12	1	15	46,43%
falsos +	46,88%	6,261%	37,5%	82%

Tabela 383: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	35	1	22,09%
folhas	102	546	0	15,74%
céu	11	2	15	46,43%
falsos +	47,08%	6,346%	6,25%	82%

Tabela 384: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	34	1	21,47%
folhas	110	538	0	16,98%
céu	12	0	15	44,44%
falsos +	48,8%	5,944%	6,25%	81,26%

Tabela 385: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	34	1	21,47%
folhas	115	533	0	17,75%
céu	11	2	15	46,43%
falsos +	49,61%	6,327%	6,25%	80,57%

Tabela 386: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	129	519	0	19,91%
céu	10	0	17	37,04%
falsos +	51,87%	5,978%	5,556%	79,36%

Tabela 387: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 20% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	33	1	20,86%
folhas	134	514	0	20,68%
céu	10	0	17	37,04%
falsos +	52,75%	6,033%	5,556%	78,76%

E.2 Testes dos classificadores treinados com o conjunto RGB – 30%

Tabela 388: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	5	145	13	96,93%
folhas	1	646	1	0,3086%
céu	3	13	12	57,14%
falsos +	44,44%	19,65%	53,85%	79,02%

Tabela 389: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	7	140	16	95,71%
folhas	2	645	1	0,463%
céu	0	13	15	46,43%
falsos +	22,22%	19,17%	53,12%	79,5%

Tabela 390: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	28	119	16	82,82%
folhas	20	627	1	3,241%
céu	5	10	13	53,57%
falsos +	47,17%	17,06%	56,67%	79,62%

Tabela 391: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	46	101	16	71,78%
folhas	38	609	1	6,019%
céu	5	9	14	50%
falsos +	48,31%	15,3%	54,84%	79,74%

Tabela 392: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	62	88	13	61,96%
folhas	35	612	1	5,556%
céu	6	9	13	53,57%
falsos +	39,81%	13,68%	51,85%	81,88%

Tabela 393: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	108	45	10	33,74%
folhas	27	621	0	4,167%
céu	3	9	16	42,86%
falsos +	21,74%	8%	38,46%	88,8%

Tabela 394: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	40	8	29,45%
folhas	32	615	1	5,093%
céu	4	6	18	35,71%
falsos +	23,84%	6,959%	33,33%	89,15%

Tabela 395: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	111	44	8	31,9%
folhas	36	612	0	5,556%
céu	5	6	17	39,29%
falsos +	26,97%	7,553%	32%	88,2%

Tabela 396: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	41	7	29,45%
folhas	39	608	1	6,173%
céu	5	6	17	39,29%
falsos +	27,67%	7,176%	32%	88,2%

Tabela 397: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	116	40	7	28,83%
folhas	35	612	1	5,556%
céu	5	6	17	39,29%
falsos +	25,64%	6,991%	32%	88,8%

Tabela 398: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	118	42	3	27,61%
folhas	36	611	1	5,71%
céu	6	5	17	39,29%
falsos +	26,25%	7,143%	19,05%	88,92%

Tabela 399: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	42	2	26,99%
folhas	45	603	0	6,944%
céu	8	3	17	39,29%
falsos +	30,81%	6,944%	10,53%	88,08%

Tabela 400: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	117	41	5	28,22%
folhas	57	590	1	8,951%
céu	7	2	19	32,14%
falsos +	35,36%	6,793%	24%	86,53%

Tabela 401: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	37	1	23,31%
folhas	55	592	1	8,642%
céu	10	0	18	35,71%
falsos +	34,21%	5,882%	10%	87,6%

Tabela 402: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	36	1	22,7%
folhas	57	590	1	8,951%
céu	10	0	18	35,71%
falsos +	34,72%	5,751%	10%	87,49%

Tabela 403: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	38	1	23,93%
folhas	73	574	1	11,42%
céu	10	0	18	35,71%
falsos +	40,1%	6,209%	10%	85,34%

Tabela 404: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	30	1	19,02%
folhas	74	573	1	11,57%
céu	10	0	18	35,71%
falsos +	38,89%	4,975%	10%	86,17%

Tabela 405: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	27	1	17,18%
folhas	82	565	1	12,81%
céu	10	0	18	35,71%
falsos +	40,53%	4,561%	10%	85,58%

Tabela 406: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 30% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	29	1	18,4%
folhas	81	566	1	12,65%
céu	10	0	18	35,71%
falsos +	40,62%	4,874%	10%	85,46%

E.3 Testes dos classificadores treinados com o conjunto RGB – 50%

Tabela 407: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	5	143	15	96,93%
folhas	2	645	1	0,463%
céu	1	12	15	46,43%
falsos +	37,5%	19,38%	51,61%	79,26%

Tabela 408: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	23	128	12	85,89%
folhas	12	635	1	2,006%
céu	4	9	15	46,43%
falsos +	41,03%	17,75%	46,43%	80,21%

Tabela 409: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	66	86	11	59,51%
folhas	38	609	1	6,019%
céu	8	4	16	42,86%
falsos +	41,07%	12,88%	42,86%	82,36%

Tabela 410: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	88	64	11	46,01%
folhas	52	595	1	8,179%
céu	8	2	18	35,71%
falsos +	40,54%	9,985%	40%	83,55%

Tabela 411: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	97	57	9	40,49%
folhas	49	598	1	7,716%
céu	10	1	17	39,29%
falsos +	37,82%	8,841%	37,04%	84,86%

Tabela 412: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	108	53	2	33,74%
folhas	48	599	1	7,562%
céu	3	5	20	28,57%
falsos +	32,08%	8,828%	13,04%	86,65%

Tabela 413: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	106	55	2	34,97%
folhas	47	600	1	7,407%
céu	3	3	22	21,43%
falsos +	32,05%	8,815%	12%	86,77%

Tabela 414: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	42	1	26,38%
folhas	46	602	0	7,099%
céu	3	3	22	21,43%
falsos +	28,99%	6,955%	4,348%	88,68%

Tabela 415: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	42	1	26,38%
folhas	35	613	0	5,401%
céu	3	3	22	21,43%
falsos +	24,05%	6,839%	4,348%	89,99%

Tabela 416: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	47	1	29,45%
folhas	39	609	0	6,019%
céu	3	2	23	17,86%
falsos +	26,75%	7,447%	4,167%	89,03%

Tabela 417: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	40	1	25,15%
folhas	36	612	0	5,556%
céu	4	1	23	17,86%
falsos +	24,69%	6,279%	4,167%	90,23%

Tabela 418: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	121	39	3	25,77%
folhas	42	606	0	6,481%
céu	4	0	24	14,29%
falsos +	27,54%	6,047%	11,11%	89,51%

Tabela 419: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	34	4	23,31%
folhas	37	611	0	5,71%
céu	4	0	24	14,29%
falsos +	24,7%	5,271%	14,29%	90,58%

Tabela 420: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	34	4	23,31%
folhas	34	612	2	5,556%
céu	3	0	25	10,71%
falsos +	22,84%	5,263%	19,35%	90,82%

Tabela 421: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	39	4	26,38%
folhas	41	607	0	6,327%
céu	4	0	24	14,29%
falsos +	27,27%	6,037%	14,29%	89,51%

Tabela 422: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	35	4	23,93%
folhas	43	603	2	6,944%
céu	2	0	26	7,143%
falsos +	26,63%	5,486%	18,75%	89,75%

Tabela 423: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	32	3	21,47%
folhas	41	605	2	6,636%
céu	3	0	25	10,71%
falsos +	25,58%	5,024%	16,67%	90,35%

Tabela 424: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	28	4	19,63%
folhas	41	607	0	6,327%
céu	3	1	24	14,29%
falsos +	25,14%	4,56%	14,29%	90,82%

Tabela 425: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 50% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	29	4	20,25%
folhas	41	606	1	6,481%
céu	3	1	24	14,29%
falsos +	25,29%	4,717%	17,24%	90,58%

E.4 Testes dos classificadores treinados com o conjunto RGB – 70%

Tabela 426: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	34	117	12	79,14%
folhas	32	614	2	5,247%
céu	6	6	16	42,86%
falsos +	52,78%	16,69%	46,67%	79,14%

Tabela 427: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	43	110	10	73,62%
folhas	41	605	2	6,636%
céu	7	6	15	46,43%
falsos +	52,75%	16,09%	44,44%	79,02%

Tabela 428: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	71	82	10	56,44%
folhas	53	594	1	8,333%
céu	9	3	16	42,86%
falsos +	46,62%	12,52%	40,74%	81,17%

Tabela 429: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	84	77	2	48,47%
folhas	55	592	1	8,642%
céu	5	1	22	21,43%
falsos +	41,67%	11,64%	12%	83,19%

Tabela 430: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	100	62	1	38,65%
folhas	54	592	2	8,642%
céu	5	1	22	21,43%
falsos +	37,11%	9,618%	12%	85,1%

Tabela 431: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	106	56	1	34,97%
folhas	57	589	2	9,105%
céu	3	1	24	14,29%
falsos +	36,14%	8,824%	11,11%	85,7%

Tabela 432: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	106	55	2	34,97%
folhas	50	596	2	8,025%
céu	3	1	24	14,29%
falsos +	33,33%	8,589%	14,29%	86,53%

Tabela 433: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	42	1	26,38%
folhas	44	602	2	7,099%
céu	3	1	24	14,29%
falsos +	28,14%	6,667%	11,11%	88,92%

Tabela 434: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	43	1	26,99%
folhas	41	604	3	6,79%
céu	3	1	24	14,29%
falsos +	26,99%	6,79%	14,29%	89,03%

Tabela 435: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	114	48	1	30,06%
folhas	40	606	2	6,481%
céu	3	1	24	14,29%
falsos +	27,39%	7,481%	11,11%	88,68%

Tabela 436: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	40	1	25,15%
folhas	40	606	2	6,481%
céu	3	1	24	14,29%
falsos +	26,06%	6,337%	11,11%	89,63%

Tabela 437: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	37	1	23,31%
folhas	43	603	2	6,944%
céu	3	1	24	14,29%
falsos +	26,9%	5,928%	11,11%	89,63%

Tabela 438: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	36	2	23,31%
folhas	39	607	2	6,327%
céu	3	0	25	10,71%
falsos +	25,15%	5,599%	13,79%	90,23%

Tabela 439: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	121	40	2	25,77%
folhas	37	609	2	6,019%
céu	2	0	26	7,143%
falsos +	24,38%	6,163%	13,33%	90,11%

Tabela 440: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	35	2	22,7%
folhas	36	609	3	6,019%
céu	2	0	26	7,143%
falsos +	23,17%	5,435%	16,13%	90,7%

Tabela 441: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	28	3	19,02%
folhas	32	613	3	5,401%
céu	1	0	27	3,571%
falsos +	20%	4,368%	18,18%	92,01%

Tabela 442: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	30	2	19,63%
folhas	35	610	3	5,864%
céu	1	0	27	3,571%
falsos +	21,56%	4,688%	15,62%	91,54%

Tabela 443: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	30	2	19,63%
folhas	39	608	1	6,173%
céu	1	1	26	7,143%
falsos +	23,39%	4,851%	10,34%	91,18%

Tabela 444: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 70% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	25	2	16,56%
folhas	41	606	1	6,481%
céu	1	1	26	7,143%
falsos +	23,6%	4,114%	10,34%	91,54%

E.5 Testes dos classificadores treinados com o conjunto RGB – 100%

Tabela 445: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	29	123	11	82,21%
folhas	26	621	1	4,167%
céu	6	6	16	42,86%
falsos +	52,46%	17,2%	42,86%	79,38%

Tabela 446: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	45	109	9	72,39%
folhas	45	603	0	6,944%
céu	9	3	16	42,86%
falsos +	54,55%	15,66%	36%	79,14%

Tabela 447: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	53	108	2	67,48%
folhas	39	609	0	6,019%
céu	4	7	17	39,29%
falsos +	44,79%	15,88%	10,53%	80,93%

Tabela 448: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	62	97	4	61,96%
folhas	49	599	0	7,562%
céu	5	1	22	21,43%
falsos +	46,55%	14,06%	15,38%	81,41%

Tabela 449: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	95	64	4	41,72%
folhas	50	597	1	7,87%
céu	6	1	21	25%
falsos +	37,09%	9,819%	19,23%	84,98%

Tabela 450: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	102	56	5	37,42%
folhas	51	596	1	8,025%
céu	5	1	22	21,43%
falsos +	35,44%	8,729%	21,43%	85,82%

Tabela 451: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	100	58	5	38,65%
folhas	44	603	1	6,944%
céu	5	0	23	17,86%
falsos +	32,89%	8,775%	20,69%	86,53%

Tabela 452: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	38	5	26,38%
folhas	42	605	1	6,636%
céu	5	0	23	17,86%
falsos +	28,14%	5,91%	20,69%	89,15%

Tabela 453: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	42	6	29,45%
folhas	39	606	3	6,481%
céu	5	0	23	17,86%
falsos +	27,67%	6,481%	28,12%	88,68%

Tabela 454: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	115	42	6	29,45%
folhas	37	608	3	6,173%
céu	5	0	23	17,86%
falsos +	26,75%	6,462%	28,12%	88,92%

Tabela 455: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	121	36	6	25,77%
folhas	36	610	2	5,864%
céu	5	0	23	17,86%
falsos +	25,31%	5,573%	25,81%	89,87%

Tabela 456: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	36	4	24,54%
folhas	36	609	3	6,019%
céu	5	0	23	17,86%
falsos +	25%	5,581%	23,33%	89,99%

Tabela 457: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	120	37	6	26,38%
folhas	33	611	4	5,71%
céu	5	0	23	17,86%
falsos +	24,05%	5,71%	30,3%	89,87%

Tabela 458: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	121	36	6	25,77%
folhas	31	613	4	5,401%
céu	4	0	24	14,29%
falsos +	22,44%	5,547%	29,41%	90,35%

Tabela 459: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	121	36	6	25,77%
folhas	33	613	2	5,401%
céu	4	0	24	14,29%
falsos +	23,42%	5,547%	25%	90,35%

Tabela 460: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	32	6	23,31%
folhas	33	612	3	5,556%
céu	4	0	24	14,29%
falsos +	22,84%	4,969%	27,27%	90,7%

Tabela 461: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	32	5	22,7%
folhas	30	615	3	5,093%
céu	2	0	26	7,143%
falsos +	20,25%	4,946%	23,53%	91,42%

Tabela 462: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	31	5	22,09%
folhas	31	614	3	5,247%
céu	2	0	26	7,143%
falsos +	20,62%	4,806%	23,53%	91,42%

Tabela 463: Matriz de confusão do classificador de Bayes ingênuo, conjunto RGB – 100% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	26	4	18,4%
folhas	31	614	3	5,247%
céu	2	0	26	7,143%
falsos +	19,88%	4,062%	21,21%	92,13%

E.6 Testes dos classificadores treinados com o conjunto HSV – 20%

Tabela 464: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	116	47	0	28,83%
folhas	19	629	0	2,932%
céu	12	11	5	82,14%
falsos +	21,09%	8,443%	0%	89,39%

Tabela 465: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	110	52	1	32,52%
folhas	14	634	0	2,16%
céu	10	12	6	78,57%
falsos +	17,91%	9,169%	14,29%	89,39%

Tabela 466: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	118	42	3	27,61%
folhas	11	637	0	1,698%
céu	9	10	9	67,86%
falsos +	14,49%	7,547%	25%	91,06%

Tabela 467: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	113	43	7	30,67%
folhas	14	633	1	2,315%
céu	6	8	14	50%
falsos +	15,04%	7,456%	36,36%	90,58%

Tabela 468: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	112	43	8	31,29%
folhas	14	633	1	2,315%
céu	6	8	14	50%
falsos +	15,15%	7,456%	39,13%	90,46%

Tabela 469: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	114	44	5	30,06%
folhas	15	633	0	2,315%
céu	6	9	13	53,57%
falsos +	15,56%	7,726%	27,78%	90,58%

Tabela 470: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	116	41	6	28,83%
folhas	16	631	1	2,623%
céu	6	9	13	53,57%
falsos +	15,94%	7,342%	35%	90,58%

Tabela 471: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	39	2	25,15%
folhas	23	625	0	3,549%
céu	8	9	11	60,71%
falsos +	20,26%	7,132%	15,38%	90,35%

Tabela 472: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	39	2	25,15%
folhas	24	624	0	3,704%
céu	8	9	11	60,71%
falsos +	20,78%	7,143%	15,38%	90,23%

Tabela 473: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	39	2	25,15%
folhas	24	624	0	3,704%
céu	7	10	11	60,71%
falsos +	20,26%	7,281%	15,38%	90,23%

Tabela 474: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	41	3	26,99%
folhas	21	627	0	3,241%
céu	5	11	12	57,14%
falsos +	17,93%	7,658%	20%	90,35%

Tabela 475: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	35	2	22,7%
folhas	19	629	0	2,932%
céu	8	9	11	60,71%
falsos +	17,65%	6,538%	15,38%	91,3%

Tabela 476: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	36	2	23,31%
folhas	22	626	0	3,395%
céu	8	9	11	60,71%
falsos +	19,35%	6,706%	15,38%	90,82%

Tabela 477: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	29	2	19,02%
folhas	26	622	0	4,012%
céu	10	7	11	60,71%
falsos +	21,43%	5,471%	15,38%	91,18%

Tabela 478: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	28	2	18,4%
folhas	33	615	0	5,093%
céu	9	7	12	57,14%
falsos +	24%	5,385%	14,29%	90,58%

Tabela 479: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	27	2	17,79%
folhas	34	614	0	5,247%
céu	11	7	10	64,29%
falsos +	25,14%	5,247%	16,67%	90,35%

Tabela 480: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	28	2	18,4%
folhas	33	615	0	5,093%
céu	9	7	12	57,14%
falsos +	24%	5,385%	14,29%	90,58%

Tabela 481: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	137	24	2	15,95%
folhas	47	601	0	7,253%
céu	9	7	12	57,14%
falsos +	29,02%	4,905%	14,29%	89,39%

Tabela 482: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 20% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	139	22	2	14,72%
folhas	58	590	0	8,951%
céu	9	7	12	57,14%
falsos +	32,52%	4,685%	14,29%	88,32%

E.7 Testes dos classificadores treinados com o conjunto HSV – 30%

Tabela 483: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	41	0	25,15%
folhas	15	633	0	2,315%
céu	10	11	7	75%
falsos +	17,01%	7,591%	0%	90,82%

Tabela 484: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	121	35	7	25,77%
folhas	21	627	0	3,241%
céu	4	7	17	39,29%
falsos +	17,12%	6,278%	29,17%	91,18%

Tabela 485: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	32	7	23,93%
folhas	23	625	0	3,549%
céu	3	8	17	39,29%
falsos +	17,33%	6,015%	29,17%	91,3%

Tabela 486: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	31	6	22,7%
folhas	24	623	1	3,858%
céu	6	9	13	53,57%
falsos +	19,23%	6,033%	35%	90,82%

Tabela 487: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	29	5	20,86%
folhas	27	621	0	4,167%
céu	4	10	14	50%
falsos +	19,38%	5,909%	26,32%	91,06%

Tabela 488: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	29	4	20,25%
folhas	31	617	0	4,784%
céu	6	8	14	50%
falsos +	22,16%	5,657%	22,22%	90,7%

Tabela 489: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	29	618	1	4,63%
céu	5	9	14	50%
falsos +	20,24%	5,649%	12,5%	91,3%

Tabela 490: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	28	2	18,4%
folhas	28	620	0	4,321%
céu	5	9	14	50%
falsos +	19,88%	5,632%	12,5%	91,42%

Tabela 491: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	28	2	18,4%
folhas	27	620	1	4,321%
céu	5	9	14	50%
falsos +	19,39%	5,632%	17,65%	91,42%

Tabela 492: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	26	2	17,18%
folhas	31	617	0	4,784%
céu	4	10	14	50%
falsos +	20,59%	5,513%	12,5%	91,3%

Tabela 493: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	26	2	17,18%
folhas	29	619	0	4,475%
céu	4	10	14	50%
falsos +	19,64%	5,496%	12,5%	91,54%

Tabela 494: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	25	2	16,56%
folhas	34	614	0	5,247%
céu	4	10	14	50%
falsos +	21,84%	5,393%	12,5%	91,06%

Tabela 495: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	25	2	16,56%
folhas	35	613	0	5,401%
céu	4	10	14	50%
falsos +	22,29%	5,401%	12,5%	90,94%

Tabela 496: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	137	25	1	15,95%
folhas	34	614	0	5,247%
céu	4	10	14	50%
falsos +	21,71%	5,393%	6,667%	91,18%

Tabela 497: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	139	22	2	14,72%
folhas	36	612	0	5,556%
céu	3	12	13	53,57%
falsos +	21,91%	5,263%	13,33%	91,06%

Tabela 498: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	134	28	1	17,79%
folhas	41	607	0	6,327%
céu	4	10	14	50%
falsos +	25,14%	5,891%	6,667%	89,99%

Tabela 499: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	135	27	1	17,18%
folhas	41	607	0	6,327%
céu	4	10	14	50%
falsos +	25%	5,745%	6,667%	90,11%

Tabela 500: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	136	26	1	16,56%
folhas	47	601	0	7,253%
céu	4	10	14	50%
falsos +	27,27%	5,651%	6,667%	89,51%

Tabela 501: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 30% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	138	24	1	15,34%
folhas	48	600	0	7,407%
céu	2	12	14	50%
falsos +	26,6%	5,66%	6,667%	89,63%

E.8 Testes dos classificadores treinados com o conjunto HSV – 50%

Tabela 502: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	101	52	10	38,04%
folhas	36	612	0	5,556%
céu	3	11	14	50%
falsos +	27,86%	9,333%	41,67%	86,65%

Tabela 503: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	119	37	7	26,99%
folhas	25	623	0	3,858%
céu	0	10	18	35,71%
falsos +	17,36%	7,015%	28%	90,58%

Tabela 504: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	35	4	23,93%
folhas	28	620	0	4,321%
céu	2	8	18	35,71%
falsos +	19,48%	6,486%	18,18%	90,82%

Tabela 505: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	36	5	25,15%
folhas	28	620	0	4,321%
céu	2	7	19	32,14%
falsos +	19,74%	6,486%	20,83%	90,7%

Tabela 506: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	34	4	23,31%
folhas	38	610	0	5,864%
céu	2	8	18	35,71%
falsos +	24,24%	6,442%	18,18%	89,75%

Tabela 507: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	38	3	25,15%
folhas	33	615	0	5,093%
céu	4	6	18	35,71%
falsos +	23,27%	6,677%	14,29%	89,99%

Tabela 508: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	37	3	24,54%
folhas	31	617	0	4,784%
céu	5	6	17	39,29%
falsos +	22,64%	6,515%	15%	90,23%

Tabela 509: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	35	4	23,93%
folhas	30	618	0	4,63%
céu	5	6	17	39,29%
falsos +	22,01%	6,222%	19,05%	90,46%

Tabela 510: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	36	3	23,93%
folhas	27	621	0	4,167%
céu	5	5	18	35,71%
falsos +	20,51%	6,193%	14,29%	90,94%

Tabela 511: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	35	3	23,31%
folhas	28	620	0	4,321%
céu	4	6	18	35,71%
falsos +	20,38%	6,203%	14,29%	90,94%

Tabela 512: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	36	3	23,93%
folhas	28	620	0	4,321%
céu	4	6	18	35,71%
falsos +	20,51%	6,344%	14,29%	90,82%

Tabela 513: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	124	36	3	23,93%
folhas	30	618	0	4,63%
céu	4	4	20	28,57%
falsos +	21,52%	6,079%	13,04%	90,82%

Tabela 514: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	37	3	24,54%
folhas	30	618	0	4,63%
céu	3	5	20	28,57%
falsos +	21,15%	6,364%	13,04%	90,7%

Tabela 515: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	34	3	22,7%
folhas	31	617	0	4,784%
céu	3	5	20	28,57%
falsos +	21,25%	5,945%	13,04%	90,94%

Tabela 516: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	34	3	22,7%
folhas	32	616	0	4,938%
céu	2	5	21	25%
falsos +	21,25%	5,954%	12,5%	90,94%

Tabela 517: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	34	3	22,7%
folhas	33	615	0	5,093%
céu	2	4	22	21,43%
falsos +	21,74%	5,819%	12%	90,94%

Tabela 518: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	34	3	22,7%
folhas	34	614	0	5,247%
céu	3	4	21	25%
falsos +	22,7%	5,828%	12,5%	90,7%

Tabela 519: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	32	2	20,86%
folhas	40	608	0	6,173%
céu	2	4	22	21,43%
falsos +	24,56%	5,59%	8,333%	90,46%

Tabela 520: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 50% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	31	2	20,25%
folhas	39	609	0	6,019%
céu	2	4	22	21,43%
falsos +	23,98%	5,435%	8,333%	90,7%

E.9 Testes dos classificadores treinados com o conjunto HSV – 70%

Tabela 521: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	111	43	9	31,9%
folhas	58	589	1	9,105%
céu	0	12	16	42,86%
falsos +	34,32%	8,54%	38,46%	85,34%

Tabela 522: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	32	3	21,47%
folhas	37	611	0	5,71%
céu	2	11	15	46,43%
falsos +	23,35%	6,575%	16,67%	89,87%

Tabela 523: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	30	4	20,86%
folhas	37	611	0	5,71%
céu	2	9	17	39,29%
falsos +	23,21%	6%	19,05%	90,23%

Tabela 524: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	122	39	2	25,15%
folhas	29	618	1	4,63%
céu	2	8	18	35,71%
falsos +	20,26%	7,068%	14,29%	90,35%

Tabela 525: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	33	4	22,7%
folhas	38	610	0	5,864%
céu	1	9	18	35,71%
falsos +	23,64%	6,442%	18,18%	89,87%

Tabela 526: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	34	3	22,7%
folhas	37	610	1	5,864%
céu	2	8	18	35,71%
falsos +	23,64%	6,442%	18,18%	89,87%

Tabela 527: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	34	2	22,09%
folhas	35	613	0	5,401%
céu	2	4	22	21,43%
falsos +	22,56%	5,837%	8,333%	90,82%

Tabela 528: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	33	2	21,47%
folhas	29	619	0	4,475%
céu	2	4	22	21,43%
falsos +	19,5%	5,64%	8,333%	91,66%

Tabela 529: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	34	1	21,47%
folhas	27	621	0	4,167%
céu	1	4	23	17,86%
falsos +	17,95%	5,766%	4,167%	92,01%

Tabela 530: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	35	0	21,47%
folhas	29	619	0	4,475%
céu	1	3	24	14,29%
falsos +	18,99%	5,784%	0%	91,9%

Tabela 531: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	36	0	22,09%
folhas	28	620	0	4,321%
céu	1	3	24	14,29%
falsos +	18,59%	5,918%	0%	91,9%

Tabela 532: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	37	0	22,7%
folhas	33	615	0	5,093%
céu	1	3	24	14,29%
falsos +	21,25%	6,107%	0%	91,18%

Tabela 533: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	35	0	21,47%
folhas	32	616	0	4,938%
céu	1	3	24	14,29%
falsos +	20,5%	5,81%	0%	91,54%

Tabela 534: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	36	0	22,09%
folhas	33	615	0	5,093%
céu	1	3	24	14,29%
falsos +	21,12%	5,963%	0%	91,3%

Tabela 535: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	36	0	22,09%
folhas	33	615	0	5,093%
céu	1	3	24	14,29%
falsos +	21,12%	5,963%	0%	91,3%

Tabela 536: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	33	0	20,25%
folhas	34	614	0	5,247%
céu	1	3	24	14,29%
falsos +	21,21%	5,538%	0%	91,54%

Tabela 537: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	34	0	20,86%
folhas	36	612	0	5,556%
céu	1	3	24	14,29%
falsos +	22,29%	5,701%	0%	91,18%

Tabela 538: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	130	32	1	20,25%
folhas	38	610	0	5,864%
céu	1	3	24	14,29%
falsos +	23,08%	5,426%	4%	91,06%

Tabela 539: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 70% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	131	31	1	19,63%
folhas	38	610	0	5,864%
céu	1	3	24	14,29%
falsos +	22,94%	5,28%	4%	91,18%

E.10 Testes dos classificadores treinados com o conjunto HSV – 100%

Tabela 540: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 2 dimensões.

	frutos	folhas	céu	falsos -
frutos	104	51	8	36,2%
folhas	39	608	1	6,173%
céu	1	12	15	46,43%
falsos +	27,78%	9,389%	37,5%	86,65%

Tabela 541: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 3 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	34	3	22,7%
folhas	29	619	0	4,475%
céu	2	8	18	35,71%
falsos +	19,75%	6,354%	14,29%	90,94%

Tabela 542: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 4 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	35	2	22,7%
folhas	24	624	0	3,704%
céu	2	6	20	28,57%
falsos +	17,11%	6,165%	9,091%	91,78%

Tabela 543: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 5 dimensões.

	frutos	folhas	céu	falsos -
frutos	123	38	2	24,54%
folhas	29	618	1	4,63%
céu	2	5	21	25%
falsos +	20,13%	6,505%	12,5%	90,82%

Tabela 544: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 6 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	36	2	23,31%
folhas	37	611	0	5,71%
céu	1	7	20	28,57%
falsos +	23,31%	6,575%	9,091%	90,11%

Tabela 545: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 7 dimensões.

	frutos	folhas	céu	falsos -
frutos	128	33	2	21,47%
folhas	32	615	1	5,093%
céu	2	5	21	25%
falsos +	20,99%	5,819%	12,5%	91,06%

Tabela 546: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 8 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	38	0	23,31%
folhas	37	611	0	5,71%
céu	2	5	21	25%
falsos +	23,78%	6,575%	0%	90,23%

Tabela 547: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 9 dimensões.

	frutos	folhas	céu	falsos -
frutos	127	36	0	22,09%
folhas	36	610	2	5,864%
céu	1	3	24	14,29%
falsos +	22,56%	6,009%	7,692%	90,7%

Tabela 548: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 10 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	37	0	22,7%
folhas	33	614	1	5,247%
céu	1	5	22	21,43%
falsos +	21,25%	6,402%	4,348%	90,82%

Tabela 549: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 11 dimensões.

	frutos	folhas	céu	falsos -
frutos	125	38	0	23,31%
folhas	35	612	1	5,556%
céu	1	5	22	21,43%
falsos +	22,36%	6,565%	4,348%	90,46%

Tabela 550: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 12 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	37	0	22,7%
folhas	34	613	1	5,401%
céu	0	5	23	17,86%
falsos +	21,25%	6,412%	4,167%	90,82%

Tabela 551: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 13 dimensões.

	frutos	folhas	céu	falsos -
frutos	126	37	0	22,7%
folhas	36	610	2	5,864%
céu	1	5	22	21,43%
falsos +	22,7%	6,442%	8,333%	90,35%

Tabela 552: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 14 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	34	0	20,86%
folhas	35	613	0	5,401%
céu	1	5	22	21,43%
falsos +	21,82%	5,982%	0%	91,06%

Tabela 553: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 15 dimensões.

	frutos	folhas	céu	falsos -
frutos	129	34	0	20,86%
folhas	33	615	0	5,093%
céu	1	4	23	17,86%
falsos +	20,86%	5,819%	0%	91,42%

Tabela 554: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 16 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	31	0	19,02%
folhas	36	611	1	5,71%
céu	0	3	25	10,71%
falsos +	21,43%	5,271%	3,846%	91,54%

Tabela 555: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 17 dimensões.

	frutos	folhas	céu	falsos -
frutos	133	30	0	18,4%
folhas	36	611	1	5,71%
céu	0	4	24	14,29%
falsos +	21,3%	5,271%	4%	91,54%

Tabela 556: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 18 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	30	1	19,02%
folhas	40	606	2	6,481%
céu	0	2	26	7,143%
falsos +	23,26%	5,016%	10,34%	91,06%

Tabela 557: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 19 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	30	1	19,02%
folhas	40	606	2	6,481%
céu	0	1	27	3,571%
falsos +	23,26%	4,867%	10%	91,18%

Tabela 558: Matriz de confusão do classificador de Bayes ingênuo, conjunto HSV – 100% com 20 dimensões.

	frutos	folhas	céu	falsos -
frutos	132	30	1	19,02%
folhas	42	605	1	6,636%
céu	0	1	27	3,571%
falsos +	24,14%	4,874%	6,897%	91,06%

APÊNDICE F – Mapas de classes

F.1 Imagem 2

Figura 71: Imagem 2.

Figura 72: Mapa de classe 2 – Bayes – HSV

Figura 73: Mapa de classe 2 – Bayes – RGB

Figura 74: Mapa de classe 2 – Bayes ingênuo – HSV

Figura 75: Mapa de classe 2 – Bayes ingênuo – RGB

Figura 76: Mapa de classe 2 – RNA – HSV

Figura 77: Mapa de classe 2 – RNA – RGB

F.2 Imagem 3

Figura 78: Imagem 3.

Figura 79: Mapa de classe 3 – Bayes – HSV

Figura 80: Mapa de classe 3 – Bayes – RGB

Figura 81: Mapa de classe 3 – Bayes ingênuo – HSV

Figura 82: Mapa de classe 3 – Bayes ingênuo – RGB

Figura 83: Mapa de classe 3 – RNA – HSV

Figura 84: Mapa de classe 3 – RNA – RGB

F.3 Imagem 4

Figura 85: Imagem 4.

Figura 86: Mapa de classe 4 – Bayes – HSV

Figura 87: Mapa de classe 4 – Bayes – RGB

Figura 88: Mapa de classe 4 – Bayes ingênuo – HSV

Figura 89: Mapa de classe 4 – Bayes ingênuo – RGB

Figura 90: Mapa de classe 4 – RNA – HSV

Figura 91: Mapa de classe 4 – RNA – RGB

F.4 Imagem 5

Figura 92: Imagem 5.

Figura 93: Mapa de classe 5 – Bayes – HSV

Figura 94: Mapa de classe 5 – Bayes – RGB

Figura 95: Mapa de classe 5 – Bayes ingênuo – HSV

Figura 96: Mapa de classe 5 – Bayes ingênuo – RGB

Figura 97: Mapa de classe 5 – RNA – HSV

Figura 98: Mapa de classe 5 – RNA – RGB

F.5 Imagem 6

Figura 99: Imagem 6.

Figura 100: Mapa de classe 6 – Bayes – HSV

Figura 101: Mapa de classe 6 – Bayes – RGB

Figura 102: Mapa de classe 6 – Bayes ingênuo – HSV

Figura 103: Mapa de classe 6 – Bayes ingênuo – RGB

Figura 104: Mapa de classe 6 – RNA – HSV

Figura 105: Mapa de classe 6 – RNA – RGB

F.6 Imagem 7

Figura 106: Imagem 7.

Figura 107: Mapa de classe 7 – Bayes – HSV

Figura 108: Mapa de classe 7 – Bayes – RGB

Figura 109: Mapa de classe 7 – Bayes ingênuo – HSV

Figura 110: Mapa de classe 7 – Bayes ingênuo – RGB

Figura 111: Mapa de classe 7 – RNA – HSV

Figura 112: Mapa de classe 7 – RNA – RGB

F.7 Imagem 8

Figura 113: Imagem 8.

Figura 114: Mapa de classe 8 – Bayes – HSV

Figura 115: Mapa de classe 8 – Bayes – RGB

Figura 116: Mapa de classe 8 – Bayes ingênuo – HSV

Figura 117: Mapa de classe 8 – Bayes ingênuo – RGB

Figura 118: Mapa de classe 8 – RNA – HSV

Figura 119: Mapa de classe 8 – RNA – RGB

F.8 Imagem 9

Figura 120: Imagem 9.

Figura 121: Mapa de classe 9 – Bayes – HSV

Figura 122: Mapa de classe 9 – Bayes – RGB

Figura 123: Mapa de classe 9 – Bayes ingênuo – HSV

Figura 124: Mapa de classe 9 – Bayes ingênuo – RGB

Figura 125: Mapa de classe 9 – RNA – HSV

Figura 126: Mapa de classe 9 – RNA – RGB

F.9 Imagem 10

Figura 127: Imagem 10.

Figura 128: Mapa de classe 10 – Bayes – HSV

Figura 129: Mapa de classe 10 – Bayes – RGB

Figura 130: Mapa de classe 10 – Bayes ingênuo – HSV

Figura 131: Mapa de classe 10 – Bayes ingênuo – RGB

Figura 132: Mapa de classe 10 – RNA – HSV

Figura 133: Mapa de classe 10 – RNA – RGB

F.10 Imagem 11

Figura 134: Imagem 11.

Figura 135: Mapa de classe 11 – Bayes – HSV

Figura 136: Mapa de classe 11 – Bayes – RGB

Figura 137: Mapa de classe 11 – Bayes ingênuo – HSV

Figura 138: Mapa de classe 11 – Bayes ingênuo – RGB

Figura 139: Mapa de classe 11 – RNA – HSV

Figura 140: Mapa de classe 11 – RNA – RGB

F.11 Imagem 12

Figura 141: Imagem 12.

Figura 142: Mapa de classe 12 – Bayes – HSV

Figura 143: Mapa de classe 12 – Bayes – RGB

Figura 144: Mapa de classe 12 – Bayes ingênuo – HSV

Figura 145: Mapa de classe 12 – Bayes ingênuo – RGB

Figura 146: Mapa de classe 12 – RNA – HSV

Figura 147: Mapa de classe 12 – RNA – RGB

F.12 Imagem 13

Figura 148: Imagem 13.

Figura 149: Mapa de classe 13 – Bayes – HSV

Figura 150: Mapa de classe 13 – Bayes – RGB

Figura 151: Mapa de classe 13 – Bayes in-gênuo – HSV

Figura 152: Mapa de classe 13 – Bayes in-gênuo – RGB

Figura 153: Mapa de classe 13 – RNA – HSV

Figura 154: Mapa de classe 13 – RNA – RGB

F.13 Imagem 14

Figura 155: Imagem 14.

Figura 156: Mapa de classe 14 – Bayes – HSV

Figura 157: Mapa de classe 14 – Bayes – RGB

Figura 158: Mapa de classe 14 – Bayes ingênuo – HSV

Figura 159: Mapa de classe 14 – Bayes ingênuo – RGB

Figura 160: Mapa de classe 14 – RNA – HSV

Figura 161: Mapa de classe 14 – RNA – RGB

F.14 Imagem 15

Figura 162: Imagem 15.

Figura 163: Mapa de classe 15 – Bayes – HSV

Figura 164: Mapa de classe 15 – Bayes – RGB

Figura 165: Mapa de classe 15 – Bayes ingênuo – HSV

Figura 166: Mapa de classe 15 – Bayes ingênuo – RGB

Figura 167: Mapa de classe 15 – RNA – HSV

Figura 168: Mapa de classe 15 – RNA – RGB

F.15 Imagem 16

Figura 169: Imagem 16.

Figura 170: Mapa de classe 16 – Bayes – HSV

Figura 171: Mapa de classe 16 – Bayes – RGB

Figura 172: Mapa de classe 16 – Bayes ingênuo – HSV

Figura 173: Mapa de classe 16 – Bayes ingênuo – RGB

Figura 174: Mapa de classe 16 – RNA – HSV

Figura 175: Mapa de classe 16 – RNA – RGB

F.16 Imagem 17

Figura 176: Imagem 17.

Figura 177: Mapa de classe 17 – Bayes – HSV

Figura 178: Mapa de classe 17 – Bayes – RGB

Figura 179: Mapa de classe 17 – Bayes ingênuo – HSV

Figura 180: Mapa de classe 17 – Bayes ingênuo – RGB

Figura 181: Mapa de classe 17 – RNA – HSV

Figura 182: Mapa de classe 17 – RNA – RGB

F.17 Imagem 18

Figura 183: Imagem 18.

Figura 184: Mapa de classe 18 – Bayes – HSV

Figura 185: Mapa de classe 18 – Bayes – RGB

Figura 186: Mapa de classe 18 – Bayes ingênuo – HSV

Figura 187: Mapa de classe 18 – Bayes ingênuo – RGB

Figura 188: Mapa de classe 18 – RNA – HSV

Figura 189: Mapa de classe 18 – RNA – RGB

F.18 Imagem 19

Figura 190: Imagem 19.

Figura 191: Mapa de classe 19 – Bayes – HSV

Figura 192: Mapa de classe 19 – Bayes – RGB

Figura 193: Mapa de classe 19 – Bayes ingênuo – HSV

Figura 194: Mapa de classe 19 – Bayes ingênuo – RGB

Figura 195: Mapa de classe 19 – RNA – HSV

Figura 196: Mapa de classe 19 – RNA – RGB

F.19 Imagem 20

Figura 197: Imagem 20.

Figura 198: Mapa de classe 20 – Bayes – HSV

Figura 199: Mapa de classe 20 – Bayes – RGB

Figura 200: Mapa de classe 20 – Bayes ingênuo – HSV

Figura 201: Mapa de classe 20 – Bayes ingênuo – RGB

Figura 202: Mapa de classe 20 – RNA – HSV

Figura 203: Mapa de classe 20 – RNA – RGB

Referências

- ALEIXOS, N. et al. (2002). Multispectral inspection of citrus in real-time using machine vision and digital signal processors. *Computers and Eletronics in Agriculture*, v. 33, n. 2, p. 121–137.
- ANNAMALAI, P.; LEE, W. S.; BURKS, T. F. (2004). Color vision system for estimating citrus yield in real-time. In: ASAE/CSAE ANNUAL INTERNATIONAL MEETING, 2004, Ottawa, Ontário, Canadá. *Proceedings...* [S.l.]: ASABE.
- ASTOLA, J.; HAAVISTO, P.; NEUVO, Y. (1990). Vector median filters. *Proceedings of IEEE*, v. 78, n. 4, p. 678–689. ISSN 0018-9219.
- BUENO, J. M. (2001). *Suporte à recuperação de imagens médicas baseada em conteúdo através de histogramas métricos*. 162 f. Tese (Doutorado em Ciências da Computação e Matemática Computacional) — Universidade de São Paulo, Instituto de Ciências Matemáticas e de Computação, São Carlos, São Paulo, Brasil, 2001.
- BULANON, D. M. (2001). Optimal thresholding for the automatic recognition of apple fruits. In: ASAE - THE SOCIETY FOR ENGINEERING IN AGRICULTURAL, FOOD, AND BIOLOGICAL SYSTEMS, 2001, Sacramento, California, EUA. *Proceedings...* [S.l.]: ASAE.
- BULANON, D. M. et al. (2004). Determining the 3-d location of the apple fruit during harvest. In: AUTOMATION TECHNOLOGY FOR OFF-ROAD EQUIPMENT, 2004, Kyoto, Japão. *Proceedings...* [S.l.]: ASAE.
- CARNEIRO, G. et al. (2007). Supervised learning of semantic classes for image annotation and retrieval. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 29, n. 3, p. 394–410. ISSN 0162-8828.
- CASTANÓN, C. A. B.; TRAINA, A. J. M. (2003). Caracterização de imagens através de análise multiresolução por wavelets para sistemas cbir. In: XXIX CONFERÊNCIA LATINOAMERICANA DE INFORMÁTICA, 2003. *Anais...* [S.l.].
- CHEIKH, F. et al. (1996). Impulse noise removal in highly corrupted color images. In: INTERNATIONAL CONFERENCE ON IMAGE PROCESSING, 1996, Lausanne, Suíça. *Proceedings of...* [S.l.]: IEEE, v. 1, p. 997–1000. ISBN 0-7803-3259-8.
- CHEN, J. et al. (2005). Adaptive perceptual color-texture image segmentation. *IEEE Transactions on Image Processing*, v. 14, n. 10, p. 1524–1536, out. ISSN 1057-7149.
- CHEN, K.; CHEN, S. (2002). Color texture segmentation using feature distributions. *Pattern Recognition Letters*, v. 23, n. 7, p. 755–771, mai.
- CHENG, H. D. et al. (2001). Color image segmentation: advances and prospects. *Pattern Recognition*, v. 34, p. 2259–2281.

CHENG, S. C. (2003). Region-growing approach to colour segmentation using 3-d clustering and relaxation labelling. *IEE Proceedings - Vision, Image, and Signal Processing*, v. 150, n. 4, p. 270–276.

COMANICIU, D.; MEER, P. (1997). Robust analysis of feature spaces: color image segmentation. In: IEEE COMPUTER SOCIETY, 1997. *Conference on Computer Vision and Pattern Recognition*. [S.l.].

COSTA, L. da F.; CESAR JÚNIOR, R. M. (2001). *Shape analysis and classification - Theory and Practice*. 1. ed. Boca Raton, Florida, EUA: CRC Press LLC. ISBN 0-8493-3493-4.

CRUVINEL, P. E.; MINATEL, E. R. (2002). Image processing in automated pattern classification of oranges. In: WORD CONGRESS OF COMPUTERS IN AGRICULTURE AND NATURAL RESOURCES, 2002, Foz do Iguaçu, Brasil. *Proceedings...* [S.l.]: ASAE, p. 56–61.

DAINESE, R. C. et al. (2004). Avaliação da incidência de plantas invasoras por meio de segmentação de imagens e redes neurais. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO, 2004. *Anais...* Piracicaba, São Paulo, Brasil: USP/Esalq.

DENG, Y. et al. (1999). Peer group filtering and perceptual color image quantization. In: INTERNATIONAL SYMPOSIUM ON CIRCUITS AND SYSTEMS, 1999. *Proceedings of...* [S.l.]: IEEE, v. 4, p. 21–25.

DENG, Y.; MANJUNATH, B. S.; SHIN, H. (1999). Color image segmentation. In: CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 1999, Fort Collins, CO, EUA. *Proceedings...* [S.l.]: IEEE Computer Society, v. 2, p. 446–451. ISBN 0-7695-0149-4.

DUDA, R. O.; HART, P. E. (1973). *Pattern classification and scene analysis*. 1. ed. New York, EUA: John Wiley & Sons, Inc. ISBN 0-471-22361-1.

EATON, J. W. et al., (2006). *Octave*. Disponível em: <http://www.octave.org>. Acesso: 12 fev. 2006.

EEGMONT-PETERSEN, M.; RIDDER, D.; HANDELS, H. (2002). Image processing with neural networks - a review. *Pattern Recognition*, v. 35, n. 10, p. 2279–2301, out.

FAIRHURST, M. C. (1988). *Computer vision for robotic systems - an introduction*. 1. ed. Reino Unido: Prentice Hall International Ltd. ISBN 0-13-166927-3.

FIGUEIREDO, M. A. T.; JAIN, A. K. (2002). Unsupervised learning of finite mixture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 24, n. 3, p. 381–396. ISSN 0162-8828.

GAY, P.; BERRUTO, R.; PICCAROLO, P. (2002). Fruit color assessment for quality grading purposes. In: ASAE ANNUAL INTERNATIONAL MEETING/CIGR XVTH WORLD CONGRESS, 2002, Chicago, Illinois, EUA. *Proceedings...* [S.l.]: ASAE.

GONZALEZ, R. C.; WINTZ, P. (1987). *Digital image processing*. 2. ed. Nova Iorque, EUA: Assison-Wesley Publishing Company.

- GONZALEZ, R. C.; WOODS, R. E. (2002). *Digital image processing*. 2. ed. New Jersey, EUA: Prentice-Hall Inc. ISBN 0-201-18075-8.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. (2003). *The elements of statistical learning*. 1. ed. New York, EUA: Springer. ISBN 0-387-95284-5.
- HAYKIN, S. (1999). *Neural networks: a comprehensive foudation*. 2. ed. New Jersey, EUA: Pretince-Hall. ISBN 0-13-273350-1.
- HILL, P. R. (2002). *Wavelet based texture analysis and segmentation for image retrieval and fusion*. Tese (Doutorado) — University of Bristol, 2002.
- IGEL, C.; HÜSKEN, M. (2000). Improving the Rprop learning algorithm. In: *Proceedings of the Second International ICSC Symposium on Neural Computation (NC 2000)*. [S.l.]: ICSC Academic Press, p. 115–121.
- IGEL, C.; HÜSKEN, M. (2003). Empirical evaluation of the improved Rprop learning algorithm. *Neurocomputing*, v. 50(C), p. 105–123.
- JAFARI, A. et al. (2004). Color feature extraction by means discriminant analysis for weed segmentation. In: ASAE ANNUAL INTERNATIONAL MEETING, 2004, Ottawa, Ontário, Canadá. *Proceedings...* [S.l.]: ASABE.
- JIMÉNEZ, A. R. et al. (1999). Automatic fruit recognition: a survey and new results using range/attenuation images. *Pattern Recognition*, v. 32, n. 10, p. 1719–1736.
- JING, F. et al. (2003). Unsupervised image segmentation using local homogeneity analysis. In: INTERNATIONAL SYMPOSIUM ON CIRCUITS AND SYSTEMS, 2003. *Proceedings of...* [S.l.]: IEEE, v. 2, p. 456–459. ISBN 0-7803-7761-3.
- KATAOKA, T.; OKAMOTO, H.; HATA, S. (2001). Automatic detection system of apple harvest season for robotic apple harvesting. In: ASAE - THE SOCIETY FOR ENGINEERING IN AGRICULTURAL, FOOD, AND BIOLOGICAL SYSTEMS, 2001, Sacramento, California, EUA. *Proceedings...* [S.l.]: ASAE.
- KATO, Z.; PONG, T.; LEE, J. C. (2001). Color image segmentation and parameter estimation in a markovian framework. *Pattern Recognition Letters*, v. 22, n. 3–4, p. 309–321, mar.
- KURUGOLLU, F.; SANKUR, B.; HARMANCI, A. E. (2002). Image segmentation by relaxation using constraint satisfaction neural network. *Image and Vision Computing*, v. 20, n. 7, p. 483–497.
- LEVINE, M. D. (1985). *Vision in man and machine*. 1. ed. Nova Iorque, EUA: McGraw-Hill, Inc. ISBN 0-07-037446-5.
- LI, J.; WANG, J. Z. (2006). Real-time computerized annotation of pictures. In: THE 14TH ANNUAL ACM INTERNATIONAL CONFERENCE ON MULTIMEDIA, 2006, Santa Barbara, CA, EUA. *Proceedings...* New York, NY, EUA: ACM Press.
- LI, N.; LI, Y. F. (2003). Feature encoding for unsupervised segmentation of color images. *IEEE Transactions on Systems Man and Cybernetics*, v. 33, n. 3, p. 438–447, jun. ISSN 1083-4419.

- LIN, W.; TSAO, E. C.; CHEN, C. (1992). Constraint satisfaction neural networks for image segmentation. *Pattern Recognition*, v. 25, n. 7, p. 679–693, jun.
- LITTMANN, E.; RITTER, H. (1997). Adaptive color segmentation - a comparison of neural and statistical methods. *IEEE Transactions on Neural Networks*, v. 8, n. 1, p. 175–185.
- LIU, Y. et al. (2005). Region-based image retrieval with high-level semantic color names. In: INTERNATIONAL MULTIMEDIA MODELLING CONFERENCE, 11., 2005, Washington, DC, USA. *Proceedings...* [S.l.]: IEEE Computer Society, p. 180–187. ISBN 0-7695-2164-9.
- LIU, Y.; ZHOU, X. (2004). Automatic texture segmentation for texture-based image retrieval. In: INTERNATIONAL MULTIMEDIA MODELLING CONFERENCE, 10., 2004. *Proceedings of...* [S.l.]: IEEE Computer Society, p. 285–290. ISBN 0-7695-2084-7.
- LUCCHESI, L.; MITRA, S. K. (2001). Colour image segmentation: a state-of-the-art survey. In: INDIAN NATIONAL SCIENCE ACADEMY, 2001, India. *Proceedings...* India: Indian National Science Academy, v. 67 A, n. 2, p. 207–222.
- MACAIRE, L.; VANDENBROUCKE, N.; POSTAIRE, J. (2006). Color image segmentation by analysis of subset connectedness and color homogeneity properties. *Computer Vision and Image Understanding*, v. 102, n. 1, p. 105–116, abr.
- MANJUNATH, B. S. et al. (2001). Color and texture descriptors. *IEEE Transactions on Circuits and Systems for Video Technology*, v. 11, n. 6, p. 703–715.
- MOLIN, J. P. (2003). *Agricultura de precisão - o gerenciamento da variabilidade*. 1. ed. Piracicaba, Brasil: José Paulo Molin. ISBN 85-893530-15-X.
- MOREIRA, J.; COSTA, L. d. F. (1996). Neural-based color image segmentation and classification using self-organizing maps. In: SIBGRAPI, IX., 1996. *Anais...* [S.l.]: Sociedade Brasileira de Computação, p. 47–54.
- MORIMOTO, T. et al. (2000). Pattern recognition of fruit shape based on the concept of chaos and neural networks. *Computers and Electronics in Agriculture*, v. 26, n. 2, p. 171–186.
- NETO, J. C. et al. (2003). Adaptive image segmentation using a fuzzy neural network and genetic algorithm for weed detection. In: ASAE ANNUAL INTERNATIONAL MEETING, 2003, Las Vegas, Nevada, EUA. *Proceedings...* [S.l.]: ASABE.
- NETO, O. C. P.; AES, M. F. G.; JORGE, L. A. C. (2004). Desempenho de redes neurais na quantificação de plantas daninhas em cultura de soja. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO, 2004. *Anais...* Piracicaba, São Paulo, Brasil: USP/Esalq.
- NISSSEN, S. et al., (2006). *FANN - Fast Artificial Neural Network Library*. Disponível em: <http://leenissen.dk/fann>. Acesso: 12 fev. 2006.
- NOBLE, S. D.; BROWN, R. B. (2004). Plant identification using hyperspectral and multi-perspective imaging. In: ASAE/CSAE ANNUAL INTERNATIONAL MEETING, 2004, Ottawa, Ontário, Canadá. *Proceedings...* [S.l.]: ASAE.
- ORLANDO, R. C.; PINTO, F. A. C.; QUEIROZ, D. M. (2004). Identificação automática de plantas daninhas e milho utilizando técnicas de visão artificial. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO, 2004, Piracicaba, São Paulo, Brasil. *Anais...* [S.l.]: USP/Esalq.

- PAALANEN, P. et al. (2006). Feature representation and discrimination based on gaussian mixture model probability densities – practices and algorithms. *Pattern Recognition*, v. 39, p. 1346–1358.
- PAL, N. R.; PAL, S. K. (1993). A review on image segmentation techniques. *Pattern Recognition*, v. 26, n. 9, p. 1277–1294, set.
- PARK, S. B.; LEE, J. W.; KIM, S. K. (2004). Content-based image classification using a neural network. *Pattern Recognition Letters*, v. 3, n. 25, p. 287–300, fev. ISSN 0167-8655.
- PARRISH, J. E. A.; GOKSEL, A. K. (1977). Pictorial pattern recognition applied to fruit harvesting. *Transactions of the ASAE*, v. 20, n. 5, p. 822–827.
- PHILIPP, I.; RATH, T. (2002). Improving plant discrimination in image processing by use of different colour space transformations. *Computers and Eletronics in Agriculture*, v. 35, n. 1, p. 1–15.
- PLEBE, A.; GRASSO, G. (2001). Localization of spherical fruits for robotic harvesting. *Machine Vision and Applications*, v. 13, p. 70–79.
- REGUNATHAN, M.; LEE, W. S. (2005). Citrus fruit identification and size determination using machine vision and ultrasonic sensors. In: ASAE/CSAE ANNUAL INTERNATIONAL MEETING, 2005, Tampa, Flórida, EUA. *Proceedings...* [S.l.]: ASABE.
- RUIZ, L. A. et al. (1996). Location and characterization of the stem-calyx area on oranges by computer vision. *Journal of Agricultural Engineering Research*, Elsevier Science, v. 64, n. 3, p. 165–172.
- RUSSELL, S.; NORVIG, P. (2004). *Inteligência artificial*. 1. ed. São Paulo, Brasil: Editora Campus. ISBN 85-352-1177-2.
- SCHALKOFF, R. J. (1989). *Digital image processing and computer vision*. 1. ed. Nova Iorque, EUA: John Wiley & Sons, Inc. ISBN 0-471-857118-1.
- SHRESTHA, D. S.; STEWARD, B. L. (2003). Automatic corn plant population measurement using machine vision. *Transactions of the ASAE*, v. 46, n. 2, p. 559–565.
- SLAUGHTER, D. C.; HARRELL, R. C. (1989). Discriminating fruit robotic harvest using color in natural outdoor scenes. *Transactions of the ASAE*, v. 32, n. 2, p. 757–763.
- SPIRKOVSKA, L., (1993). *A summary of image segmentation techniques*. NASA Technical Memorandum 104022. Disponível em: <http://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19940006802_1994006802.pdf>. Acesso em: 24 mai. 2006.
- STAJNKO, D.; LAKOTA, M.; HOCEVAR, M. (2004). Estimation of number and diameter of apple fruits in an orchard during the growing season by thermal imaging. *Computers and Eletronics in Agriculture*, v. 42, p. 31–42.
- STEWART, B. L. et al. (2004). Reduced-dimension clustering for vegetation segmentation. *Transactions of the ASAE*, v. 47, p. 609–616.
- STEWART, B. L.; TIAN, L. F.; TANG, L. (2002). Distance-based control system for machine vision-based selective spraying. *Transactions of the ASAE*, v. 45, n. 5, p. 1255–1262.

- SWAIN, M. J.; BALLARD, D. H. (1991). Color indexing. *International Journal of Computer Vision*, v. 7, n. 1, p. 11–32. Disponível em: <<http://dx.doi.org/10.1007/BF00130487>>. Acesso em: 22 out. 2006.
- TANG, L.; TIAN, L.; STEWARD, B. L. (2000). Color image segmentation with genetic algorithm for in-field weed sensing. *Transactions of the ASAE*, v. 43, p. 1019–1027.
- TANG, L.; TIAN, L.; STEWARD, B. L. (2003). Classification of broadleaf and grass weeds using gabor wavelets and an artificial neural network. *Transactions of the ASAE*, v. 46, p. 1247–1254.
- TIAN, L. F.; SLAUGHTER, D. C. (1998). Environmentally adaptive segmentation algorithm for outdoor image segmentation. *Computers and Electronics in Agriculture*, v. 21, p. 153–168.
- TRONCO, M. L. (1999). *Sistema de reconhecimento de imagens baseado no modelo GSN de rede neural*. Tese (Doutorado) — Universidade de São Paulo, Escola de Engenharia de São Carlos, 1999.
- VANDENBROUCKE, N.; MACAIRE, L.; POSTAIRE, J. (2003). Color image segmentation by pixel classification in an adapted hybrid color space. application to soccer image analysis. *Computer Vision and Image Understanding*, v. 90, n. 2, p. 190–216, maio.
- WEI, J. (2002). Image segmentation based on situational dct descriptors. *Pattern Recognition Letters*, v. 23, n. 1–3, p. 295–302.
- WHITTAKER, A. D. et al. (1987). Fruit location in a partially occluded image. *Transactions of the ASAE*, v. 30, n. 3, p. 591–596.
- ZHANG, Y. J. (1996). A survey on evaluation methods for image segmentation. *Pattern Recognition*, v. 29, n. 8, p. 1335–1346.
- ZHANG, Y. J. (2001). A review of recent evaluation methods for image segmentation. In: SIGNAL PROCESSING AND ITS APPLICATIONS, 6., 2001, Kuala Lumpur, Malaysia. *Symposium on...* [S.l.]: Dept. of Microelectronics and Computer Engineering, UTM and Signal Processing Research Center, QUT, v. 1, p. 148–151. ISBN 0-7803-6703-0.