



UNIVERSIDADE
ESTADUAL DE LONDRINA

FELIPE HADDAD MANFIO

**RECONHECIMENTO DE PADRÕES VISUAIS HERDADOS
ATRAVÉS DE TÉCNICAS DE PROCESSAMENTO DE
IMAGEM E MINERAÇÃO DE DADOS:
UM ESTUDO DE CASO DA ORQUÍDEA *Dendrobium nobile***

FELIPE HADDAD MANFIO

**RECONHECIMENTO DE PADRÕES VISUAIS HERDADOS
ATRAVÉS DE TÉCNICAS DE PROCESSAMENTO DE
IMAGEM E MINERAÇÃO DE DADOS:
UM ESTUDO DE CASO DA ORQUÍDEA *Dendrobium nobile***

Dissertação apresentada ao Curso de Mestrado, Departamento de Computação da Universidade Estadual de Londrina, como requisito parcial para a obtenção do título de Mestre, sob orientação do Prof. Dr. Alan Salvany Felinto.

Londrina
2011

M276r Manfio, Felipe Haddad.

Reconhecimento de padrões visuais herdados através de técnicas de processamento de imagem e mineração de dados: um estudo de caso da orquídea *Dendrobium nobile* / Felipe Haddad Manfio. – Londrina, 2011.
88. : il.

Orientador: Alan Salvany Felinto Dr.

Dissertação (Mestrado em Ciência da Computação) □ Universidade Estadual de Londrina, Centro de Ciências Exatas, Programa de Pós-Graduação em Ciência da Computação, 2011.

Inclui bibliografia.

1. Reconhecimento de Padrões. 2. Processamento de Imagem. 3. Segmentação de Imagem. 4. Data Mining. 5. *Dendrobium nobile*. I. Felinto, Alan Salvany. II. Universidade Estadual de Londrina. Centro de Ciências Exatas. III. Título.

CDD 621.367

FELIPE HADDAD MANFIO

**RECONHECIMENTO DE PADRÕES VISUAIS HERDADOS ATRAVÉS
DE TÉCNICAS DE PROCESSAMENTO DE IMAGEM E MINERAÇÃO
DE DADOS:**

UM ESTUDO DE CASO DA ORQUÍDEA *Dendrobium nobile*

Esta Dissertação foi julgada adequada para obtenção do título de Mestre, e aprovada em sua forma final pela Coordenação do Curso de Mestrado em Ciência da Computação, do Departamento de Computação da Universidade Estadual de Londrina.

BANCA EXAMINADORA

Prof. Dr. Alan Salvany Felinto
UEL- Londrina - PR

Prof. Dr. Jacques Duílio Brancher
UEL- Londrina - PR

Prof^a. Dr^a. Lúcia Sadayo Assari Takahashi
UEL- Londrina - PR

Prof. Dr. Wesley Attrot
UEL- Londrina - PR

Londrina, 21de Março de 2011.

A minha esposa Jessica e meu filho Miguel que são minha inspiração. A minha Família que sempre está ao meu lado. Aos meus amigos. Ao meu orientador pela dedicação, apoio e reconhecimento.

AGRADECIMENTOS

Agradeço também à Universidade Estadual de Londrina por permitir que eu me qualificasse para juntos trabalharmos por uma Universidade cada vez mais competente.

Agradeço aos colegas do Departamento de Computação pelo apoio em busca de um mesmo ideal e pela dedicação e esclarecimento.

Agradeço especialmente ao meu orientador, Prof, Alan Salvany Felinto pelo apoio seguro, firme e com qualidade.

Agradeço ao Departamento de Agronomia da Universidade Estadual de Londrina, principalmente a Prof^a. Lúcia Sadayo Assari Takahashi por colocar a minha disposição o conhecimento do departamento.

MANFIO, Felipe Haddad. **Reconhecimento de padrões visuais herdados através de técnicas de processamento de imagem e mineração de dados:** um estudo de caso da orquídea *Dendrobium nobile*. 2011. 88f. Dissertação (Mestrado em Ciências da Computação) – Universidade Estadual de Londrina, Londrina, 2011.

RESUMO

Esta dissertação descreve a implementação de uma metodologia para o reconhecimento de padrões visuais herdados em flores através de técnicas de processamento de imagem e mineração de dados. Esta ferramenta permite quantificar os atributos visuais tamanho, média e desvio padrão dos componentes do modelo de cor RGB e através dos algoritmos de mineração de dados PART e JRIP identificar padrões visuais herdados. Para realização dos testes um grupo de 152 imagens da orquídea do gênero *Dendrobium nobile*, divididos em 7 cruzamentos, foram analisados. Os resultados mostram a existência de padrões visuais herdados que não poderiam ser encontrados por um perito humano. Essa abordagem contribuiu com uma nova aplicação das técnicas de reconhecimento de padrões visuais, definindo um método que pode ser aplicada para a caracterização de outras espécies de plantas.

Palavras-Chave: Reconhecimento de padrões. Processamento de imagem. Segmentação de imagem. Data mining. *Dendrobium nobile*.

MANFIO, Felipe Haddad. **Recognition of inherited visual patterns through image processing and data mining techniques**: a case study of orchid *Dendrobium nobile*. 2011. 88p. Dissertação (Mestrado em Ciências da Computação) – Universidade Estadual de Londrina, Londrina, 2011.

ABSTRACT

This study draws on the implementation of a methodology for the recognition of visual patterns inherited through image and data mining processing techniques. This tool permits the quantification of visual attributes such as size, medium and deviation pattern of RGB color components, and through data mining algorithm PART and JRIP it is possible to identify inherited visual patterns. In order to accomplish the tests a group of 152 images of orchid *Dendrobium nobile*, parted in 7 cross-breeding, were analyzed. The results display the existence of inherited visual patters that cannot be found by human expert. This approach has contributed to a new application of visual patterns recognition techniques, thus defining a method that can be applied to the characterization of other plant species.

Keywords: Pattern recognition. Image processing. Image section. Data mining.
Dendrobium nobile.

LISTA DE FIGURAS

Figura 1-	Representação de uma imagem digital matricial. Adaptação de [42].....	17
Figura 2 –	Imagem colorida denominada Lena [31].....	18
Figura 3 –	Espectro eletromagnético. Adaptado de [42]	19
Figura 4 –	Imagem binária da imagem Lena (Figura 2)	20
Figura 5 –	Imagem monocromática da imagem Lena (Figura 2).....	21
Figura 6 –	Relação de cores interpretadas pelo humano através da faixa de comprimentos de ondas eletromagnéticas. Adaptado de [17].22	
Figura 7 –	Cubo representando a variação de cores do modelo de cor RGB...23	
Figura 8 –	Etapas do processamento de imagem adaptada de [17].	25
Figura 9 –	Exemplo do Gráfico do Histograma	28
Figura 10 –	Imagem com concentração de pontos e histograma da imagem.....	28
Figura 11 –	Imagem com equalização e histograma da imagem.....	28
Figura 12 –	Imagem Original (A) e seu histograma (B), [48].....	29
Figura 13 –	Imagem equalizada (A) e seu histograma (B), [48].....	30
Figura 14 –	Imagem (a) e seu histograma (b), [48].....	31
Figura 15 –	Imagem segmentada (a) e escolha do limiar (b), [48].....	31
Figura 16 –	Imagem (a) e seu histograma (b), [48].....	32
Figura 17 -	Imagem segmentada (a) e escolha do limiar (b), [48].....	32
Figura 18 –	Operador de Sobel aplicado a imagem Lena (Figura 2)	33
Figura 19 –	Resultado da aplicação do algoritmo de Mumford & Shah à Lena ..	35
Figura 20 -	Síntese do fluxograma de classificação apresentado por [15]	39
Figura 21 -	Exemplo de definição de classes: Trabalho de JANSSEN [22] onde foi estabelecida a regra para diferenciação entre homem e mulher baseada na massa corporal e muscular	41
Figura 22 -	Adaptação da Taxonomia de seleção das características segundo [21]	46

Figura 23 - Conjunto de regras adaptado do WEKA, geradas pelo algoritmo de tabela de decisão baseada nos dados da tabela 3	51
Figura 24 - Árvore de decisão com atributos nominais e numéricos.....	52
Figura 25 - Conjunto de regras adaptado do WEKA, geradas pelo algoritmo de regras de decisão baseada nos dados da tabela 3.....	53
Figura 26 - Exemplo da Rede Bayesiana.....	57
Figura 27 – Imagem da <i>Dendrobium nobile</i> capturada pelo scanner de mesa, para a realização da medição através do software Flores.....	63
Figura 28 – Fluxograma do projeto	64
Figura 29 – (a) Segmentação da Figura 27 através do limiar 23; (b) Segmentação da Figura 27 através do limiar 27.....	66
Figura 30 – Segmentação da Figura 27 através de operadores morfológicos.....	66
Figura 31 – Indicação da falha de segmentação da Figura 27 através do método de sobel	67
Figura 32 - a) Segmentação da Figura 27 através de um limiar único no modelo de cor $L^*a^*b^*$, com $T=30$; (b) Figura 27 segmentada através de limiares independentes para o modelo de cor $L^*a^*b^*$, com $T_L=21$, $T_a=10$ e $T_b=13$;	68
Figura 33 – (a) Imagem segmentada (b) Imagem representado o contorno da flor segmentada em (a)	69
Figura 34 – Classificação do Método PART. Os valores numéricos representam o número de instâncias classificadas.....	74
Figura 35 – Dispersão da Média do G componente de cor RGB	76
Figura 36 – Exemplo de cada cruzamento no formato original	76
Figura 37 – Dispersão do tamanho da flor.....	77
Figura 38 – Dispersão da Quantidade de Pixels.....	79

LISTA DE TABELAS

Tabela 1 - Abordagens para o reconhecimento de padrões. Adaptação de [21]	40
Tabela 2 - Taxonomia dos espaços de características [3].....	43
Tabela 3 - Condições do tempo. Adaptação da Tabela 1.2 de [53].....	51
Tabela 4 - Algoritmos de classificação através de Árvore de Decisão disponíveis no WEKA.....	53
Tabela 5 - Algoritmos de Classificação através de Regras de Classificação disponível no WEKA.....	54
Tabela 6 - Algoritmos de Classificação baseados em Instâncias disponíveis no WEKA.....	56
Tabela 7 - Algoritmos de Classificação Bayesianos disponíveis no WEKA.....	58
Tabela 8 - Quantidade de Imagens existentes por cruzamento	64
Tabela 9 - Resultados da aplicação dos métodos de classificação PART e JRIP	73
Tabela 10 - Número de regras e condições dos métodos PART e JRIP	74
Tabela 11 -Número de regras e condições dos métodos PART e JRIP	75
Tabela 12 - Características que são utilizadas juntas com a Média e G nas regras definidas pelo algoritmo PART	77
Tabela 13 - Número de regras e classificações corretas do método PART.....	78
Tabela 14 - Quantidade de Imagens existentes por cruzamento.....	80
Tabela 15 – Características dos Pais	80
Tabela 16 – Características dos Cruzamentos	81
Tabela 17 – Desvio Padrão Médio dos cruzamentos com os pais.....	81
Tabela 18 – Desvio Padrão dos cruzamentos com os pais.....	82

LISTA DE ABREVIATURAS

2D	Duas Dimensões
ARFF	Attribute-Relation File Format
CIE	Commission internationale de l'éclairage
CSV	Comma-separated values
JPG	Extensão do arquivo JPEG
JPEG	Joint Photographic Experts Group
KB	Kilobyte
nm	Nanómetro
M	Mega
PIL	Python Image Library
PTA	Plus I – Take Away
RBF	Radial Basis Function
Ripper	Repeated Incremental Pruning to Produce Error Reduction
SFBS	Sequential Floating Backward Search
SFFS	Sequential Floating Forward Search
SOM	Self-Organizing Map
THZ	Tera Hertz
WEKA	Waikato Environment for Knowledge Analysis

SUMÁRIO

INTRODUÇÃO	13
1 IMAGENS DIGITAIS	17
1.1 Elementos da Imagem	19
1.2 Imagens Binárias.....	20
1.3 Imagens Monocromáticas	20
1.4 Imagens Coloridas	21
1.4.1 A Cor	21
1.5 MODELOS DE COR	22
1.5.1 Modelo de Cor RGB.....	22
1.5.2 Modelo de Cor XYZ.....	23
1.5.3 Modelo de cor $L^*a^*b^*$	23
2 PROCESSAMENTO DIGITAL DE IMAGENS	25
2.1 ETAPAS DO PROCESSAMENTO DE IMAGENS	25
2.1.1 Aquisição de Imagens Digitais	26
2.1.2 Pré-processamento	26
2.1.3 Segmentação	30
2.1.4 Representação e Descrição	37
2.1.5 Reconhecimento e Interpretação	37
3 RECONHECIMENTO DE PADRÕES	38
3.1 EXTRAÇÃO DAS CARACTERÍSTICAS.....	42
3.2 PRÉ-PROCESSAMENTO E REDUÇÃO DE DADOS	44
3.2.1 Limpeza dos Dados.....	44
3.2.2 Tratamento de Valores Omissos	44
3.2.3 Amostragem (Sampling).....	45
3.2.4 Seleção das Características.....	45
3.3 DISCRETIZAÇÃO.....	49
3.4 MODELOS E ALGORITMOS DE APRENDIZAGEM	50
3.4.1 Modelos de Classificação.....	50
3.4.2 Modelos de Associação	58

3.4.3	Modelos de Clustering.....	59
3.5	SELEÇÃO DE ALGORITMOS	60
3.6	AVALIAÇÃO DO ALGORITMO DE CLASSIFICAÇÃO.....	61
4	O PROJETO	62
4.1	SEGMENTAÇÃO.....	65
4.2	CARACTERÍSTICAS OBTIDAS	68
5	RESULTADOS EXPERIMENTAIS	70
	CONCLUSÃO	83
	BIBLIOGRAFIA	85

INTRODUÇÃO

A visão é considerada um dos principais meios de percepção do mundo exterior pelos seres humanos. Para o auxílio de tarefas que utilizam a visão como função principal podem ser utilizados sistemas de visão artificial, que são sistemas capazes de reconhecer padrões previamente ensinados em uma imagem complexa. O principal objetivo de um sistema de visão artificial é adquirir, processar, analisar e interpretar um determinado tipo de imagem para uma determinada finalidade. O desempenho de um sistema automático de análise de imagem é fundamental, por isso são desenvolvidos para aplicações específicas, permitindo que o sistema apresente um alto desempenho para uma determinada função, como por exemplo o reconhecimento de padrões.

Definir padrões visuais é de extrema importância em atividades que têm como objetivo correlacionar objetos [5, 1, 56, 36], ou seja, encontrar similaridades visuais ou conceituais entre diferentes elementos determinando as relações existentes entre eles. Essas similaridades podem ser determinadas através da procura de padrões específicos, sendo que o grau de dificuldade desta atividade está diretamente relacionado com a quantidade de itens e a complexidade das relações procuradas [5].

Quando a procura de padrões é executada por uma pessoa as definições de características podem estar sujeitas a uma análise subjetiva [7, 36, 54, 57], pois a sua percepção é influenciada pela sua educação e a sociedade em que vive [49], assim em diferentes povos e culturas a análise de correlação pode resultar em diferentes resultados.

Visando a eliminação da análise subjetiva, encontrar padrões visuais em objetos tem sido alvo de constantes pesquisas na área computacional [41, 57, 1, 43, 2], pois a utilização de técnicas de processamento de imagem e inteligência artificial potencializam a realização desta tarefa garantindo maior eficiência e otimização do resultado esperado.

Das diversas áreas onde a procura de padrões visuais são utilizadas pode-se destacar a extrema importância dessa técnica na agricultura, pois a definição de padrões visuais de tamanho e cor em plantas, como flores, folhas, frutos e sementes são alvo de estudos constantes para a melhoria das culturas

vegetais, visto que tais padrões estão relacionados a qualidade e quantidade dos produtos agrícolas [55]. Artigos que exploram a busca de padrões através da análise de imagens em flores são abordados em [57, 55, 41, 39, 36, 26]. Outros artigos também realizam a análise de cores em maçãs [30], tomates [7], melões [54] e em grama [25]. Esta dissertação investigará a existência de padrões visuais herdados em orquídeas do gênero *Dendrobium nobile* através de técnicas computacionais de processamento de imagem e mineração de dados.

Para a análise de hereditariedade em plantas através de recursos computacionais torna-se vital a definição de um método de avaliação objetivo e quantitativo dos padrões visuais existentes. Analisando [43, 2, 38] verifica-se a necessidade de responder a duas questões na definição de um método para reconhecimento de padrões: a primeira é quais as características que serão utilizadas como critérios de classificação; a segunda é quais técnicas serão utilizadas para encontrar as similaridades das características. Além disso, considerando a construção de um sistema automatizado para o registro de diferentes variedades ou pelo menos semi-automatizado, deve-se analisar quais as características podem ser obtidas automaticamente.

Com a utilização de técnicas de processamento de imagem o bom resultado da detecção das características depende da eficiência do processo de segmentação da imagem [5]. Essa é a principal etapa em um sistema de análise de imagem [4] e essencial para detecção de padrões e reconhecimento [46]. Problemas causados pelo fundo da imagem ou interferência da iluminação podem comprometer o objetivo do sistema. A segmentação de flores em seu ambiente natural é explorada em [8, 41, 45, 39, 40, 20, 9]. Utilizando uma abordagem diferente [55, 57, 26, 7] captura as flores em um ambiente controlado com um fundo fixo, facilitando o processo de segmentação. Entretanto, em alguns casos, se torna necessário a calibragem da imagem para eliminar interferências produzidas pelo próprio equipamento de captura.

Após a segmentação do objeto, basicamente, é realizada a fase de extração de características para a realização da busca de padrões. A procura de padrões em imagens utilizando técnicas de data mining são abordadas por [43, 2, 12, 33, 6, 1]. O uso destas técnicas favorece a busca da similaridade das características, mas alguns padrões que são identificados pelo perito humano podem ser descartados por possuírem uma alta complexidade. O conhecimento

obtido pode ser representado em diversas formas, entre elas tabela de decisão, árvore de decisão e regras de associação, que deve ser analisado visando encontrar padrões e correlações entre os objetos [53].

Assim, a utilização de diversas técnicas em conjunto auxiliara a realização dos objetivos desta dissertação.

OBJETIVOS

O objetivo geral deste trabalho é desenvolver uma metodologia para reconhecimento de padrões visuais herdados em flores, composta pelas etapas de captura da imagem, segmentação, definição das características e classificação, com a utilização de processamento de imagens e técnicas de mineração de dados

Os objetivos específicos são:

- Encontrar padrões visuais herdados em orquídeas do gênero *Dendrobium nobile*.
- Realizar um estudo teórico sobre as técnicas de processamento de imagem.
- Realizar um estudo teórico sobre as técnicas de reconhecimento de padrões visuais.
- Desenvolver um método para captura da imagem, segmentação, definição das características e classificação.
- Desenvolver softwares para realizar etapas específicas do método desenvolvido.
- Aplicar o método desenvolvido
- Demonstrar os resultados.

CONTRIBUIÇÃO

Essa abordagem contribuiu com uma nova aplicação das técnicas de reconhecimento de padrões visuais, definindo um método que pode ser aplicada para a caracterização de outras espécies de plantas. Além disso, este trabalho poderá servir como referência a outros pesquisadores que queiram realizar estudos sobre áreas afins.

ORGANIZAÇÃO DO TEXTO


No primeiro capítulo são apresentados as definições de imagens digitais e seus elementos e componentes, conceituando os tipos de imagens digitais e seus modelos de cores. No segundo capítulo são abordadas as etapas do processamento de imagem: aquisição, pré-processamento, segmentação, representação e descrição e reconhecimento e Interpretação. Também é explanado o conceito de morfologia matemática. No terceiro capítulo é destacado o conceito de reconhecimento de padrões e suas fases de extração, pré-processamento e discretização. Do mesmo modo são conceituados os modelos de algoritmos de aprendizados existentes definindo como deve ser feita a seleção e avaliação dos mesmos. No quarto capítulo são definidos os passos executados pelo projeto, caracterizando a etapa de segmentação e utilização do Data Mining. No quinto capítulo são apresentados os resultados experimentais que serviram de base para as conclusões finais que são apresentadas no último capítulo.

1 IMAGENS DIGITAIS

A imagem é uma representação gráfica de pessoa ou objeto. É formada pelo conjunto de pontos no espaço, para onde convergem ou de onde divergem os raios luminosos que, originados de um objeto luminoso ou iluminado, passam através de um sistema óptico. Para o ser humano uma imagem é o que ele percebe como resultado da luz atingindo seus olhos, passando pelo cristalino e incidindo na retina. Na computação segundo [17] o termo imagem pode ser definido como uma função de intensidade da luz, denominada $f(x,y)$, onde x e y são as coordenadas espaciais e o valor de f é brilho da imagem no ponto (x, y) .

A imagem digital pode ser considerada uma imagem com os valores discretizados das coordenadas e brilhos, formadas por linhas e colunas onde cada ponta da imagem contém a intensidade de cor do ponto. A Figura 1 representa a convenção dos eixos da imagem digital que inicia no canto superior esquerdo. A imagem digital possui algumas características fundamentais, como a resolução e o número de cores, e pode ser representada, processada e armazenada no formato de uma imagem matricial ou vetorial.

Figura 1- Representação de uma imagem digital matricial. Adaptação de [42]



A imagem matricial é formada por uma série ordenada de pixels dispostos continuamente em linha e colunas, chamada de matriz de pontos, onde cada pixel tem suas características definidas com cor e brilho. A imagem vetorial é formada por um conjunto de instruções matemáticas, onde ela é gerada a partir das instruções que são processadas. Nesse modelo pode-se alterar o tamanho da

mesma sem perder definição, pois serão calculadas as instruções novamente para o novo tamanho.

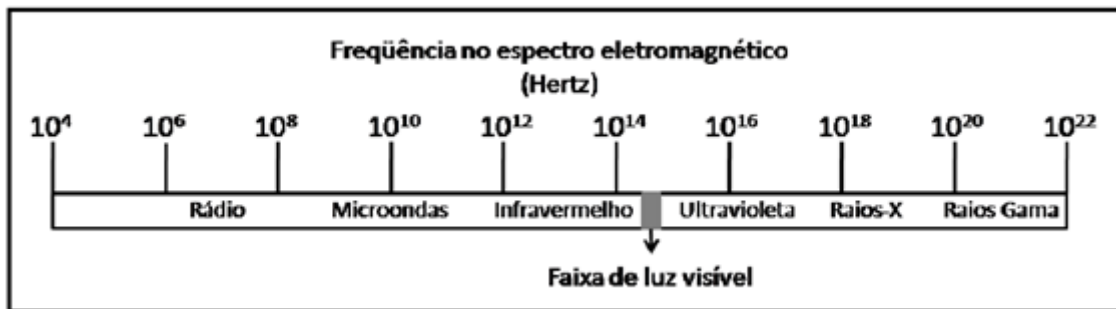
Normalmente as imagens matriciais possuem formato retangular e são compostas por elementos de imagem que definem sua estrutura. Neste caso cada uma das posições da matriz armazena um elemento estruturante, definindo a cor ou intensidade de luminosidade naquele ponto. A Figura 2 é a representação da imagem matricial colorida denominada Lena que será utilizada para demonstrar algumas características da imagem.

Figura 2 – Imagem colorida denominada Lena [31]



A captura da imagem está vinculada a capturar de um sinal que pode ser em uma dimensão (por exemplo: luminosidade), duas dimensões (por exemplo: imagens estáticas) ou três dimensões (por exemplo: tomografias computadorizadas). Pode-se associar ao sinal o fator tempo compondo assim uma seqüência de sinais, como por exemplo vídeos compostos por uma seqüência de capturas de sinais bidimensionais. A aquisição da imagem digital pode ser feita pela captura de diferentes faixas do espectro do campo eletromagnético como infravermelho, luz visível, ultravioleta e raios-x, possuindo as mais diferentes aplicações em cada faixa. A Figura 3 mostra as diferentes faixas de luz existentes, onde uma pequena faixa é visível ao olho humano.

Figura 3 – Espectro eletromagnético. Adaptado de [42]



1.1 ELEMENTOS DA IMAGEM

A imagem digital é formada por elementos que são valores de resposta da função imagem para cada coordenada. Esses valores são estruturas que armazenam a intensidade de brilho, ou intensidade de cores, quando aplicável. Os elementos da imagem são comumente conhecidos como *pixel* (*Picture Element*). O pixel é a menor unidade da imagem digital. Uma imagem de tamanho 1024x768 possui 786432 pixels.

A resolução representa a quantidade de pixels que uma imagem possui e está fortemente ligada a qualidade gráfica da imagem. Uma imagem com um mega pixels (1M pixels) possui um milhão de pixels. Quando maior a quantidade de pixels melhor a imagem é representada, assim melhorando a qualidade de detalhes da mesma.

A quantidade de cores que a função da imagem pode representar também é um elemento da imagem. A definição do modelo de cor utilizado pela imagem irá definir as características de armazenamento do valor de intensidade da cor. Em alguns caso pode-se armazenar a essa característica utilizando números binários, onde o valor “0” representa à ausência completa de luminosidade e o valor “1” a captura máxima de luminosidade. E outros caso, e mais tradicional, os valores utilizados são normalizados em faixas de valores baseados em números potência de dois, como por exemplo, números entre 0 e 255, representando os 256 valores possíveis = 2^8 (oito bits por canal).

1.2 IMAGENS BINÁRIAS

As imagens binárias são matrizes onde a função da imagem pode assumir apenas dois valores, geralmente o preto e o branco ou ausência ou não de cor. É muito utilizada no processamento da imagem, pois é possível transformar uma imagem colorida em uma imagem binária revelando característica da imagem que pode ser utilizadas para criação de máscaras, definição de regiões, descrição de bordas e esqueletos de objetos. A Figura 4 mostra um exemplo a imagem Lena transformada em uma imagem binária.

Figura 4 – Imagem binária da imagem Lena (Figura 2)



1.3 IMAGENS MONOCROMÁTICAS

A imagem monocromática é aquela de apresenta apenas um canal de cor. Imagens em tons de cinza, televisões antigas e monitores antigos de fósforo verde são exemplos de imagens monocromáticas. Imagens de exames de raios-x, tomografia computadorizada, ressonâncias magnéticas podem ser capturadas neste formato e imagens coloridas podem ser transformadas neste modelo. Esta transformação auxilia o pré-processamento da imagem e o processamento dela, pois para transformar uma imagem colorida em uma imagem binária geralmente é necessário transformá-la em uma imagem monocromática. A Figura 5 mostra um exemplo a imagem Lena transformada em uma imagem monocromática.

Figura 5 – Imagem monocromática da imagem Lena (Figura 2).




1.4 IMAGENS COLORIDAS

A identificação de uma imagem colorida pelos olhos humanos é possível pois a imagem digital representará cenas com espectros visíveis de cores através de elementos estruturantes diferentes, pixels, que armazenam diferentes tipos de dados, em um padrão definido pelo modelo de cor utilizado. Existem diferentes modelos de cores, assim a cor pode ser representada de formas diferentes.

1.4.1 A Cor

A cor está relacionada a percepção visual de diferente comprimentos de onda do espectro da luz, onde a distribuição da intensidade e o comprimento da onda definem a cor. Por ser uma radiação eletromagnética a luz é caracterizada por um comprimento de onda ou frequência, onde existe uma faixa de comprimentos de onda visíveis aos olhos humanos que é de aproximadamente 380nm até 780nm ou 788THZ até 384THZ demonstrada na Figura 6.

Figura 6 – Relação de cores interpretadas pelo humano através da faixa de comprimentos de ondas eletromagnéticas. Adaptado de [17].



1.5 MODELOS DE COR

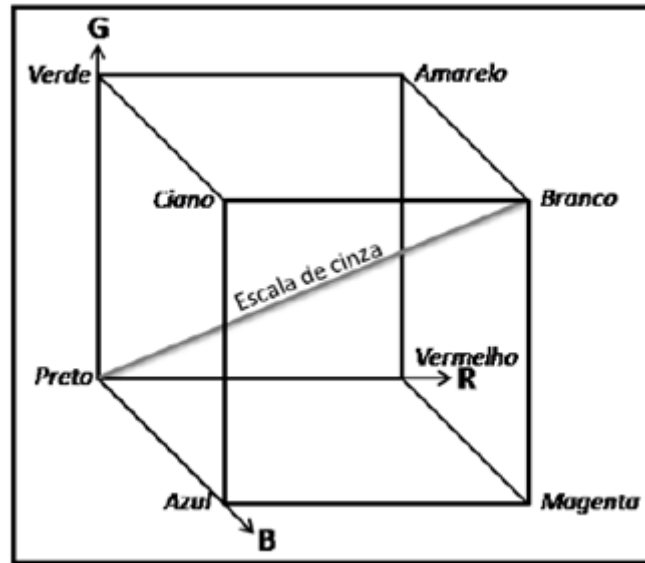
Um modelo de cor é um modelo matemático abstrato que descreve um formato de representação para cores, sendo formados por tuplas de três ou quatro números. Na sua estrutura o modelo de cor deve ter a função de mapeamento, interligando a cor associada aos valores da tupla à cor específica no espectro de cores, bem como sua intensidade, sendo que cada modelo de cor pode representar uma determinada gama ou paleta de cores. Entre os diversos existem pode-se citar os três utilizados nesta dissertação, o RGB, XYZ e $L^*a^*b^*$.

1.5.1 Modelo de cor RGB

RGB é uma abreviação na língua inglesa para três cores primárias de luz: *Red* (Vermelho), *Green* (Verde) e *Blue* (Azul). O modelo computacional adota o RGB como padrão nativo, isso ocorre pela semelhança do RGB com o padrão humano [28].

Representando um espaço de cores em forma de cubo o modelo RGB é baseado em um sistema de coordenadas cartesianas, onde cada uma das três cores representa uma dimensão do cubo. Na diagonal onde os valores dos três componentes de cores têm valores equivalentes se encontra a escala de tons de cinza, como visto da Figura 7. Também nesta escala pode definir o branco e o preto, sendo que o branco é representado pela intensidade máxima dos três componentes e o preto pela intensidade mínima dos três componentes.

Figura 7 – Cubo representando a variação de cores do modelo de cor RGB



1.5.2 Modelo de Cor XYZ

Proposto pela CIE¹ o modelo de cor XYZ é baseado nas cores imaginárias X, Y e Z, onde qualquer combinação aditiva entre duas cores sempre será localizada na reta que conecta estas duas cores no plano XY [28]. Sua relação com o modelo de cor RGB é linear através da relação demonstrada pela Equação 1. A cor branca do modelo de cor XYZ é representada por $X = Y = Z = 1$.

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,49 & 0,31 & 0,20 \\ 0,17697 & 0,81240 & 0,01063 \\ 0,00 & 0,01 & 0,99 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (1)$$

1.5.3 Modelo de cor L*a*b*

O modelo de cor L*a*b* é derivado do modelo XYZ da CIE, onde o L* corresponde à luminância, e os componentes u* e v* correspondem à informação de crominância [28], dado pela Equação 2.

¹ Commission internationale de l'éclairage é o comitê internacional autoridade em luz, iluminação, cor e espaço de cores, situado em Vienna, Austria.

$$\begin{aligned}L^* &= 116f(Y/Yn) - 16 \\ a^* &= 500[f(X/Xn) - f(Y/Yn)] \\ b^* &= 200[f(Y/Yn) - f(Z/Zn)]\end{aligned}\tag{2}$$

onde

$$f(t) = t^{1/3} \text{ para } t > 0,008856$$

$$f(t) = 7,787t + 16/116 \text{ para outros casos}$$

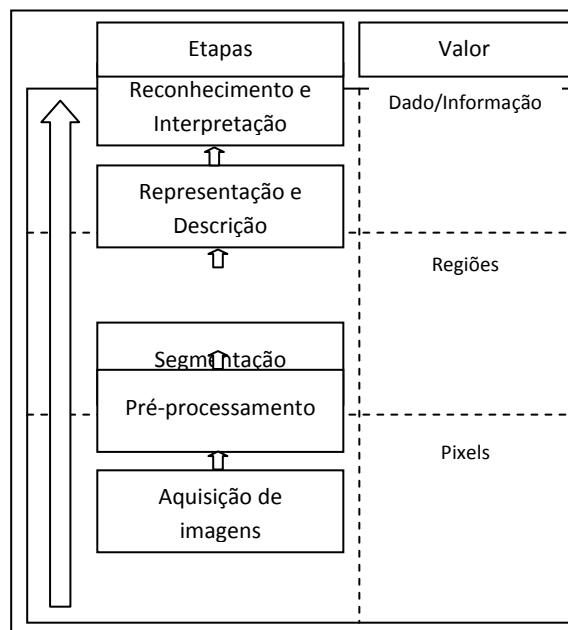
2 PROCESSAMENTO DIGITAL DE IMAGENS

Realizar o processamento em uma imagem digital é analisar e manipular a imagens através de um computador. Inicialmente processamento de imagem digital foi utilizado para pequenas restaurações em imagens digitalizadas. Atualmente as finalidades podem ser diversas como extrair informações da imagem e transformar a imagem realçando elementos. Essas transformações auxiliam a análise da imagem, identificando objetos ou partes da imagem, possibilitando a compreensão da mesma, transformando a imagem em informação.

2.1 ETAPAS DO PROCESSAMENTO DE IMAGENS

Pode-se dividir o processamento de imagem em cinco etapas, cada uma delas envolvendo muitos conceitos diferentes, sendo executadas seqüencialmente, devido à dependência de informação. São elas: aquisição de imagens digitais, pré-processamento, segmentação, descrição e interpretação, conforme demonstradas na Figura 8 e descritas nas seções seguintes.

Figura 8 – Etapas do processamento de imagem adaptada de [17].



2.1.1 Aquisição de Imagens Digitais

Esta é a primeira etapa, onde a imagem é adquirida por um dispositivo físico sensível a uma banda do espectro de energia eletromagnética, que recebe uma intensidade de sinal e produz um sinal elétrico de saída proporcional a um nível de energia. Um elemento digitalizador converte os níveis de energia para o formato digital que é transformado em imagem.

A captura dessas imagens só são possíveis na existência de uma fonte geradora de energia na frequência de interesse, como por exemplo a presença de luz solar ou artificial para aquisição de imagens na banda de luz visível. Em outras frequências não visíveis também é necessário a um gerador de ondas, assim, para gerar imagens de tomografias computadorizadas ou radiografias é necessário um gerador de onda na banda de raio-x.

2.1.2 Pré-processamento

Esta etapa tem como objetivo melhorar/preparar a imagem de tal maneira que possibilite a realização das etapas seguintes. Para isso geralmente são executados algoritmos de atenuação de ruído, realce de contraste, equalização de luminosidade, entre outros.

A existência de ruído na imagem pode ser provida da etapa de aquisição da imagem, pois os equipamentos utilizados estão sujeito a interferência, que podem causar distorções na imagem. Essas distorções podem ser alterações nas cores, manchas ou até mesmo qualidade por causa da resolução de captura. Então nesta etapa serão aplicadas correções visando suavizar a quantidade de distorção ou ruídos.

Para efetuar as correções são aplicados um ou mais filtros visam resolver determinado problema. Os filtros passa-baixa, passa-alta e equalização de histograma são comumente utilizados na etapa de pré-processamento.

O filtro passa-baixa suaviza e diminui os ruídos causados pela processo de captura da imagem digital quando ela sofre interferência pela alteração abrupta e difusa no contraste da imagem, atenuando as altas frequências aplicando um filtro que realiza esmaecimento da imagem. Sua aplicação é através da convolução de uma máscara na qual todos os valores são maiores que zero e

geralmente cada ponto da máscara tem o mesmo valor em relação à distância do ponto central da máscara. A Equação 3 mostra um exemplo de máscara para a filtragem de ruídos no formato passa-baixa, que é aplicada em forma de uma janela móvel, onde a seu funcionamento consiste em posicionar a janela sobre o canto superior esquerdo da imagem, multiplicando cada pixels pelo respectivo valor da janela. Em seguida, substitui-se o valor do pixel central dessa área da imagem pela soma desses 9 valores, dividindo-os por 9, assim encontrando o novo valor do pixel correspondente a imagem de saída. Essa operação deve ser feita pixel-a-pixel aplicando sobre toda a imagem, com isso o novo valor do pixel será recalculado em função dos seus 8 vizinhos mais próximos.


$$\begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \div 9 \quad (3)$$

O filtro passa-alta realça os detalhes, isto é, as transições entre regiões diferentes tornam-se mais nítidas. Sua aplicação é recomendada em imagens que deve destacar as bordas, linhas curvas ou manchas, sendo que não se deve aplicar este filtro sobre imagem com ruídos, pois ele irá enfatizá-lo. A Equação 4 mostra um exemplo de máscara passa-alta. A aplicação deste filtro é equivalente a do filtro passa-baixa.

$$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad (4)$$

Outra técnica de realce existente e muito utilizada é a equalização do histograma, que é utilizado para verificar a distribuição dos níveis de cinza de uma imagem. Ele fornece a informação de quantos pixels na imagem possuem um determinado nível de cinza, com essa informação pode-se verificar se a imagem está com alto ou baixo contraste [14]. Geralmente, como visto na Figura 9, ele é visualizado através de um gráfico (x,y), onde o x é a distribuição dos níveis de cinza e o y é a freqüência que os mesmos ocorrem.

Figura 9 – Exemplo do Gráfico do Histograma




Caso o histograma tenha uma concentração de pontos na esquerda do gráfico significa que a imagem está escura, e caso a concentração seja na direita do gráfico ela está muito clara. Para deixar a imagem com uma boa distribuição utiliza-se a equalizá-lo, ou seja melhorar a distribuição de frequência na imagem. A Figura 10 não contém uma boa visualização, isso pode ser visto pelo seu gráfico representando o histograma. A equalização é mostrada na Figura 11, pode-se notar com facilidade a melhora na imagem.

Figura 10 – Imagem com concentração de pontos e histograma da imagem




Figura 11 – Imagem com equalização e histograma da imagem



A alteração do contraste é uma forma de modificar o histograma para tentar equalizá-lo. Uma iluminação deficiente ou uma falha na captura da imagem poderá deixá-la com pouco contraste [48]. Aumentando o contraste a separação entre os elementos existente tornará mais evidente.

A Figura 12 possui uma iluminação deficiente, isso pode ser visto pelo seu histograma concentrado no lado esquerdo, que possui tons de cinza entre os níveis 0 (preto) e 60 (cinza escuro), para a melhor visualização deve-se tentar expandir o seu histograma utilizando a alteração do contraste.

Figura 12 – Imagem Original (A) e seu histograma (B), [48]



Para a modificação do contraste [48] utilizou uma técnica conhecida como *contrast stretching*. A equação utilizada para a transformação é representada pela Equação 5, onde i é o valor do tons de cinza original do pixels analisado, $[a, b]$ é a faixa de tons de cinza original, i' é o valor do tons de cinza transformado do pixels analisado e $[A, B]$ é a faixa de tons de cinza expandida.

$$i' = \frac{B - A}{b - a} (i - a) + A$$

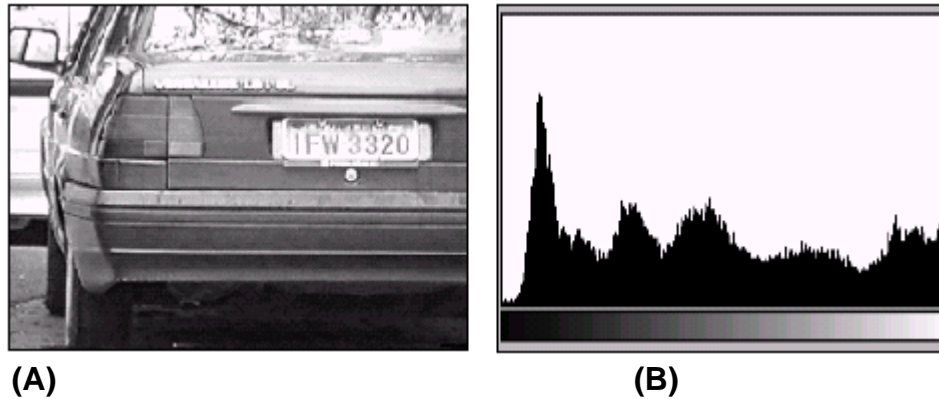
(5)

No caso da Figura 12 $[a, b]$ tem o valor de $[0, 60]$. $[A, B]$ será usado como $[0, 255]$ para expandir ao máximo o histograma. Colocando os valores na fórmula anterior tem-se:

$$i' = \frac{255 - 0}{60 - 0} (i - 0) + 0 = \frac{255}{60} i = 4,25i$$

Então para alterar o contraste da Figura 12, deve-se multiplicar qualquer valor de i por 4,25. A Figura 13 mostra o resultado da equalização da Figura 12.

Figura 13 – Imagem equalizada (A) e seu histograma (B), [48]



2.1.3 Segmentação

A segmentação é responsável por dividir a imagem, separando as partes interessantes ao sistema. Esse processo pode ser repetido várias vezes, retirando a cada execução elementos da imagem que não interessam ao processo, sendo que seu objetivo é isolar o elemento procurado. O algoritmo de segmentação, para as imagens monocromáticas, é geralmente baseado em descontinuidades ou similaridades entre pixels [48]. O primeiro algoritmo faz a segmentação da imagem verificando a mudança de níveis de cinza, sendo muito utilizada para a detecção de pontos isolados, linhas e bordas da imagem. O segundo algoritmo faz a segmentação verificando regiões da imagem que possuem o mesmo padrão, como cor ou textura. Esses algoritmos podem utilizar técnicas de limiarização, crescimento, divisão e fusão de regiões [16]. Os algoritmos de segmentação baseados em limiarização, detecção de bordas e orientados por região serão descritos a seguir.


A limiarização é utilizada quando o elemento procurado na imagem possui um fundo contrastante, isto é, quando o valor do pixel analisado for diferente do valor do limiar, sendo considerado parte do elemento. Uma imagem limiarizada $g(x,y)$ é definida pela Equação 6.

$$G(x,y) = \begin{cases} 1 & \text{se } f(x,y) \geq T \\ 0 & \text{se } f(x,y) < T \end{cases} \quad (6)$$

O $f(x,y)$ é o valor correspondente ao nível de cinza da imagem nos pontos x e y . Os pixels pertencentes ao objeto são rotulados como 1, os pixels pertencentes ao fundo são rotulados como 0 e T é o valor predefinido de um tom de cinza denominado como limiar ou *threshold*.


A segmentação por limiarização pode ser feita completa ou parcial. Na completa é definido um limiar global e a segmentação é feita na imagem de entrada [48]. Na figura 14 pode-se ver a imagem com um fundo contrastante e seu histograma.

Figura 14 – Imagem (a) e seu histograma (b), [48]



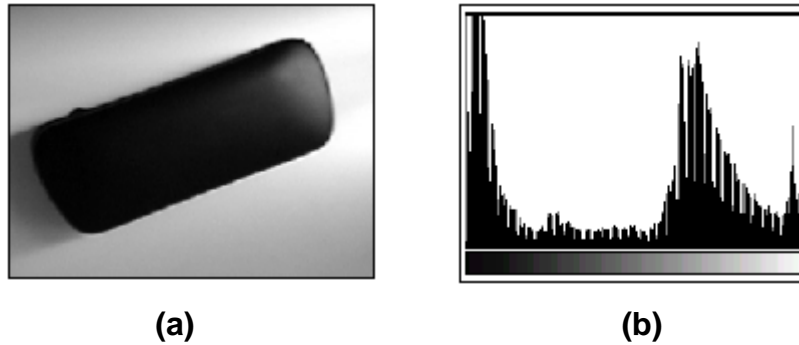
Na figura 15 foi escolhido um limiar global e foi realizado a limiarização da imagem, pode-se ver que a segmentação da imagem foi bem sucedida.

Figura 15 – Imagem segmentada (a) e escolha do limiar (b), [48]



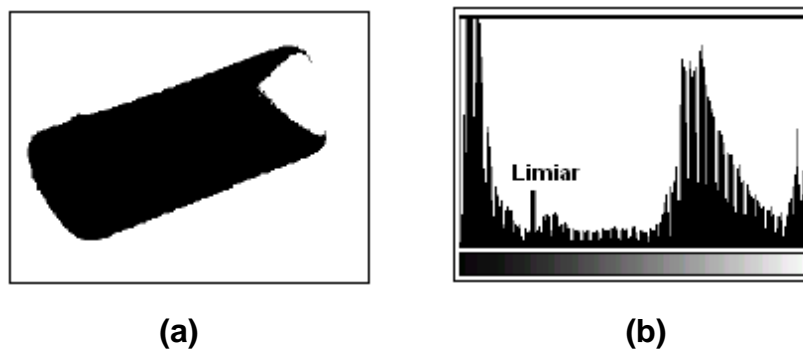
Na parcial a imagem é dividida em parte que possuem propriedades comuns, como brilho e cor, e um limiar parcial é escolhido para cada parte. Na figura 16 pode-se perceber que a imagem possui iluminação diferente em determinadas partes, então a escolha de um limiar global não segmentará a imagem com o resultado pretendido.

Figura 16 – Imagem (a) e seu histograma (b), [48]



A Figura 17 mostra a segmentação da imagem e o valor do limiar escolhido, pode-se perceber que a segmentação realizada não obteve o resultado pretendido.

Figura 17 - Imagem segmentada (a) e escolha do limiar (b), [48]



Para melhorar a segmentação pode-se utilizar um limiar para cada área da imagem e concatenar os resultados posteriormente

Além da limiarização no modelo de tons de cinza também é possível aplicar esse processo em outros modelos de cores como RGB e $L^*a^*b^*$, onde um ou vários limiares podem ser definidos. Este tipo de técnica tem vantagens quando se quer separar um objeto pela sua cor ou luminância.

Após a realização da segmentação a imagem deve ser representada para que elemento encontrado possa ser analisado posteriormente. A representação pode ser feita através da representação das características externas (como bordas), ou de suas características internas.


A característica externa é geralmente utilizada quando o formato do elemento é necessário, e a interna quando o interesse está em sua textura, cor e outras características

A detecção de bordas permite detectar as discontinuidades existentes na imagem, destacando os contornos de objetos através da aplicação de uma máscara que identifica locais de mudanças significativas de contraste na imagem. As mudanças podem ser descritas basicamente pelo conceito de derivada.

Existe uma grande quantidade de técnicas para detecção de bordas, desde as mais clássicas as mais inovadoras, mas praticamente todas possuem a mesma idéia central, encontrar variação de cores ou luminosidade entre pixels vizinhos, pois uma borda em uma imagem nada mais é do que a variação de contraste em uma imagem, definindo assim o contorno do objeto.

O operador de sobel é um algoritmo popular que destaca as bordas dos objetos existentes na imagem. Ele consiste na aplicação de duas pequenas máscaras, onde a primeira é utilizada para o cálculo da derivada em função de x , o G_x e a segunda é utilizada para o cálculo da derivada em função de y , o G_y , ambas respectivamente apresentadas pelas Equações 7 e 8. A figura 18 mostra a aplicação do operador de sobel sobre a imagem Lena.

Figura 18 – Operador de Sobel aplicado a imagem Lena (Figura 2)



As bordas são destacadas pelo cálculo da magnitude do gradiente das derivadas de x e y através da Equação 9. A direção do gradiente pode ser estimada através da Equação 10, conhecida como imagem Θ de origem.

$$G_x = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \times I \quad (7)$$

$$G_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \times I \quad (8)$$

$$G = \sqrt{(G_x)^2 + (G_y)^2} \quad (9)$$

$$\Theta = \arctan\left(\frac{G_y}{G_x}\right) \quad (10)$$

A segmentação orientada a regiões pode ser dividida em duas formas básicas: Crescimento de regiões por agregação de pixels; e Divisão e união de regiões.

No crescimento de regiões são plantadas sementes em pontos da imagem e a partir deles a região irá crescendo anexando pixels que possuem certa similaridade a cada semente até que todos os pixels da imagem pertençam a alguma região.

Na divisão e união de regiões a imagem é dividida em um conjunto aleatório e disjunto de partes que a partir de similaridades irão se unindo, até não ser mais possível encontrar regiões similares [42].

O algoritmo de Mumford & Shah [37] é um algoritmo de segmentação de imagens baseado no crescimento de regiões, sendo uns dos mais utilizados na área de processamento de imagem. Seu funcionamento consiste na análise da função de energia, descrita na Equação 11, onde as regiões possuem um comportamento elástico definido pela função, onde esses grupos de pixels caracterizando pedaços de borracha são soltos sobre os pontos iniciais, denominados sementes, e começam a ser esticados sobre as regiões. A fusão de áreas pode ser utilizada quando a borracha possui elasticidade de abranger mais *pixels* que são pertencentes a outra borracha.

$$E(u, K) = \int_{\Omega} \|u - g\|^2 dx dy + \int_{\Omega/K} \|\nabla u\|^2 dx dy + \lambda \quad (11)$$

Seu funcionamento tem como base a variância dos tons de cinza da imagem, assim quanto maior a variância do tom de cinza maior e mais difícil é a união de regiões. Os termos da funcional de energia de Mumford & Shah são descritos a seguir:

$E(u, K)$	Energia funcional de Mumford & Shah
Ω	Domínio da Imagem
Ω_i	Região Sensata (<i>Piece-wise</i>)
$u(x, y)$	Função diferenciável dentro de cada região
$g(x, y)$	Intensidade de Luz
K	Fronteira entre regiões
λ	Parâmetro de escala
$l(K)$	Comprimento dos arcos das bordas

A aplicação do algoritmo de Mumford & Shah pode ser visto na Figura 19, onde o $\lambda = 1400$ define o parâmetro de escala, onde quanto maior o valor maior será a contribuição desse termo para o valor da energia.

Figura 19 – Resultado da aplicação do algoritmo de Mumford & Shah à Lena



Outra técnica de segmentação utiliza a morfologia matemática que tem como base o conceito da álgebra, como teoria dos conjuntos e reticulados completos, e da geometria, como translação, conexidade e distância, sendo estudada pela área de processamento e análise não linear de imagens digitais.

Por seu reconhecido poder a morfologia matemática é uma ferramenta utilizada para processamento e análise de imagem em diversas áreas, tais como, mineralogia, histologia, análise de imagens médicas, análise de documentos e visão computacional, além de realizar processo como realce, filtragem, segmentação, esqueletização e outras afins.

Seu funcionamento consiste na análise geométrica de uma imagem através de casamentos entre a imagem principal e pequenos padrões, chamados de elementos estruturantes, em diversas regiões da imagem. Com a variação destes padrões é possível realizar a extração de características numéricas úteis.

Apesar de originalmente ser desenvolvida para trabalhar com imagens binárias sua evolução durante anos fez com que existissem variações que trabalham com imagens em tons de cinza e coloridas. A diferença está na forma de trabalhar com os valores dos pixels. Na operação de imagens binárias são trabalhados com os pixels pretos que são identificados pelos seus índices de linha e coluna a partir de um ponto no espaço bidimensional, como por exemplo, $A=\{(1,1),(3,3),(7,3)\}$, onde a mudança de um valor de um pixels significa a mudança da cor dele, como de preto para branco. Na imagem colorida e em tons de cinza as operações de conjunto realizadas não implicam na retirada ou inclusão de um pixel, mas sim na modificação parcial de seu valor, sendo seu valor representado por três elementos, sendo os dois primeiros as coordenadas do pixel e o terceiro a cor do pixel.

Para aplicação dos testes com morfologia matemática foi utilizado a toolbox *pymorph* com suas funções *mmero* e *mmdil*, que respectivamente realizam a erosão e a dilatação da imagem. Com a aplicação sobre imagens binárias a dilatação expande a objeto acrescentando uma borda sobre o objeto. A erosão diminui o objeto retirando a borda do objeto. Através da função *mmtoggle* é calculado o resultado da dilatação menos o resultado da erosão, assim restando a borda do objeto.

Outras funções podem ser utilizadas para melhorar os resultados, a função *mmareaopen* e *mmareaclose* que respectivamente remove os pixels isolados enquanto o outro preenche pequenas falhas de conectividade entre os pixels. Na morfologia matemática o *mmareaopen* é denominado como algoritmo de abertura e o *mmareaclose* algoritmo de fechamento. Para encontrar o esqueleto do objeto foi utilizada a função *mmthin*, que consegue definir a estrutura do objeto.

2.1.4 Representação e Descrição

Após a segmentação os dados são representados por vários conjuntos de pixels, denominado *raw pixel data*, definindo as fronteiras existentes na imagem. Realizar comparação, verificação de similaridades e busca de padrões nesta grande quantidade de pixels gera um altíssimo custo computacional, assim a criação de alguns descritores facilita o processo. Estes descritores irão definir quais as partes segmentadas são importantes para uma tarefa específica e a informação contida neles pode ser quantitativa, como tamanho de área ou informações estatísticas como coloração média, entre diversos outros tipos de atributos extraídos. Esta etapa pode ser chamada de seleção de atributos.

2.1.5 Reconhecimento e Interpretação

Nesta etapa com base nas informações fornecidas pelos descritores são atribuídos rótulos aos objetos encontrados, assim possibilitando que um conjunto de objetos reconhecidos seja interpretado, isto é, sejam atribuídos significados a eles. Para isso são aplicadas técnicas de inteligência artificial ou estatísticas sobre os descritores identificando padrões ou objetos esperados.

3 RECONHECIMENTO DE PADRÕES

Definir padrões visuais é de extrema importância em atividades que têm como objetivo correlacionar objetos [5, 1, 56, 36], ou seja, encontrar similaridades visuais ou conceituais entre diferentes elementos determinando as relações existentes entre eles. Essas similaridades podem ser determinadas através da procura de padrões específicos, sendo que o grau de dificuldade desta atividade está diretamente relacionado com a quantidade de itens e a complexidade das relações procuradas [5].

Os objetos podem ser uma imagem, um sinal de onda ou qualquer outra medida. No presente caso estes objetos são sinais bidimensionais, isto é imagens digitais. Os estudos de reconhecimento de padrões acontecem a muito tempo, mas antes de 1960 eram responsabilidades dos profissionais de estatísticas que através de estudos formulavam teorias nesta área.

Quando a procura de padrões é executada por uma pessoa as definições de características podem estar sujeitas a uma análise subjetiva [7, 36, 54, 57], pois a sua percepção é influenciada pela sua educação e a sociedade em que vive [49], assim em diferentes povos e culturas a análise de correlação pode resultar em diferentes resultados.

Visando a eliminação da análise subjetiva, encontrar padrões visuais em objetos tem sido alvo de constantes pesquisas na área computacional [41, 57, 1, 43, 2], pois a utilização de técnicas de processamento de imagem e inteligência artificial potencializam a realização desta tarefa garantindo maior eficiência e otimização do resultado esperado.

Com a criação dos computadores foi possível desenvolver e colocar em prática as teorias definidas e após o período pós-industrial o reconhecimento de padrões está se tornando importante nas aplicações de engenharia e pesquisas científicas, pois suas aplicações fazem parte das maiorias dos sistemas inteligentes que tem como objetivo tomar decisões. A visão artificial através do computador tem sido muito importante nas aplicações de reconhecimento de padrões.

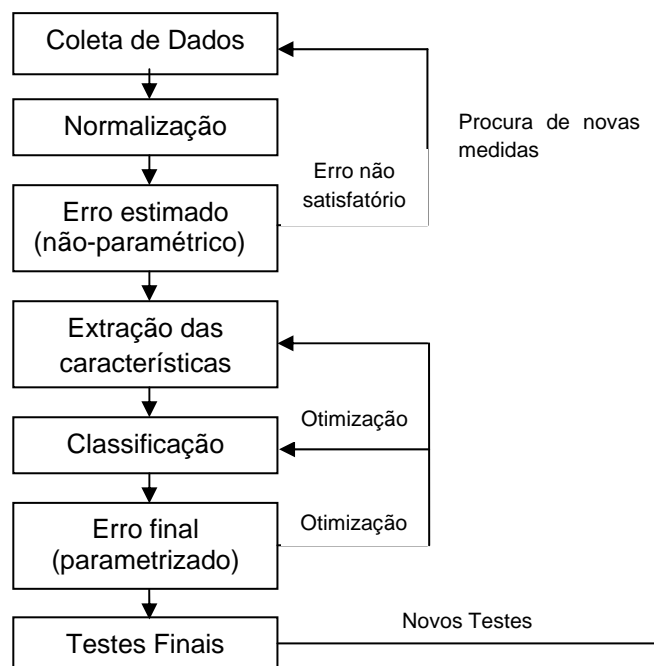
Na área de processamento de imagem a visão computacional tem desempenhado um papel fundamental no auxílio e melhoria do reconhecimento de padrão. Uma aplicação típica da utilização destes recursos está nas indústrias de transformação na qual a montagem e a inspeção visual são realizadas de forma

automática. Por exemplo, em uma indústria em que os objetos percorrem as etapas de fabricação através de uma esteira até chegarem na estação de inspeção, que através de uma câmera captura a imagem do objeto para ser definido o seu padrão, como cor e formato, e posteriormente comparados com o padrão necessário. Assim, podendo descartar ou não automaticamente o objeto fabricado.

Também pode-se destacar a extrema importância dessa técnica na agricultura, pois a definição de padrões visuais de tamanho e cor em plantas, como flores, folhas, frutos e sementes são alvo de estudos constantes para a melhoria das culturas vegetais, visto que tais padrões estão relacionados a qualidade e quantidade dos produtos agrícolas [55]. Artigos que exploram a busca de padrões através da análise de imagens em flores são abordados em [57, 55, 41, 39, 36, 26]. Outros artigos também realizam a análise de cores em maçãs [30], tomates [7], melões [54] e em grama [25].

O termo padrão consiste em um conjunto de características ou medidas pertencentes a um objeto, coletados a partir de uma transformação, ou seqüência de transformações aplicadas sobre a imagem. Conceitualmente [15] o reconhecimento de padrão segue as etapas apresentadas na Figura 20: coleta de dados, normalização, estimação não-paramétrica do erro inicial, extração das características, classificação, estimação paramétrica do erro final, testes.

Figura 20 - Síntese do fluxograma de classificação apresentado por [15]



Para melhorar o desempenho o fluxograma do processo de classificação define algumas etapas de realimentação, visando a otimização do processo. Quando o erro obtido não é satisfatório pode-se retornar o processo para a etapa de extração de características selecionando outras formas de extração e até mesmo alterando o classificador. Após os teste finais pode-se retornar ao início do processo alterando os parâmetros de algumas etapas para tentar encontrar um melhor resultado. É importante ressaltar que o termo extração de características visa a segmentação, seleção ou combinação de dados para formar um pequeno conjunto de informações mais relevante para o reconhecimento.

As quatro melhores abordagens para o reconhecimento de padrões são [21]: *Template machine*, Estatística, Sintática, e Redes Neurais, demonstrados na Tabela 1. Esses métodos não são necessariamente independentes e alguns possuem diferentes interpretações. Modelos híbridos envolvendo vários métodos também foram projetados.

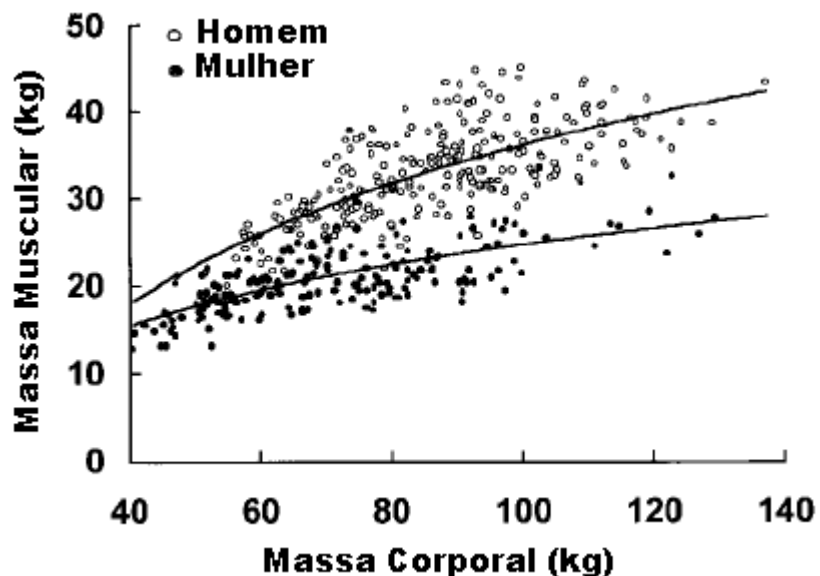
Tabela 1 - Abordagens para o reconhecimento de padrões. Adaptação de [21]

Abordagem	Representação	Função de Reconhecimento	Critério
<i>Template machine</i>	Amostras, Pixels e Curvas	Correlação e Distância	Erro de Classificação
Estatística	Características	Função Discriminante	Erro de Classificação
Sintática	Primitivas	Regras e Gramática	Erro de aceitação
Redes Neurais	Amostras, Pixels e Características	Função e Rede	Erro Médio Quadrado

A *template matching* trata-se de uma abordagem simples baseada no casamento de modelos, pois o modelo do objeto procurado está disponível possibilitando a comparação com objeto encontrado [21]. Normalmente este modelo são formas 2D, como por exemplo imagens. Para classificar o objeto deve-se conter o padrão a ser reconhecido, levando em consideração variações com translação, rotação e mudanças na escala. A medida de similaridade, geralmente, é atribuída pela correlação existente entre o modelo e o objeto encontrado, podendo ser a otimizada com base no conjunto de treinamento.

A abordagem mais abrangente é a estatística [15], que tem sido utilizada para projetar uma série de aplicações comerciais [21]. Ela consiste em formular através de um conjunto de medidas uma base estatística para que o algoritmo de classificação associe cada vetor de entrada a uma classe previamente estabelecida por um treinamento que identificou os limites que separam as classes existentes, assim reconhecendo a natureza estatística das características utilizadas para formular as classes e os resultados que devem ser expressos. Para demonstrar o conceito de fronteira de classes observam-se os dados da pesquisa de JANSSEN [22] na qual são obtidas a medida da massa corporal e massa muscular de homens e mulheres. Pode-se observar que a Figura 21 mostra a curvatura estabelecida para homem e mulher definindo assim a tendência particular de cada classe.

Figura 21 - Exemplo de definição de classes: Trabalho de JANSSEN [22] onde foi estabelecida a regra para diferenciação entre homem e mulher baseada na massa corporal e muscular



A existência de tendência viabiliza a utilização de funções discriminantes que no exemplo de JANSSEN [22] possuem como argumento as medidas de massa. Tais funções, após treinada com alguns valores de entrada, retornaram um valor que analisado por um classificador definirá se o gênero é masculino ou feminino. A modelagem do classificador depende das particularidades das classes analisadas por ele definidas na etapa de aprendizado ou treinamento.

A abordagem sintética consiste em dividir um padrão complexo em subpadrões simples que são compostos por subpadrões mais simples ainda

obedecendo a uma perspectiva hierárquica [21]. O mais simples subpadrão é chamado de primitivo. Uma analogia desta abordagem é a comparação da estrutura de padrões a sintaxe da linguagem. Os padrões podem ser vistos como uma frase, o primitivo como o alfabeto e subpadrões intermediários como a gramática da linguagem. Assim um pequeno número de primitivas e regras gramaticais pode definir uma coleção de padrões complexos. Sua abordagem vem sendo utilizada em problemas cujo padrão procurado tem estrutura definida e que pode ser definido por um conjunto de regras, tais como busca de textura, forma e análise de contornos.

As redes neurais podem ser vistas como um sistema de computação paralelo composto por um número extremamente grande de processadores simples com muitas interconexões [21]. A principal característica desta abordagem é que ela consegue apreender relações complexas não lineares. As técnicas mais utilizadas no reconhecimento de padrões é a *feedforward* (sem retroalimentação), *Perception Multicamadas* e a *Radial Basis Function* (RBF). Outras como *Self-Organizing Map* (SOM) e a *Rede de Kohonen* são utilizadas principalmente para agrupamento de dados e mapeamento de recursos. Seu funcionamento consiste em estabelecer uma arquitetura e pesos para as conexões tornando a rede utilizada capaz de classificar ou agrupar corretamente as classes. Esse tipo de abordagem vem se tornando popular graças a eficiência dos algoritmos de aprendizagem utilizados.

3.1 EXTRAÇÃO DAS CARACTERÍSTICAS

Extrair características é encontrar funções que quantifiquem uma ou mais medidas de uma propriedade de um objeto [42]. Em se tratando de extrair características de uma imagem os métodos de extração de características possuem as habilidades de extrair características e também de reduzir a dimensionalidade dos dados gerando conjunto de n características que, juntas, formam o vetor de características. Seu funcionamento consiste em simplificar um conjunto de dados descrevendo um grande conjunto com mais precisão. Quando se analisa uma grande e complexa quantidade de dados maior é a complexidade e os problemas computacionais, pois ao analisar uma gama muito grande de variações numéricas pode ser necessário uma grande quantidade de memória e um alto poder de processamento muitas vezes conduzindo o algoritmo de classificação a gerar uma quantidade grande de classes ou classes desnecessárias. Os descritores analisados

pela extração das características são resultando do processo de representação da imagem descrito anteriormente.

Em BROWN [3] é apresentada uma taxonomia das características mais utilizadas no processo de extração das mesmas, agrupando-os em seis espaços. A Tabela 2 sumariza os grupos definidos por BROWN [3], sendo que a utilização de uma ou mais técnicas em conjunto podem otimizar o resultado esperado.

Pode-se destacar a utilização das características estatísticas como histograma, média e desvio padrão, que por representarem um comportamento mais global são adequadas para inicializar o processo de seleção ou eliminação dos candidatos. Já para a busca por similaridades é recomendado à utilização das características baseadas na intensidade dos pixels.

Tabela 2 - Taxonomia dos espaços de características [3]

Espaço de Características	Características
Intensidade Bruta	Baseia-se na intensidade dos pixels
Bordas	Estrutura intrínseca, menos sensíveis ao ruído. Aplicado em bordas, contornos e superfícies.
Características salientes	Estrutura intrínseca. Posicionamento preciso. Abrange curvatura, centro de gravidade, interseção de linhas e descritores de Fourier.
Características Estatísticas	Utiliza todas as informações. Obtêm bons resultados para transformações rígidas, as suposições. Abrange dispersão espacial, momentos invariantes e centróide / principais
Características de alto nível	Utiliza relações e informações de alto nível, bons resultados para correspondência local. Abrange características estruturais (grafos), sintáticas (gramáticas) e redes semânticas (regiões de cena e suas relações).
Matching ² versus Modelo	Estrutura intrínseca e precisa, o ruído em uma única imagem. Abrange atlas anatômico, mapa geográfico modelo do objeto.

² Método de segmentação utilizado quando se conhecem os objetos ou estruturas presentes na imagem. Trata-se de procurar na imagem uma instância de um modelo pré-determinado.

3.2 PRÉ-PROCESSAMENTO E REDUÇÃO DE DADOS

A fase de pré-processamento realiza a padronização e redução dos dados para que o algoritmo classificador realize sua função. Esta é uma etapa indispensável, pois seu resultado influencia no desempenho da classificação. Ele é dividido em cinco etapas: limpeza dos dados, tratamento dos valores omissos, amostragem, seleção de características e discretização.

3.2.1 Limpeza dos Dados

Esta etapa é necessária para eliminar possíveis erros de alimentação ou armazenamento na base de dados que será analisada. A detecção deve ser realizada levando em consideração a forma que o dado é coletado e armazenado. Quando o erro é ocasionado pela alimentação dos dados através de um humano é possível identificá-lo através da análise e comparação dos dados cadastrados com os valores normalmente freqüentes para aquele campo. Em caso dos valores serem coletados por sensores, pode-se levar em consideração a geração de ruídos a medição pelo equipamento, onde dependendo da natureza do sinal diversos filtros podem ser aplicados para reduzir ou eliminar o ruído. Também pode-se realizar a limpeza de dados eliminando cadastro repetidos ou representações de dados heterogenias, expressa em diferentes unidades.

3.2.2 Tratamento de Valores Omissos

Ao encontrar valores omissos é necessário realizar a verificação para diagnosticar se aqueles campos não estão definidos porque existe alguma impossibilidade lógica ou se existe uma inconsistência no cadastro, pois o campo deveria estar preenchido. No primeiro caso pode-se aplicar um valor indicando o status do campo ou eliminar este registro, pois alguns algoritmos de classificação não conseguem trabalhar com valores omissos. No segundo caso, além da eliminação pode-se tentar outra solução menos radical, porém mais difícil, encontrar através de comparações com registros parecidos o valor a ser inserido no campo ou, mais simples, substituí-lo pela média ou pela moda dos valores do atributo, lembrando que essas soluções podem influenciar no resultado da classificação.

3.2.3 Amostragem (Sampling)

Utilizados todos os dados disponibilizados para a classificação pode gerar um tempo elevado de processamento e necessitar de um poder computacional muito alto. Outro problema é que vários algoritmos de classificação possuem limites quanto ao número de casos que conseguem tratar, em contra partida muitos desses algoritmos possuem resultados bastante aceitáveis quando treinado com um subconjunto dos dados disponibilizados. Para solucionar esse problema é necessário recorrer a técnicas de redução de dados, selecionando uma amostragem dos dados.

Existem duas técnicas para selecionar a amostra de dados, a estática e a dinâmica. A amostragem estática tenta deixar o subconjunto com as mesmas características do conjunto completo enquanto a dinâmica visa o desempenho do algoritmo de classificação utilizado. A amostragem dinâmica possui melhor desempenho do algoritmo de classificação se comparado com a amostragem estática [23]. A forma de escolha de cada indivíduo pode ser classificada como aleatória ou seletiva, onde na primeira todos os dados têm a mesma probabilidade de serem escolhidos e na segunda cada registro possui uma classificação dará a ele maior ou menor vantagem no processo de seleção.

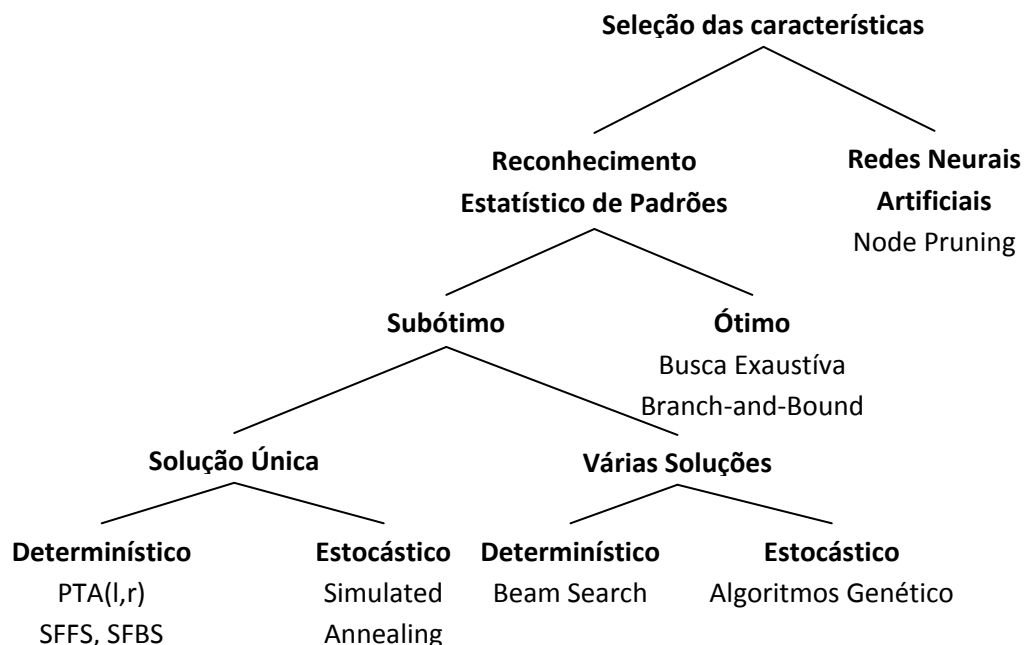
3.2.4 Seleção das Características

Para aumentar a eficiência do sistema de classificação e reduzir custos computacionais é necessário definir quais características serão analisadas [21]. Nesta etapa nenhuma nova característica será criada, apenas serão selecionadas as características mais representativas e descartadas as menos importantes. É importante salientar que o excesso de características pode prejudicar o resultado, visto que alguns algoritmos de classificação possuem limitações a quantidade de descritores utilizados. Neste caso é importante utilizar um método automático para selecionar um subconjunto que será utilizado na etapa de classificação, visando à otimização do resultado e um melhor desempenho do algoritmo.

Além da técnica de redução de dimensionalidade o algoritmo poderá realizar a fusão dos dados, que acontece quando duas ou mais características

apresentam as mesmas características variação de valores. A seleção pode ser realizada por métodos supervisionados ou não supervisionados [29]. Os métodos supervisionados são métodos estáticos baseados na busca do resultado por exaustão, enquanto o não supervisionado é baseado em heurística e não se sabe a influência de cada característica no resultado final sendo que a seleção é realizada baseada na correlação entre as características. Pode-se dividir os métodos de seleção em dois grupos [23]: os filtros e wrappers, onde os filtros são aplicados antes da fase de classificação e os wrappers selecionam as características visando o melhor desempenho do algoritmo de classificação. A taxonomia dos métodos seleção de características segundo [21] é apresentada na Figura 22, onde os algoritmos são divididos em duas grandes classes, as dos métodos estatísticos e os que utilizam redes neurais.

Figura 22 - Adaptação da Taxonomia de seleção das características segundo [21]



Em aplicações de redes neurais *Node Pruning* ou “corte de nós” é um método de seleção que através de uma rede *Perceptron MultiCamadas* com retro-alimentação tenta-se eliminar várias características de uma vez e realizar um novo treinamento com as características restantes através de um algoritmo de aprendizado baseado em retro-propagação (*backpropagation*). É utilizado para

eliminação dos nós o valor de saliência, assim os nós menos saliente são eliminados, sendo que a saliência de um nó é a soma do aumento do erro com a remoção daquele nó. É necessário remover uma característica por vez e realizar imediatamente o re-treino [32]. Isso acontece, pois a eliminação de uma característica do conjunto pode ser irrelevante, mas sua ausência pode aumentar a importância de outra característica. A execução dos treinamentos sucessivamente a cada exclusão aumentará o custo computacional.

Para obter realmente a melhor qualidade no conjunto de características o único método é o exaustivo. A busca exaustiva consiste no teste de todas as combinações possíveis para determinar qual o conjunto de características é o mais relevante. Sua deficiência está na procura da melhor configuração em uma grande quantidade de características, pois sua complexidade é da ordem de 2^n-1 , sendo n o número de características. Sua complexidade pode reduzir quando definimos o número máximo de características por conjunto. Um método guloso pode ser aplicado eliminando as características menos relevantes sucessivamente a cada interação, isso melhorará o tempo de respostas, mas não garantirá o retorno do melhor conjunto. Um método não exaustivo que garante o melhor resultado é o Branch and Bound [15].

Utilizada para encontrar a solução ótima de problema de otimização NP - difíceis o algoritmo de Branch na Bound percorre uma árvore de enumeração a procura de soluções, o que permite que o algoritmo desenvolvido utilize paralelismo, pois a análise de sub-árvores podem ser realizadas de modo quase independente. Seu funcionamento consiste em achar a solução para um subproblema (nó) e a partir da solução deste subproblema achar a melhor solução, dividindo iterativamente a árvore em subproblemas mais fáceis de serem resolvidos que o problema original. A definição de limites para a solução ótima irá limitar o crescimento da árvore. Baseado nisto pais terão valores maiores que os filhos, assim pode-se destacar toda uma sub árvore descendente de um pai, já sabendo que o valor encontrado não é desejado, mesmo assim no pior caso sua complexidade é da ordem de 2^n-1 .

Os métodos estocásticos com múltiplas soluções trás diferentes conjuntos de soluções que obtiveram um bom resultado pela avaliação da função critério. Uma característica importante é que a cada vez que é executado o algoritmo

fornece soluções diferentes da anterior. Neste tipo de solução são utilizados algoritmos genéticos [47].

Nesta abordagem o conjunto de característica é representado um uma cadeia, chamada de cromossomo, de tamanho N formado por números binários, onde o 0 representa a ausência da característica na solução. Para iniciar o processo uma população de cromossomos é gerada aleatoriamente e cada um é avaliado por uma função de aptidão denominada *fitness*, a qual define se os cromossomos deverão sobreviver ou morrer na próxima geração. A criação de novos cromossomos é feita por cruzamento e mutações.

Após vários cruzamentos a aptidão da geração será melhorada até que o critério de parada seja atingido. O melhor cromossomo pertencente a geração otimizada será utilizado como referência para a seleção das características.

Diferentemente do método estocásticos o método determinístico sempre apresenta as mesmas soluções a cada execução. Entre vários métodos alguns utilizam-se de um grafo para representar o espaço das características, onde cada nó representa um sub-conjunto e a aresta a relação entre os sub-conjuntos. Para encontrar a melhor configuração utiliza-se algoritmos de busca em grafo, onde pode destacar o *beam search* que utiliza o algoritmo *Best-first search* para construir a sua árvore de busca [47].

Entre os métodos estocásticos com solução única pode-se destacar a técnica de *Simulated Annealing* que é uma analogia da termodinâmica entre o modo como um metal com alta temperatura se resfria gradativamente várias vezes até a sua solidificação numa estrutura cristalina de energia mínima. Na área computacional esse conceito foi utilizado para procurar soluções ótimas, evitando os ótimos locais. Seu funcionamento consiste em gerar uma solução inicial qualquer e a cada interação gerar um único vizinho. A variação da função objetivo é testada a partir da relação dos vizinhos, que pode ser aceito a partir da probabilidade dependente de T , chamado de temperatura. O processo é repetido até que o valor de T se torne irrisório para aceitar um vizinho, assim encontrando o mínimo local, com isso a T é decrementada e o processo é realizado novamente.

Outro método existe para seleção de características são os algoritmos determinísticos com solução única. Seu funcionamento basicamente é baseado em busca, onde a maioria possui duas abordagens: para frente (*botton-up*) e para trás (*top-down*). Na abordagem para frente é iniciado um conjunto de

características vazias e a cada interação a partir de um critério será incluindo um novo membro neste conjunto até que ele possua um tamanho específico. Na seleção para trás inicia-se um conjunto com todas as características e a partir de um critério deve-se retirar uma a uma até que o conjunto possua um tamanho determinado. Em geral pode-se afirmar que o algoritmo para frente é mais rápido que o para trás, pois o custo para calcular a função critério para conjuntos grandes é maior do que para conjuntos pequenos. Quando o tamanho do conjunto esperado é próximo ao número de características é preferível utilizar o algoritmo para trás. Em ambos os casos pode acontecer o efeito *nesting*, que é quando uma característica importante não foi atribuída ao subconjunto ótimo.

O método PTA(l,r), *Plus l – Take Away r*, foi desenvolvido para tentar eliminar *nesting*. Seu funcionamento baseia-se na utilização da seleção para frente e para trás, onde inicialmente um conjunto nulo é gerado e é incluído l elementos e em seguida é retirado r elementos, onde o l e o r são definidos anteriormente. Para seu funcionamento correto o valor de l deve ser maior que o valor de r .

3.3 DISCRETIZAÇÃO

A quantidade de valores distintos que um atributo pode apresentar influencia significativamente na qualidade de alguns algoritmos de classificação, assim a discretização tem como objetivo transformar valores contínuos em intervalos. Uma comparação empírica de vários métodos de discretização conclui que a discretização não só melhora significativamente o desempenho dos algoritmos afetados por esse problema como também melhora o resultado dos algoritmos menos sensíveis ao mesmo [10].

Existem duas classes de métodos de discretização a não supervisionada e a supervisionada. A primeira as classes são particionadas em intervalos iguais. O risco de utilizar essa técnica é que pode ocorrer acúmulo de instâncias em uma classe. No segundo existe uma correlação entre a classe e o atributo, sendo que o valor discriminante do atributo deverá ser mantido.

3.4 MODELOS E ALGORITMOS DE APRENDIZAGEM

A inteligência artificial é uma área de ciência da computação que iniciou seu desenvolvimento logo após a segunda guerra mundial, assim possui anos de evolução, devido a isso existem muitos estudos que geraram algoritmos de aprendizado com diversos objetivos, características e aplicações. Por causa disso foi necessário especificar quais algoritmos esta dissertação irá estudar. Assim, definiu-se pelo estudo da ferramenta Waikato Environment for Knowledge Analysis (WEKA), uma vez que ela possui um grande conjunto de algoritmos de classificação, associação e clustering, sendo possível a sua utilização para a classificação e avaliação dos problemas apresentados por esta dissertação. Nesta seção serão apresentados os vários modelos e algoritmos de aprendizagem disponíveis no WEKA, que são divididos em modelos de classificação, de associação e de clustering [53].

3.4.1 Modelos de Classificação

O WEKA possui métodos para a classificação de dados divididos em: tabela de decisão, árvore de decisão, regras de classificação, aprendizagem baseado em instância, redes bayesianas e funções. Cada categoria apresenta um gama de algoritmos destinado a classificação dos dados, sendo cada tópico explicado a seguir.

Na tabela de decisão os atributos de saída são representados na mesmo forma dos atributos de entrada, ou seja, uma tabela. Nela são apresentadas qual o conjunto de condições que é necessário ocorrer para que um determinado conjunto de ações deva ser executado. É considerada a forma mais simples e rudimentar de representar a informação de saída da máquina de aprendizado. A Tabela 3 apresenta uma tabela cujo objetivo é determinar em quais condições meteorológicas deve-se jogar um jogo.

No exemplo da Tabela 3 é apresentada uma tabela de decisão onde, após o treinamento, de acordo com a previsão do tempo deverá se decidido se irá acontecer o jogo. Este caso possui quatro atributos: tempo, temperatura, umidade e o vento e um atributos de saída denominado jogar. O algoritmo tentará encontrar quais as características dos atributos são relevantes para a decisão de jogar ou não.

Tabela 3 - Condições do tempo. Adaptação da Tabela 1.2 de [53]

Tempo	Temperatura	Umidade	Vento	Jogar
Ensolarado	Calor	Alta	Não	Não
Ensolarado	Calor	Alta	Sim	Não
Nublado	Calor	Alta	Não	Sim
Chuvoso	Média	Alta	Não	Sim
Chuvoso	Frio	Normal	Não	Sim
Chuvoso	Frio	Normal	Sim	Não
Nublado	Frio	Normal	Sim	Sim
Ensolarado	Média	Alta	Não	Não
Ensolarado	Frio	Normal	Não	Sim
Chuvoso	Média	Normal	Não	Sim
Ensolarado	Média	Normal	Sim	Sim
Nublado	Média	Alta	Sim	Sim
Nublado	Calor	Normal	Não	Sim
Chuvoso	Média	Alta	Sim	Não

A partir da tabela de decisão é gerado um conjunto de regras, demonstrado na Figura 23, que são interpretadas em seqüência, seguindo a ordem que é apresentada, sendo que quando uma regra for verdadeira as demais serão desconsideradas, pois as regras são exclusivas.

Figura 23 - Conjunto de regras adaptado do WEKA, geradas pelo algoritmo de tabela de decisão baseada nos dados da tabela 3

Se Tempo = Ensolarado e Umidade = Alta então Jogar= Não
Senão Se Tempo = Chuvoso e Vento = Sim então Jogar= Não
Senão Se Tempo = Nublado então Jogar=Sim
Senão Se Umidade = normal então Jogar=Sim
Senão Jogar=Sim

É importante ressaltar a importância de manter a estrutura do conjunto de regras, pois se for levado em consideração apenas uma regra ou a ordem das regras forem alteradas, é muito provável que aconteça erros na classificação.

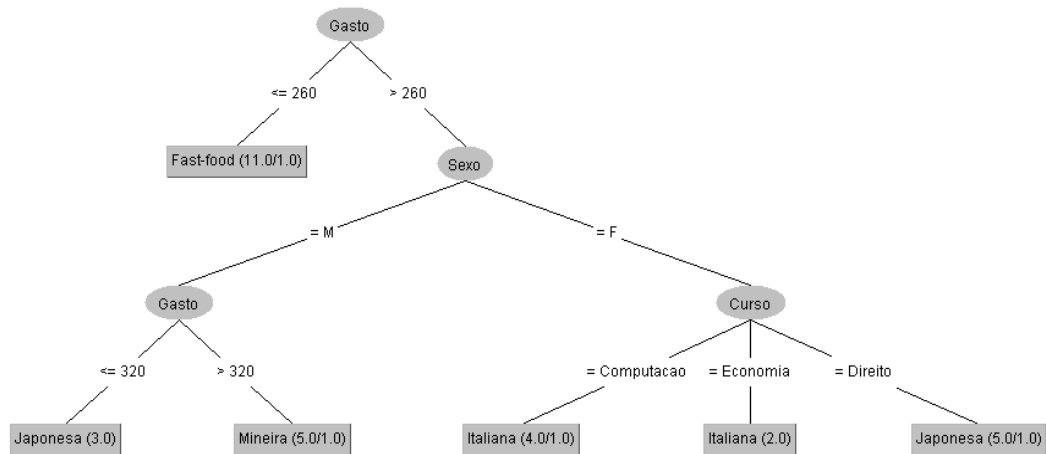
Os algoritmos baseados em árvore de decisão apresentam seus resultados em forma de uma árvore, composta por nós que representam os atributos

e arestas que associa um atributo a outro. A partir do nó raiz inicial, através das arestas o algoritmo vem percorrendo os nós descendentes testando os atributos até encontrar um nó folha que representa o resultado do processo de classificação. É considerado uma aproximação do divide-and-conquer, pois a medida que o classificador percorre a árvore o número de possibilidade diminui até chegar em uma solução única.

Geralmente o nó representa um teste de um atributo, mais existem modelos que pode-se comparar no mesmo nó um ou mais atributos e até mesmo uma função de um ou mais atributos. No caso de atributo ser nominal o número de filhos do nó é a quantidade de valores possíveis do atributo. Se o atributo for numérico normalmente o teste é realizado em cima das funções de maior que ou menor que certo valor predeterminado, assim existindo apenas duas hipóteses de escolha. E alguns casos pode-se existir três opções, maior que, menor que ou igual a certo valor. Um exemplo da árvore de decisão com atributos nominais e numéricos é demonstrada pela Figura 24.

Esse algoritmo não tem a capacidade de trabalhar com atributos nulos sendo necessário aplicar alguma técnica para validar esse registro, conforme visto anteriormente. Outro problema é a ocorrência de *overfitting*, pois o modelo consegue classificar com exatidão problemas apresentadas durante o treinamento, mas não consegue generalizar, isto é classificar corretamente qualquer valor diferente que não tenha sido treinamento, causando um erro de classificação.

Figura 24 - Árvore de decisão com atributos nominais e numéricos



A Tabela 4 apresenta vários algoritmos de classificação baseados em árvores de decisão disponíveis no *WEKA*.

Tabela 4 - Algoritmos de classificação através de Árvore de Decisão disponíveis no WEKA

Nome	Função
ADTree	Árvores de decisão alternadas
DecisionStump	Árvores de decisão de apenas um nível
Id3	Utilização do algoritmo básico de <i>divide-and-conquer</i>
J48	Utilização do Algoritmo <i>C4.5</i>
LMT	Utilização do modelo logístico
M5P	Utilização do modelo <i>M5</i>
NBTree	Utilização do classificador <i>Naive Bayes</i>
RandomForest	Construção aleatória de árvores de decisão
RandomTree	Construção de uma árvore de decisão, dado um número aleatório de atributos para cada nó
REPTree	Árvore de decisão com <i>reduced-error pruning</i>
UserClassifier	Criação de uma árvore de decisão pelo utilizador

Os algoritmos de regras de classificação são uma alternativa popular para as árvores de decisão. Cada regra é composta de uma pré-condição, ou antecedente, que é um conjunto de teste idêntico aos nós das árvores de decisão, e pela conclusão, ou conseqüente, equivalente ao nó folha da árvore de decisão. Normalmente, os antecedentes de uma regra estão associados por um E lógico, assim para que a classificação aceite aquela regra como verdadeira, todos os teste dos antecedentes devem ser verdadeiros. Pode-se observar na Figura 25 um exemplo de classificação referente aos dados da Tabela 3.

Figura 25 - Conjunto de regras adaptado do WEKA, geradas pelo algoritmo de regras de decisão baseada nos dados da tabela 3

Se (umidade = elevado) **e** (tempo = ensolarado) **então** jogar=não
Senão Se (tempo = chuvoso) **e** (vento = sim) **então** jogar=não
Senão jogar=sim

Obter um conjunto de regras a partir de uma árvore de decisão é relativamente simples. Cada nó folha da árvore seria uma regra, e os nós e aresta que servem para definir aquela classe seriam os antecedentes da regra. Assim não importa qual a ordem de execução das regras pois ela possuiria como pré-condição a caminho completo do nó raiz até o nó folha, não possuindo qualquer tipo de

ambigüidade. Esse é o motivo pelo qual as regras de classificação são tão populares, pois deve-se entender cada regra como um conjunto independente de conhecimento, afirmando a facilidade da utilização da técnica de *divide-and-conquer*, pois é possível adicionar uma nova regra ao conjunto sem perturbar as regras existente, enquanto em uma árvore de decisão seria necessário uma reestruturação da mesma. No entanto, pode acontecer de diferentes regras estabelecerem a mesmas classes e esta falta de independência pode comprometer o resultado caso fosse adicionado uma nova regra. Assim como na árvore de decisão algoritmos de regras de classificação, existe a possibilidade de *overfitting*.

Os algoritmos de regras de classificação disponíveis no WEKA encontram-se descritos na tabela 5.

Tabela 5- Algoritmos de Classificação através de Regras de Classificação disponível no WEKA

Nome	Função
ConjunctiveRule	Criação de simples regras conjuntivas
DecisionTable	Criação de uma tabela de decisão
JRip	Criação de regras rápidas utilizando o algoritmo <i>RIPPER</i>
M5Rules	Criação de regras a partir de árvores obtidas a partir de modelos <i>M5</i>
Nnge	Criação de regras utilizando o algoritmo <i>Nearest-neighbor</i>
OneR	Utilização do classificador <i>1R</i>
Part	Criação de regras a partir de árvores de decisão obtidas com o algoritmo <i>J4.8</i>
Prism	Utilização de um algoritmo de cobertura simples
Ridor	Criação de regras a partir do método <i>Ripple-down</i>
ZeroR	Predição da classe predominante (se for nominal) ou do valor médio (se for numérico)

Os modelos baseados em Instância partem do princípio que memorizar é a forma mais simples de aprendizado, pois memorizando um conjunto de instância de treino, é possível classificar uma nova instância realizando uma pesquisa da instância que mais se aproxima a ela. Com isso é possível notar que a forma de aprendizado é diferente das anteriores pois basta memorizar as instância de treinamento e quando necessário realizar uma classificação de uma nova instância deve-se encontrar a mais próxima através de uma métrica de distância. Ao contrário dos processos anteriores onde é necessário gerar regras de classificação, ou seja, novo conhecimento, neste tipo de modelo as próprias instâncias representam o conhecimento. Outra diferença é que o trabalho de classificação é

realizado na fase de comparação das instâncias, enquanto nos outros modelos o maior trabalho é na fase de treinamento, assim do modelo baseado em instância a aprendizagem é na fase de classificação e não previamente.

Este tipo de classificação é denominada *nearest-neighbor*, pois o objetivo é determinar qual instância se aproxima mais da nova instância. Outra técnica utilizada é a *k-nearest-neighbor*, que acontece quando o objetivo é determinar as k instâncias mais próximas da nova instância. É recomendado aplicar esse tipo de técnica quando a probabilidade de existirem instância com ruído, comprometendo a classificação, assim a opção de retornar k instância classificadas pode amenizar o erro. Quando os atributos são numéricos pode-se aplicar a distância Euclidiana, demonstrada na Equação 12, para definir a correlação com as instância. Mas no caso de atributos nominais deve-se utilizar a nomenclatura de zero para atributos idênticos e um para os restantes dos casos.

$$\sqrt{(a_1^{(1)} - a_1^{(2)})^2 + (a_2^{(1)} - a_2^{(2)})^2 + \dots + (a_k^{(1)} - a_k^{(2)})^2}, \quad (12)$$

Pode-se haver desvantagem no uso desta técnica, pois ela considera que os atributos possuem a mesma importância, o que nem sempre é verdade em casos reais. Assim, como forma de resolver esse problema, é necessário utilizar um grau de importância que reflita sobre a métrica de distância, utilizando pesos associados a cada atributo conforme a Equação 13, definindo quais os atributos mais significativos.

$$\sqrt{w_1^2(a_1^{(1)} - a_1^{(2)})^2 + w_2^2(a_2^{(1)} - a_2^{(2)})^2 + \dots + w_k^2(a_k^{(1)} - a_k^{(2)})^2}, \quad (13)$$

Outro cuidado que se deve ter é na quantidade de instância de treino que serão utilizadas. Uma grande quantidade de instância na fase de treinamento poderá acarretar na lentidão do processo e no uso exagerado de espaço de memória, sendo que cada nova instância tem que ser testada com todo o conjunto de instâncias de treino. Poucas instâncias também podem gerar problemas. O uso

de poucas instâncias não refletirá a realidade do conjunto de instância o que pode gerar uma classificação incorreta.

Para os modelos de aprendizagem baseados em instâncias, o WEKA disponibiliza os algoritmos descritos na Tabela 6.

Tabela 6 - Algoritmos de Classificação baseados em Instâncias disponíveis no WEKA

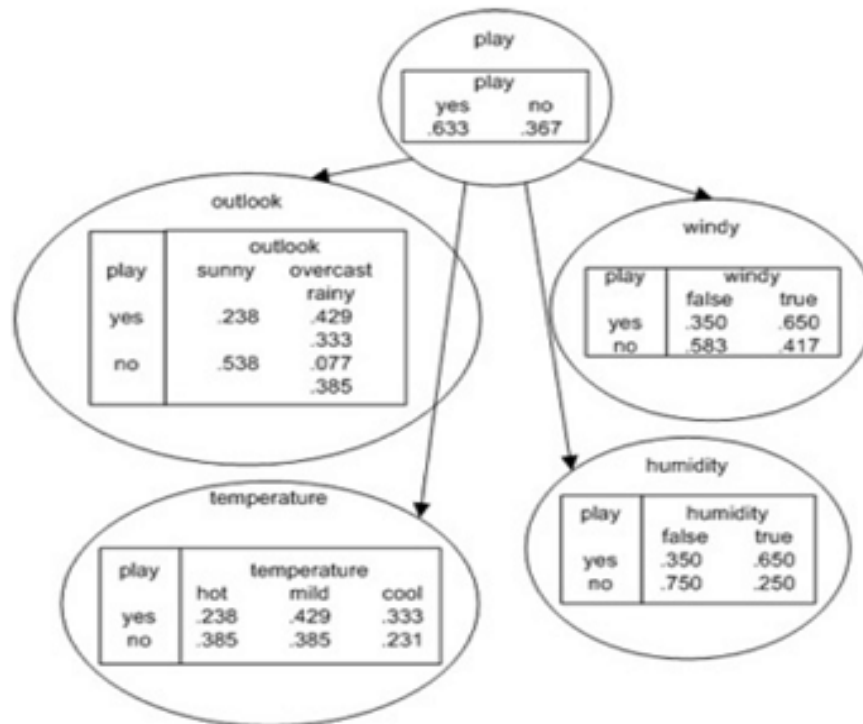
Nome	Função
IB1	Utilização do algoritmo <i>nearest-neighbor</i>
IBk	Utilização do algoritmo <i>k-nearest-neighbor</i>
KStar	Utilização do algoritmo <i>nearest-neighbor</i> com a função de distância generalizada
LWL	Utilização de pesos nos atributos

As redes Bayesianas fazem as suas predições com base numa estimativa da probabilidade, onde o valor de cada classe é estimado a partir da probabilidade de uma determinada instância pertencer a essa classe. Redes Bayesianas são modelos de representação do conhecimento que trabalham com o conhecimento incerto e incompleto através da Teoria da Probabilidade Bayesiana, baseando-se na Regra de Bayes demonstrada pela Equação 14.

$$P(A | B) = \frac{P(A \cap B)}{P(B)} \quad (14)$$

A forma gráfica em forma de rede vem para facilitar a compreensão dos valores de distribuições de probabilidade, por isso se dá o nome de redes bayesianas. Uma rede de nós, um para cada atributo, ligados de forma direcional, é criada a partir da distribuição de probabilidade, traduzindo-se assim numa rede sem ciclos. A Figura 26 mostra um desses exemplos.

Figura 26 - Exemplo da Rede Bayesiana



Pode observar que cada atributo, tempo, temperatura, umidade e vento possui um nó na rede bayesiana, além do atributo de saída jogar. Cada nó possui uma tabela que descreve a probabilidade utilizada para prever a probabilidade de classificação de uma determinada instância. Na parte da esquerda da tabela contém o atributo jogar, enquanto da direita contém respectivamente a probabilidade de cada valor do atributo. A partir desta tabela é possível definir a probabilidade para cada classe. Para isso é necessário multiplicar todas as probabilidades que vão sendo adquiridas ao longo da rede de acordo com os valores de cada atributo. Por exemplo, considerando que o objetivo é determinar a probabilidade da classificação jogar=sim, com os atributos nos valores: tempo=chuvoso, temperatura=frio, umidade=sim, vento=sim.

Com base na Figura 26, obtêm as probabilidades 0,333 do atributo tempo, 0,333 do temperatura, 0,650 do umidade e 0,650 do vento, multiplicando estas probabilidades obtêm o valor de 0,04685. Fazendo o mesmo cálculo para jogar=não, obtêm o valor de 0,00927. É necessário normalizar dividindo os valores obtidos pelas somas dos dois valores para obter a probabilidade condicional. Assim a probabilidade de jogar=sim é de 0,8348 e a de jogar=não é de 0,1652, sendo que

somadas têm dar obrigatoriamente 1, uma vez que só existem estas duas classes possíveis.

A plataforma WEKA disponibiliza vários algoritmos de aprendizagem com base no modelo de redes bayesianas, os quais se encontram na Tabela 7.

Tabela 7 - Algoritmos de Classificação Bayesianos disponíveis no WEKA

Nome	Função
AODE	Estimador médio de uma dependência
BayesNet	Redes bayesianas
ComplementNaiveBayes	Criação de uma <i>Naive Bayes</i> complementar
NaiveBayes	Criação de uma rede probabilística <i>Naive Bayes</i>
NaiveBayesMultinomial	Rede <i>Naive Bayes</i> multinomial
NaiveBayesSimple	Rede <i>Naive Bayes</i> simples
NaiveBayesUpdateable	Rede <i>Naive Bayes</i> incremental
LBR	Regras obtidas pelo algoritmo <i>Lazy Bayesian</i>

Além dos algoritmos descritos anteriormente o WEKA possui outros algoritmos de classificação que possuem características diferentes, mas com o mesmo objetivo, classificar uma instância. Pode-se encontrar modelos de regressão linear, regressão logística, *perceptron*, otimização seqüencial, entre outros. Esses outros classificadores não serão detalhados nesta dissertação pois esta dissertação não tem como objetivo demonstrar todos os tipos de classificadores existentes no WEKA, e sim apresentar uma visão geral do WEKA, sendo que o mesmo foi utilizado para a conclusão desta dissertação.

3.4.2 Modelos de Associação

A diferença entre os modelos baseados em regras de associação e regras de classificação é que o primeiro consegue prever qualquer atributo, e não apenas uma classe, além de possuir capacidade para prever combinações de atributos. É importante ressaltar que é necessário restringir o número de regras de associação criadas, conseguindo garantir uma elevada qualidade sobre as instâncias aplicadas. Esta qualidade é medida através de dois indicadores, o *coverage* e o *confidence*. O *coverage* indica o número de instâncias que a regra de associação permite prever corretamente. O *confidence* é o quociente entre o número de instâncias cuja previsão foi correta e o número total das instâncias abrangidas pela regra. Pode-se especificar um valor mínimo tanto para o *coverage* como para o

confidence assim será obtido as regras mais importantes, reduzindo a quantidade de regras de associação geradas. Por exemplo, se observar a seguinte regra de associação:

Se temperatura = frio então umidade = normal

Verifica-se que existem quatro instâncias onde a regra pode ser aplicada, *coverage* igual a quatro, destas quatro a umidade é normal logo o *confidence* da regra é de 100%. Observando outra regra:

Se umidade = normal e vento = não então jogar = sim

A parte da esquerda (umidade = normal e vento = não) é denominada de antecedente e a parte direita (jogar = sim) é denominada de conseqüente. Neste caso *coverage* igual a quatro e *confidence* igual a 100%. Para esse tipo de modelo o WEKA disponibiliza três algoritmos de aprendizagem, o *Apriori*, *PredictiveApriori* e *Tertius*.

O *Apriori* começa com um *coverage* de 100% e diminui em intervalos de 5% até que existam no mínimo 10 regras com um valor de *confidence* de 90% ou até que o *coverage* alcance o valor mínimo de 10%.

O *PredictiveApriori* combina o *confidence* e o *coverage* numa única métrica e descobre as melhores n regras de associação. Sua técnica consiste em incrementar sucessivamente o valor do *coverage*, tentando desta forma aumentar o valor da certeza da previsão.

O *Tertius* através de uma métrica de confirmação descobre as regras, podendo, igualmente o *Apriori*, utilizar múltiplas condições, mas diferente no fato destas condições serem OU lógico e não E lógico. Pode ser configurado para encontrar regras que prevêm uma simples condição ou um predeterminado atributo.

3.4.3 Modelos de Clustering

As técnicas de *clustering* pressupõe que pode-se dividir as instância em grupos naturais, pois existe uma forte relação entre as várias instâncias que

compõem o domínio, assim elas são utilizadas quando não existe nenhuma classe a ser inferida.

Normalmente uma instância pertence a somente um grupo e uma técnica para particionar a instâncias em clusters é a *k-means*. Este método de *clustering* é simples e eficaz, pois para formar grupos de instâncias ele utiliza uma forma iterativa de modo a que cada grupo seja o mais homogêneo possível assim definindo a menor semelhança entre grupos distintos.

O ponto de partida desse algoritmo é definir quantos clusters serão definidos a partir do parâmetro *k*, sendo que os *k* pontos serão dos centros do clusters ou centróides. Todas as instâncias são associadas ao centro do *cluster* mais próximo, de acordo com o quadrado da distância Euclidiana. A seguir é calculado a centróide de cada cluster. Este processo é repetido até que o sistema esteja estabilizado, ou seja, até se obter os mesmos pontos associados a cada *cluster* nas várias iterações.

No WEKA estão disponíveis dois algoritmos com essas definições, o *SimpleKMeans* e o *FarthestFirst*, sendo que a diferença entre estes dois algoritmos está na forma como são calculados os centróides. No caso do *SimpleKMeans*, os centróides são determinados de forma a minimizar a distância dos vários elementos que compõem o *cluster* ao centro do *cluster* e o *FarthestFirst* determina o centróide como o elemento do *cluster* com o valor máximo das distâncias mínimas aos centros atuais

3.5 SELEÇÃO DE ALGORITMOS

É importante saber que não existe nenhum algoritmo de classificação que seja superior aos outros em todos os problemas de classificação, sendo que do ponto de vista do utilizador o problema é saber qual algoritmo terá um melhor resultado em um determinado problema. O melhor algoritmo é aquele que consegue obter um modelo de classificação que atinja a maior taxa de acertos possível. Mas o utilizador não testará todos os algoritmos existentes, ele deverá saber quais resultados o satisfaz, assim, caso algum algoritmo retorne um resultado bom, ele pode trabalhar com ele aperfeiçoando e alterando os parâmetros ou o conjunto de treinamento para otimizar ainda mais o resultado, lembrando que um problema pode ser formulado de várias formas.

Nesta dissertação serão utilizados os algoritmos de classificação JRIP e PART para averiguar a existência de padrões visuais herdados nos cruzamento realizados entre orquídeas do gênero *Dendrobium nobile*.

3.6 AVALIAÇÃO DO ALGORITMO DE CLASSIFICAÇÃO

A avaliação de um método depende da taxa de acerto que ele possui para um determinado conjunto de dados. Existem vários métodos para avaliar um resultado de um algoritmo. Os disponíveis para os algoritmos de classificação no WEKA são: *use training set*, *supplied test set*, *cross-validation* e *percentage split*.

O *use training set* o algoritmo usará todos os dados para treinamento e avaliação.

O *supplied test set* o usuário fornecerá um conjunto de dados para treinamento em um arquivo no formato ARFF.

No *cross-validation* é realizada uma validação cruzada, ou seja, o usuário indicará em quantas partes k serão divididas os dados e o WEKA treinará o sistema k vezes, sendo que cada vez ele irá retirar do treinamento uma parte que será utilizada para avaliação. A média da avaliação será utilizada como referência de qualidade.

O *percentage split* separa uma porcentagem das instâncias para o treinamento e outra para validação.

4 O PROJETO

O comércio mundial de flores e plantas ornamentais movimentava 6,7 bilhões de dólares anualmente, sendo o Brasil responsável por apenas 0,3% [51]. Entre diversos tipos de plantas existentes pode-se destacar as orquídeas que são plantas ornamentais cultivadas tanto para produção de plantas de corte, utilizadas para bouquet de flores, como de vaso.

Dentre os diversos gêneros de orquídeas a *Dendrobium nobile* ocupa uma posição de destaque no mercado de plantas de corte e de vaso, sendo considerada uma das mais populares do Brasil [50]. Com sua larga distribuição geográfica a *Dendrobium nobile* vem sendo cultivada em diferentes habitats sendo que seu elevado valor florístico favorece seu volume expressivo de comercialização [24]. Contudo, as plantas dessa família requerem um tempo de desenvolvimento muito elevado, necessitando de um período maior de cultivo antes de serem comercializadas [50],

Seu valor de venda depende de padrões específicos repassados por herança genética [51], como coloração variada e atraente, mínimo de dois pseudobulbos por planta florescendo, grande número de flores e pseudobulbos com aproximadamente 60 cm.

Devido à depredação do meio ambiente as orquídeas vêm sofrendo dificuldade de se propagar em seu habitat natural, trazendo como consequência a existência de mais espécies híbridas do que naturais, criadas de forma artificial [13]. A hibridação visa à produção de espécies para fins comerciais, que devem apresentar características como alto vigor, grande número de flores e variabilidade de cores, propiciando a floração precoce [44]. Levando em consideração a necessidade de um longo período para o cultivo, a utilização de híbridos selecionados para cruzamento e autofecundação pode favorecer o melhoramento genético, visando à obtenção de novos cultivares [13].

Em 1997 o Departamento de Agronomia da Universidade Estadual de Londrina deu início a um programa de melhoramento de diversos gêneros de orquídeas. O programa consiste na observação, análise e documentação dos resultados de cruzamento entre as flores.

Com 15 plantas do gênero *Dendrobium nobile* [51] realizou 11 cruzamentos e 10 autofecundações. Os resultados dos cruzamentos e

autofecundações foram documentados através de fotos. Para a aquisição das imagens, cada planta foi coletada, colocada dentro de uma caixa com o fundo escuro e escaneada, utilizando um scanner de mesa, diminuindo a interferência da iluminação externa sobre a planta. Para que a medição de tamanho fosse possível duas réguas, uma na vertical e outra na horizontal, foram colocadas na extremidade da caixa, conforme mostra a Figura 27, possibilitando manter a proporção de quantos pixels existem por centímetro para o cálculo do tamanho da planta, mesmo que a imagem tenha sofrido alteração da sua resolução. As imagens obtidas pelo projeto foram capturadas invertidas, assim para que a orquídea corresponde-se a posição convencional as imagens apresentadas neste trabalho foram giradas.

Figura 27 – Imagem da *Dendrobium nobile* capturada pelo scanner de mesa, para a realização da medição através do software Flores



No projeto desenvolvido por TAKAHASHI [51] para realizar a medição de cada planta foi utilizado o software Flores, desenvolvido pelo professor Alan Salvany Felinto do Departamento de Computação da Universidade Estadual de Londrina, que, depois de calibrado, fornece a distância em centímetros entre dois pontos selecionados na imagem. Esses dados eram documentados, arquivados e analisados pela pesquisadora.

As imagens capturadas pelo scanner foram arquivadas utilizando a extensão JPG, que utiliza a técnica de compressão de imagem JPEG. Essa técnica diminuiu o espaço utilizado pelos arquivos e manteve as características da imagem.

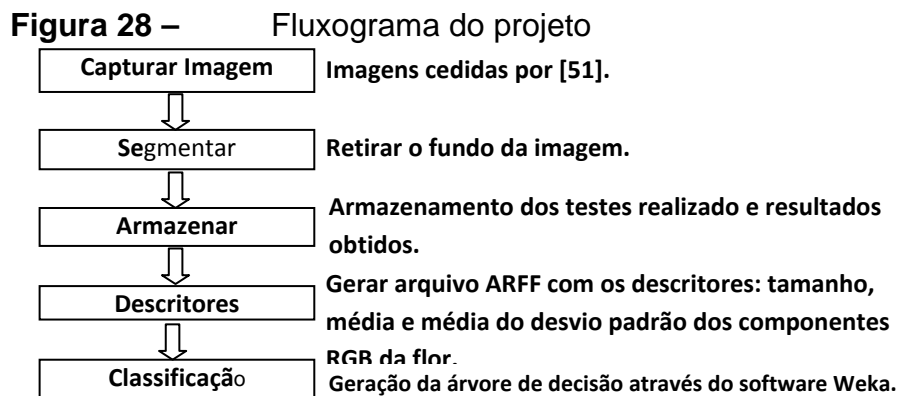
Em média cada imagem ocupa 800 KB, possuem uma proporção de 118 pixels por centímetro e 1 Mega Pixels de resolução. O projeto possui 152 imagens capturadas referentes a 7 cruzamentos divididos em pastas de acordo com a Tabela 8, onde as flores estão identificadas como d2, d5, d6, d7, d9, d11, d4, d15 e da.

Tabela 8 - Quantidade de Imagens existentes por cruzamento

Cruzamento ♀ x ♂	Quantidade de Imagens
d5xd9	21
d6xd9	28
d6xd15	28
d9xd2	13
d9xd7	20
d11xda	24
d14Xd7	22

Esta dissertação propõe um método completo para a captura, segmentação e análise de similaridades visuais herdadas entre flores, que tem como objetivo identificar quais características visuais em comuns possui flores resultantes de um cruzamento, assim como também identificar quais as características herdadas pelos filhos.

Nesta seção serão detalhadas as etapas realizadas para alcançar os objetivos desta dissertação, que estão divididas conforme o Figura 28 que representa o fluxograma do projeto. A etapa de captura foi realizada por TAKAHASHI [51] como descrito anteriormente.



4.1 SEGMENTAÇÃO


A primeira etapa do projeto foi segmentação das imagens distinguindo o fundo da flor. Para realizar a segmentação e a extração das características foi desenvolvido um protótipo implementado na linguagem de programação Python [34, 35] e para realizar a manipulação das imagens utilizou-se a biblioteca de processamento de imagem Python Image Library (PIL). Depois de calibrado, o protótipo segmentava automaticamente todas as imagens, sem a necessidade de intervenção manual.

Apesar das imagens das orquídeas serem capturadas através de um processo que elimina a interferência da iluminação externa, diferentemente de [55, 57, 26, 7] o fundo utilizado para a captura da imagem no projeto [51] não era uniforme, visto que o objetivo de digitalizar as flores foi para manter documentado os experimentos e realizar a medição do tamanho através de um sistema próprio onde seleção da flor foi realizada manualmente. Com a análise de medição destrutiva da plantas através da massa seca dos órgãos da planta realizada [51] não foi possível recriar a captura com um fundo apropriado para este trabalho, portanto, inicialmente, essas características dificultaram a segmentação correta, pois a tonalidade das extremidades de algumas flores era equivalente ao fundo utilizado na captura.

Testes de segmentação foram realizados, alterando os parâmetros, modelos de cores e técnicas e todos resultados foram documentados e analisados. A alteração de cada parâmetro individualmente possibilitou a verificação da influência de cada parâmetro no resultado final.


Considerando que os fundos das imagens possuíam características semelhantes inicialmente foi aplicado a segmentação através de um limiar no modelo de cor tons de cinza, mas o resultado não foi satisfatório. Uma análise do histograma demonstrou que várias flores possuem tonalidades próximas ao fundo, o que prejudica o uso desta técnica. Vários limiares foram testados, porém, pela variedade de cores das flores e pelas características do fundo não foi encontrado um limiar único para a segmentação satisfatória de todas as flores. Flores com extremidades escuras não tiveram um bom resultado, conforme mostra a Figura 29.

Figura 29 – (a) Segmentação da Figura 27 através do limiar 23; (b) Segmentação da Figura 27 através do limiar 27



Partiu-se para a segmentação através de operadores morfológicos de dilatação e erosão, através do toolbox pymorph [11]. Apesar do bom resultado da segmentação, os testes, incluindo a aplicação dos algoritmos de abertura e fechamento de áreas, apresentaram um tempo de processamento superior ao da segmentação por um limiar e as flores com extremidades escuras tiveram uma segmentação parcial, conforme mostra a Figura 30. Essa ineficiência da segmentação se deve a necessidade de realizar a limiarização da imagem para a aplicação dos filtros morfológicos, causando os mesmos problemas do teste anterior. Mesmo considerando a melhora obtida pelos algoritmos de abertura e fechamento de áreas que eliminaram parte dos ruídos esse processo foi descartado e outros algoritmos foram testados.


Figura 30 – Segmentação da Figura 27 através de operadores morfológicos



Aplicou-se então o método de sobel [18, 42] para encontrar as bordas, entretanto, para a aplicação deste método é necessário que a imagem esteja no modelo de cor tons de cinza, acarretando na mesma dificuldade existente na aplicação das técnicas de limiarização. Em alguns casos variando a matriz de

sobel a melhora é perceptível, mas ocorriam pequenas falhas de descontinuidade da borda, demonstradas na Figura 31, que poderiam comprometer a eficiência do projeto.

Figura 31 – Indicação da falha de segmentação da Figura 27 através do método de sobel



Partiu-se para a segmentação através do modelo de cor RGB, tentando eliminar o fundo que nas imagens possuem tonalidades equivalentes. Durante os testes cada componente do modelo foi alterado individualmente buscando uma melhor configuração do método, mas os resultados não foram satisfatórios e rapidamente essa abordagem foi descartada. Aplicou-se então a segmentação através de um limiar aplicado no modelo de cor $L^*a^*b^*$, onde o resultado e o tempo foram satisfatórios. A transformação do modelo de cor RGB para $L^*a^*b^*$ foi realizada pela biblioteca GrapeFruit disponibilizada pela licença Apache License 2.0 no site <http://code.google.com/p/grapefruit>.

Nos primeiros testes de segmentação utilizando o modelo de cor $L^*a^*b^*$ foi aplicado um limiar T único para os três componentes. Em testes realizados o $T=30$ foi considerado o melhor resultado, pois na maioria das imagens o fundo foi eliminado, mas algumas imagens com flores mais escuras a segmentação não foi realizada adequadamente, conforme a Figura 31. Por esse motivo foi desenvolvido outro algoritmo de segmentação que utilizava limiares independentes para cada componente do $L^*a^*b^*$, onde T_L , T_a e T_b são respectivamente os limiares dos componentes de $L^*a^*b^*$. Em comparação com o método anterior esse método demonstrou uma melhor segmentação, resolvendo o problema das flores que possuem tonalidades fortes. Os testes mostraram que $T_L=21, T_a=10$ e $T_b=13$ apresentavam um bom resultado na segmentação, conforme a Figura 32.

Figura 32 - a) Segmentação da Figura 27 através de um limiar único no modelo de cor $L^*a^*b^*$, com $T = 30$; (b) Figura 27 segmentada através de limiares independentes para o modelo de cor $L^*a^*b^*$, com $T_L = 21$, $T_a = 10$ e $T_b = 13$;




4.2 CARACTERÍSTICAS OBTIDAS

Mesmo com a eliminação do fundo obtido pela segmentação da imagem através do limiar aplicado no modelo de cor $L^*a^*b^*$ foi necessário identificar na imagem segmentada quais conjuntos de pixels destacados representam a flor. Nessa etapa foi necessário levar em consideração que a segmentação além de destacar a flor também destacou as régua existentes na imagem, demonstrado na Figura 33 item (a). Outro problema é que o centro do labelo de algumas flores possui tonalidade próxima ao fundo, sendo eliminado pela técnica causando buracos na flor encontrada pela segmentação, como demonstrado na Figura 33 item (a). Isso obrigou a desenvolvimento de um algoritmo para buscar a borda externa da flor, assim definindo a posição exata da mesma.

Analisando as imagens originais foi possível definir quais conjuntos de pixels representavam a flor, pois é possível perceber que as flores estão parcialmente centralizadas, portanto um cluster é colocado no centro da imagem segmentada percorrendo a imagem da direita para a esquerda a procura da flor que é definida pelo maior conjunto de pixels vizinhos com valor 1. A posição do pixel da extremidade esquerda deste conjunto de pixels é definida como ponto de partida para delimitar a posição da flor na imagem através do processo que destaca a borda externa da flor. Esta verificação é realizada por um algoritmo que, a partir da posição inicial, procura entre os 8 vizinhos do pixel o pixel mais externo correspondente a flor. A cada interação são definidas as coordenadas (x,y) iniciais e finais da flor que serão utilizadas para definir o seu tamanho. O item (b) da Figura 33 representa a posição da flor na imagem através da sua borda, sendo que a parte externa a borda

será desconsiderada pelo projeto e I_F será a flor segmentada no modelo de cor RGB.

Figura 33 – (a) Imagem segmentada (b) Imagem representado o contorno da flor segmentada em (a)



Com a delimitação da flor na imagem, representada por I_F , foi possível realizar a coleta das características utilizadas para a procura de padrões. Foram coletados os seguintes descritores de I_F : largura, altura e área da flor, histograma de cada componente de cor RGB, histograma dos tons de cinza, a média e o desvio padrão de cada componente de cor do modelo RGB.

Os resultados foram arquivados em um arquivo texto, seguindo o formato CSV, onde as colunas são separadas por ponto e vírgula e a primeira linha contém os títulos das colunas. Os histogramas, além de numericamente arquivados, foram gerados graficamente para análise visual.

5 RESULTADOS EXPERIMENTAIS

Como ferramenta de Data Mining foi utilizado o software Weka [53] onde o tamanho da flor, média e desvio padrão de cada componentes RGB foram comparados com os algoritmos JRIP [12, 6, 19] que extrai regras de classificação através do método *Repeated Incremental Pruning to Produce Error Reduction* (Ripper) e PART [6, 19] que produz um conjunto de regras a partir de uma árvore de decisão gerada pelo algoritmo C4.5. Os dados salvo no formato CSV foram convertidos em um arquivo no formato ARFF, padrão do software Weka.

As execuções dos algoritmos PART e JRIP geraram regras que são apresentadas em forma de tabela de decisão. Cada regra possui um conjunto de condições que quando validado aponta exclusivamente para um cruzamento. A primeira regra é testada e caso o resultado for falso é testada a próxima e assim sucessivamente até a última regra que aponta diretamente para um cruzamento. O resultado foi remodelado para um melhor entendimento e é apresentado nos Quadro 1 e Quadro 2. Após a definição de cada instância é apresentado um valor (x/y) onde o x representa o número de elementos classificados e o y o número de elementos classificados com erro. O tempo gasto para a construção do modelo do algoritmo PART foi de 0,03 segundos enquanto no JRIP foi 0,05 segundos.

Nos testes realizados com o algoritmo PART, conforme mostra o Quadro 1, a primeira regra define o cruzamento d11xda que é selecionado quando a média do componente G é maior que 97 e a média do componente B é menor ou igual a 98 e a última regra aponta diretamente para o cruzamento d5xd9.

Quadro 1– Resultado em forma de estrutura de condição do algoritmo PART

<p>Se (MédiaG > 97) e (MédiaB <= 98)</p> <p>então d11xda (24,0/1,0)</p> <p>Senão, Se (TamFlorX <= 5,8674) e (desvioB <= 32,768293) e (desvioR <= 28,940913) e (MédiaR <= 104)</p> <p>então d6xd9 (18,0/0,0)</p> <p>Senão, Se (TamFlorX > 6,434667) e (MédiaG <= 64) e (desvioR <= 31,107687)</p> <p>então d14Xd7 (11,0/1,0)</p> <p>Senão, Se (TamFlorX > 6,434667) e (desvioR > 28,940913) e (TamFlorX > 6,544733) e (MédiaG > 61)</p> <p>então d6xd15 (12,0/0,0)</p> <p>Senão, Se (MédiaG <= 62) e (TamFlorX > 6,544733) e (TamFlorY <= 6,9342) e (TamFlorY > 5,985933)</p> <p>então d6xd15 (11,0/1,0)</p> <p>Senão, Se MédiaG <= 62 e TamFlorX <= 6,544733 e TamFlorY > 5,3848</p> <p>então d9xd7 (7,0/0,0)</p> <p>Senão, Se (MédiaG <= 62) e (TamFlorY > 5,164667)</p> <p>então d14Xd7 (9,0/0,0)</p> <p>Senão, Se (MédiaG > 100) e (MédiaG > 107)</p> <p>então d9xd2 (6,0/1,0)</p> <p>Senão, Se(MédiaB <= 90) e (MédiaG > 66)</p> <p>então d9xd2 (7,0/0,0)</p> <p>Senão, Se (TamFlorX <= 5,8674) e (desvioB > 32,119935) e (TamFlorX > 5,037667)</p> <p>então d5xd9 (14,0/0,0)</p> <p>Senão, Se (desvioR <= 32,209738) e (TamFlorY > 5,647267) e (MédiaR > 104)</p> <p>então d9xd7 (8,0/1,0)</p> <p>Senão, Se (desvioR <= 32,209738) e (TamFlorX <= 6,1976) e (desvioG > 32,953556)</p> <p>então d6xd9 (9,0/1,0)</p> <p>Senão, Se (MédiaR > 105) e (MédiaB <= 107) e (MédiaR > 108)</p> <p>então d9xd7 (6,0/1,0)</p> <p>Senão, Se (MédiaR > 106)</p> <p style="padding-left: 40px;">então d6xd15 (6,0/1,0)</p> <p>Senão d5xd9 (4,0/1,0)</p>

Com o algoritmo JRIP, conforme mostra o Quadro 2, a primeira regra define o cruzamento d9xd2 que é selecionado quando o desvio padrão do componente B for maior ou igual a 38,308945 e o desvio padrão do componente R for menor ou igual a 34,177744 e a última regra aponta diretamente para o cruzamento d6xd15.

Quadro 2 – Resultado em forma de estrutura de condição do algoritmo JRIP

<p>Se (desvioB \geq 38,308945) e (desvioR \leq 34,177744) então d9xd2 (6,0/1,0)</p> <p>Senão, Se (MédiaB \geq 94) e (TamFlorX \leq 5,8674) e (desvioR \geq 29,017975) e (MédiaR \leq 121) então d5xd9 (15,0/1,0)</p> <p>Senão, Se (desvioG \leq 32,576785) e (MédiaR \geq 99) e (MédiaG \leq 61) então d9xd7 (7,0/1,0)</p> <p>Senão, Se (MédiaB \geq 102) e (MédiaG \leq 75) e (MédiaB \geq 105) então d9xd7 (6,0/0,0)</p> <p>Senão, Se (MédiaB \geq 98) e (desvioR \leq 27,277815) então d9xd7 (5,0/1,0)</p> <p>Senão, Se (TamFlorY \geq 7,1882) e (MédiaG \leq 64) então d14Xd7 (10,0/1,0)</p> <p>Senão, Se (MédiaG \leq 42) então d14Xd7 (5,0/1,0)</p> <p>Senão, Se (MédiaR \geq 121) e (MédiaB \leq 111) então d11xda (24,0/0,0)</p> <p>Senão, Se (TamFlorX \leq 5,825067) e (desvioB \leq 32,557962) então d6xd9 (24,0/2,0)</p> <p>Senão d6xd15 (50,0/24,0)</p>
--

O método PART obteve maior eficiência classificando os dados em 15 regras com aproximadamente 94,08% de êxito na classificação das flores, enquanto o JRIP utilizou 10 regras e apresentou aproximadamente 78,94% de êxito na classificação das flores, conforme demonstrado na Tabela 9.

Tabela 9 - Resultados da aplicação dos métodos de classificação PART e JRIP


Cruzamentos	Quant. Imagens	ACERTOS	
		PART	JRIP
d5xd9	19	17	14
d6xd9	26	26	22
d6xd15	28	27	26
d9xd2	13	12	5
d9xd7	20	19	16
d11xda	24	23	24
d14Xd7	22	19	13
% das Classificações Corretas		~94,08 %	~78,94 %

Pode-se destacar a melhor acurácia do algoritmo PART em relação ao algoritmo JRIP, mas também deve-se levar em consideração a quantidade de regras e condições geradas conforme a Tabela 10. O algoritmo PART gerou 50% a mais de regras e utilizou 85% a mais de condições, essas definições deram uma eficiência de 15,14% superior quando comparado com o algoritmo JRIP. Esse desempenho pode ser analisado observando a definição do cruzamento d6xd9, o algoritmo PART utiliza 2 regras e 7 condições enquanto o algoritmo JRIP utiliza 1 regra e 2 condições. Neste caso o algoritmo PART teve uma acurácia de 100%, enquanto o JRIP teve 84,61%. O número inferior de regras e condições favorece o desempenho computacional na hora de validar o modelo e isso pode ser levado em consideração quando o desempenho do tempo de execução for considerado essencial, pois com mais dados de entrada e mais números de características analisadas os algoritmos tendem utilizar mais tempo. Como objetivo do trabalho não envolve otimizar os recursos computacionais e sim obter uma melhor classificação analisaremos somente o método PART.

Tabela 10 - Número de regras e condições dos métodos PART e JRIP

Cruzamento	PART		JRIP	
	REGRAS	CONDI- ÇÕES	REGRAS	CONDI- ÇÕES
d5xd9	2	3	1	4
d6xd9	2	7	1	2
d6xd15	3	9	1	0
d9xd2	2	4	1	2
d9xd7	3	9	3	8
d11xda	1	2	1	2
d14Xd7	2	5	2	3
TOTAL	15	39	10	21

A Figura 34 mostra o gráfico de classificações do método PART. A melhor classificação foi do cruzamento d6xd9 com 100% de exatidão, enquanto o pior resultado foi do cruzamento d14xd7 com aproximadamente 86% de exatidão.

Figura 34 – Classificação do Método PART. Os valores numéricos representam o número de instâncias classificadas

Mesmo considerando o resultado do método PART melhor, existe uma característica que é comum entre os dois métodos. Analisando as regras geradas pelos dois algoritmos definiu-se através da Tabela 11 a quantidade de vezes que cada característica é utilizada em cada método. Entre todas as características analisadas a Média de G obteve a maior influência na definição dos agrupamentos, tendo participação em 53% das regras do algoritmo PART e 40% das regras do algoritmo JRIP. Através da Tabela 11 e considerando o melhor desempenho do algoritmo PART pode-se definir que a média dos componentes de

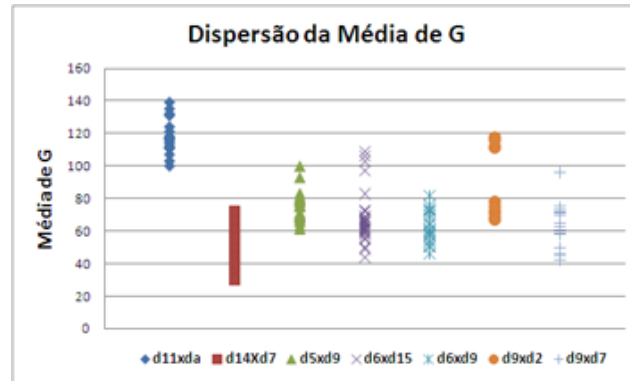
cor do modelo RGB é a característica que possui maior peso na classificação, seguida pelo tamanho da flor e desvio padrão dos componentes de cor do modelo RGB.

Tabela 11 - Número de regras e condições dos métodos PART e JRIP

Características	PART	JRIP
	Qt. de regras que utilizam	Qt. de regras que utilizam
Tam. X	7	2
Tam. Y	4	1
Média de R	4	3
Média de G	8	4
Média de B	3	4
Desvio de R	5	3
Desvio de G	1	1
Desvio de B	2	2

Pode-se entender a importância da Média de G para a eficiência do algoritmo analisando a dispersão de G. O valor da média do componente G em uma planta possui uma dispersão de ± 23 níveis em relação a média do componente de G daquele cruzamento, isso representa uma variabilidade de 9% na escala de cor do modelo RGB e um desvio padrão de 13,11. Isso demonstra que flores advindas do mesmo cruzamento possuem tonalidade de G próximas estabelecidas dentro de um intervalo de valores. É possível verificar essa afirmação observando a Figura 35 que apresenta o gráfico de dispersão da média de G, onde o mesmo demonstra que na maioria dos cruzamentos o valor de G fica estabelecido dentro do intervalo padrão. Outra característica que favorece o componente G em relação ao R e B é o desvio padrão médio entre os cruzamentos, que do G é de 24,71, R é de 14,54 e B é de 12,21, isso demonstra que existe uma maior separação entre os cruzamentos quando analisado média do componente G.

Figura 35 – Dispersão da Média do G componente de cor RGB



Analisando gráfico de dispersão da média de G pode-se notar que o cruzamento d11xda possui uma cor diferente dos outros cruzamentos, isso pode ser confirmado através da análise da Figura 36. Neste caso a definição desse cruzamento pode ser realizada utilizando como característica principal o valor de médio de G, pois a maioria das flores pertencentes a esse cruzamento possui um valor médio do componente G elevado. Mas analisando os outros cruzamentos representados no gráfico de dispersão da Média G pode-se perceber que com somente a média do componente G não é possível classificar corretamente as flores. Essa validação é feita analisando a primeira regra do método PART, onde a média do componente G e do componente B são utilizados para classificar a d11xda, onde, neste caso, a média do componente G deve ser maior que 97 e média de componente B menor ou igual a 98. A utilização do componente B é necessário pois existem outros cruzamentos que possuem a mesma característica do componente G do cruzamento d11xda.

Figura 36 – Exemplo de cada cruzamento no formato original



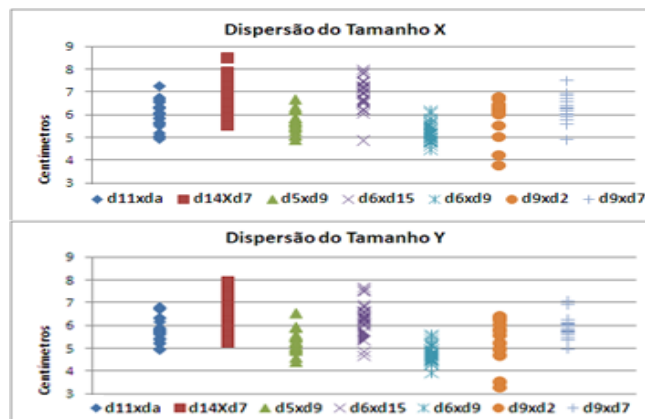
Analisando somente as regras onde a média do componente G é utilizada, representado pela Tabela 12, pode-se destacar que o tamanho da flor é uma das características que auxilia na definição do cruzamento.

Tabela 12 - Características que são utilizadas juntas com a Média e G nas regras definidas pelo algoritmo PART

Características	Número de regras
Tam. X	4
Tam. Y	3
Média de R	0
Média de B	2
Desvio de R	2
Desvio de G	0
Desvio de B	0
Somente Média de G	1

Pode-se analisar a dispersão do tamanho através da Figura 37 que demonstra que flores advindas do mesmo cruzamento possuem tamanhos próximos, já tendo sido observado em [51]. Mas, somente com a característica de tamanho não é possível obter um bom resultado de classificação. Isso ocorre devido ao desvio padrão existente entre todos os cruzamentos analisados, que no tamanho x é de 0,87 e no tamanho y é de 0,89. Esses valores demonstram que os tamanhos das flores possuem diferenças mínimas dificultando a classificação somente por essa característica.

Figura 37 – Dispersão do tamanho da flor




Para confirmar a importância de cada característica foi executado o método PART e a cada execução uma característica era retirada, conforme mostra a Tabela 13. Pode-se observar que a característica que mais influência no bom desempenho do algoritmo é a média do componente G e a segunda característica que mais influência é o tamanho X, ambas reforçando os argumentos anteriores. As características que menos influenciaram no resultado do algoritmo foram a média do componente B e a média do desvio do componente G, sendo que com a eliminação dessa última característica o algoritmo teve um melhor desempenho na classificação. É importante salientar que em todos os casos a eliminação de uma característica aumentou o número de regras criadas e que apesar da eliminação individual da média do componente B e da média do desvio do componente G manter o desempenho do algoritmo, quando retirado as duas características o método obteve um desempenho inferior estabelecendo 93,42% de acerto nas classificações através de 22 regras.

Tabela 13 - Número de regras e classificações corretas do método PART

Características Parciais	MÉTODO PART	
	Núm. de Regras	% das Classificações Corretas
Sem Tamanho X	18	90,13%
Sem Tamanho Y	17	92,10%
Sem Média R	19	92,76%
Sem Média G	20	88,81%
Sem Média B	19	94,08%
Sem Desvio R	16	92,10%
Sem Desvio G	17	94,73%
Sem Desvio B	17	93,42%

Para confirmar a importância do tamanho na classificação foi adicionada uma nova característica referente ao tamanho, a quantidade de pixels da flor. Considerando que a proporção de pixels por centímetro em todas as imagens são iguais esta característica pode ser considerada a área da flor em pixels. A Figura 38 apresenta a dispersão da quantidade de pixels, que possui características equivalentes a dispersão do tamanho X e Y demonstrada na Figura 37.

Figura 38 – Dispersão da Quantidade de Pixels



Ao incluir a quantidade de pixels na execução do método PART a classificação obteve 94,08% de eficiência com a utilização de 17 regras, assim, mantendo a acurácia mais aumentando o número de regras. Outra característica interessante é que com essa configuração o tamanho X não foi utilizado em nenhuma regra, mas apesar de não ser utilizado quando retirado o tamanho X do conjunto de características analisadas o algoritmo teve uma eficiência de 91,45% com 12 regras.

Analisando a acurácia dos métodos PART e JRIP que obtiveram 94,08% e 78,94% respectivamente e as regras geradas sobre o desvio padrão e dispersão dos dados obtidos pelo protótipo a partir das características físicas de tamanho e coloração pode-se perceber que existem padrões entre as flores que possuem os mesmos pais, isso demonstra a existência de heranças de características visuais repassadas dos pais para seus filhos.

A próxima etapa desta dissertação é encontrar qual a influência individual dos pais sobre as características herdadas pelos filhos. Para isso foram levantadas as características dos pais utilizados nos cruzamentos. Assim como os filhos as imagens dos pais foram capturadas pelo scanner e arquivadas utilizando a extensão JPG. Em média cada imagem ocupa 800 KB, possuem uma proporção de 157 pixels por centímetro e 1 Mega Pixels de resolução. O projeto possui 31 imagens capturadas referentes a 7 flores divididos em pastas de acordo com a Tabela 14, onde as flores estão identificadas como m11, m14, m15, m5, m6, m7 e

m9 que correspondem respectivamente a d11, d14, d15, d5, d6, d7 e d9. É necessário salientar imagens de d 2 não foram coletadas por TAKAHASHI [51], assim os cruzamentos d11x d1 e d9x d2 não serão analisados nesta etapa.

Todos os métodos descritos anteriormente para os filhos foram aplicados nos pais, assim eliminou-se o fundo da imagem segmentando a flor e colhendo as mesmas características de tamanho e cor dos pais.

Tabela 14 - Quantidade de Imagens existentes por cruzamento

Cruzamento	Qt. de Imagens
m5	17
m6	3
m7	2
m9	2
m11	2
m14	2
m15	3

A Tabela 15 demonstra os valores médios das características dos pais após a análise. Os valores apresentados são valores aproximados, pois foram arredondados para duas casas decimais. A última linha apresenta o desvio padrão das características, onde pode-se perceber novamente que a Média de G possui uma dispersão maior que as outras características, assim reafirmando a teoria que a Média do componente de cor G é um dos componentes mais importantes para a definição de grupos.

Tabela 15 – Características dos Pais

	TamFlorX	TamFlorY	MédiaR	MédiaG	DesvioR	MédiaB	DesvioG	DesvioB
m11	6,41 cm	6,00 cm	122,00	102,50	35,63	64,50	34,51	19,45
m14	6,47 cm	5,69 cm	86,50	59,50	27,85	63,50	31,39	26,79
m15	6,78 cm	6,12 cm	99,33	79,67	29,17	65,67	30,50	28,11
m5	6,12 cm	6,15 cm	135,24	112,65	35,31	77,65	42,42	29,17
m6	7,24 cm	6,25 cm	100,67	61,67	29,51	68,00	32,26	31,83
m7	7,90 cm	7,56 cm	126,00	119,00	31,34	712,00	35,47	34,47
m9	3,95 cm	3,70 cm	124,50	106,00	24,13	721,50	32,03	25,73
Desvio	1,24	1,15	17,87	24,46	4,09	22,38	4,07	4,79

Para realizar a comparação entres os pais e os filhos foi definido a Tabela 16 com os valores médios das características dos cruzamentos. Os valores apresentados são valores aproximados, pois foram arredondados para duas casas decimais. Nesta tabela também é possível observar a importância da Média do componente de cor G para realizar a definição de grupos.

Tabela 16 – Características dos Cruzamentos

	TamFlorX	TamFlorY	MédiaR	MédiaB	MédiaG	DesvioR	DesvioG	DesvioB
d11xda	5,98 cm	5,83 cm	133,42	84,08	117,79	36,18	41,10	32,99
d14Xd7	7,00 cm	6,65 cm	99,45	84,05	53,00	30,50	36,13	31,41
d5xd9	5,70 cm	5,29 cm	110,11	102,32	75,11	31,07	37,49	35,06
d6xd15	6,90 cm	6,38 cm	107,82	95,89	68,04	34,11	38,67	36,30
d6xd9	5,20 cm	4,78 cm	98,54	90,00	61,42	25,75	32,91	28,72
d9xd2	5,82 cm	5,29 cm	116,31	96,38	91,69	30,15	34,70	34,68
d9xd7	6,24 cm	5,90 cm	112,70	97,10	64,15	29,33	34,21	32,83
Desvio	0,65	0,66	11,78	6,98	22,13	3,36	2,84	2,54

A Tabela 17 compara o desvio padrão de todas as características dos cruzamentos com o pai e a mãe. Pode-se notar em geral que o cruzamento tem uma tendência de obter características similares a da mãe.

Tabela 17 – Desvio Padrão Médio dos cruzamentos com os pais

	Mãe	Pai
d14Xd7	2,96	11,21
d5xd9	9,17	7,91
d6xd15	2,79	3,71
d6xd9	1,89	9,71
d9xd7	8,57	8,07

A tabela 18 demonstra o desvio padrão dos cruzamentos com a mãe e o pai, assim, quanto menor o desvio padrão maior é a similaridade. Foram analisadas três características: o desvio padrão da diferença do tamanho de x e y que é calculado através do valor absoluto da subtração de x e y, o desvio padrão da média de dos componentes RGB e o desvio padrão da média do desvio padrão dos componentes RGB. A tabela mostra destacados em azul os valores com maiores similaridades.

A diferença do tamanho de x e y representa a harmonia de circunferência, pois quanto menor a diferença entre o x e y maior será a

possibilidade da flor ter uma circunferência perfeita. Em análise pode-se definir que o cruzamento tem a tendência de obter proporção de circunferência do pai, enquanto a média da coloração da mãe. O desvio demonstra que a variação de cor é aproximada a variação do pai.

Tabela 18 – Desvio Padrão dos cruzamentos com os pais

Desvio dos Cruzamentos em comparação com a Mãe			
	Dif. XY	Méd. RGB	Méd. D. RGB
d14Xd7	0,30	1,65	2,83
d5xd9	0,27	8,96	0,78
d6xd15	0,34	2,69	3,65
d6xd9	0,41	2,44	1,47
d9xd7	0,06	18,40	3,41
Desvio	0,13	7,10	1,25

Desvio dos Cruzamentos em comparação com o Pai			
	Dif. XY	Méd. RGB	Méd. D. RGB
d14Xd7	0,01	28,40	0,77
d5xd9	0,11	15,20	5,11
d6xd15	0,10	0,69	5,02
d6xd9	0,11	24,05	1,29
d9xd7	0,01	19,58	1,16
Desvio	0,05	10,65	2,20

Pode-se definir que existe herança visual nas orquídeas do gênero *Dendrobium nobile*, pois é possível agrupar os cruzamentos através das características, sendo que apesar de o cruzamento ter a tendência geral de herdar características da mãe existem características que são obtida do pai.

CONCLUSÃO

Neste trabalho foi apresentada uma metodologia para reconhecimento de padrões visuais herdados, composta pelas etapas de captura da imagem, segmentação, definição das características e classificação, com a utilização de processamento de imagens e técnicas de mineração de dados através dos algoritmos PART e JRIP.

Durante a aplicação da metodologia foi possível identificar que a captura de plantas através de um scanner produz um ambiente controlado, sem influência de iluminação externa, possibilitando a utilização da segmentação por limiarização que é considerada de fácil aplicação e implementação, mas com pouca eficiência em ambientes com interferência da iluminação. Para essa conclusão foram aplicados, documentados e analisados as técnicas de segmentação limiarização por tons de cinza, operadores morfológicos, método de sobel e limiarização por $L^*a^*b^*$. Os testes com a variação dos modelos de cores e parâmetros aperfeiçoaram a etapa de segmentação otimizando os resultados, sendo que o algoritmo que obteve o melhor resultado foi o de limiarização por $L^*a^*b^*$. Esse bom resultado foi alcançado pois neste método é possível identificar a diferença de luminosidade entre o fundo e a flor, enquanto os outros métodos baseassem na diferença das cores, impossibilitando a segmentação correta da extremidade da flor que possui coloração equivalente ao fundo.

A utilização de algoritmos de mineração de dados auxiliou a encontrar padrões existentes entre as flores com os mesmos pais. A comparação entre os dois métodos PART e JRIP definiu o quanto cada descritor contribui para a classificação correta das flores, possibilitando a verificação do grau de importância de cada descritor para a análise de herança. Os dois descritores que obtiveram um melhor desempenho foram o média da coloração verde do modelo de cor RGB e o tamanho.

Na aplicação do método proposto por essa dissertação sobre *Dendrobium nobile*, os algoritmos PART e JRIP obtiveram 94,08% e 78,94% de acurácia respectivamente sendo que analisando as regras geradas baseadas no o desvio padrão e dispersão das características físicas de tamanho e coloração pode-se perceber que existem padrões entre as flores que possuem os mesmos pais, isso

demonstra a existência de heranças de características visuais repassadas dos pais para seus filhos. Outra análise realizada identificou que os filhos herdam no geral as características na mãe, mas que a proporcionalidade entre a largura e altura da flor são herdadas do pai.

Levando em consideração que o período de polinização até o florescimento dura em média de três a quatro anos, com a utilização de um sistema de reconhecimento e análise das características é possível aumentar a eficiência do cruzamento, bem como abaixar os custo de operação. Esses aspectos viabilizam a utilização de tecnologias para auxiliar no processo de identificação, substituindo o método manual e proporcionando maior eficiência e agilidade no processo.

Para trabalhos futuros pretende-se incorporar novos descritores para análise da *Dendrobium nobile*, identificando quais descritores são herdados do pai e da mãe. Também será aplicada uma variação deste método em outras flores onde as características visuais são importantes, estendendo futuramente a aplicação para frutos, folhas e sementes.

BIBLIOGRAFIA

- [1] ABU-MOSTAFA, Y. S.; PSALTIS, D. **Optical neural computers**, Scientific American, v. 256, p. 88–95, 1987.
- [2] BERLAGE, T. **Analyzing and mining image databases**, International Journal of Rock Mechanics and Mining Sciences, v. 30, p. 297-298, 1993.
- [3] BROWN, L. G. **A Survey of Image Registration Techniques**, ACM Computing Surveys (CSUR), v. 24, 1992.
- [4] CAMPADELLI, P.; MEDICI, D.; SCHETTINI, R. **Color image segmentation using Hopfield networks**, Image and Vision Computing, v. 15, p. 161–166, 1997.
- [5] CHENG, Y. **Image classification using color, texture and regions**, Image and Vision Computing, v. 21, p. 759-776, 2003.
- [6] CORNFORTH, D.; JELINEK, H. **Automated classification reveals morphological factors associated with dementia**, Applied Soft Computing, v. 8, p. 182-190, 2008.
- [7] DARRIGUES, A.; HALL, J.; KNAAP, E.; FRANCIS, D. **Tomato Analyzer-color Test: A New Tool for Efficient Digital Phenotyping**, Journal of the, v. 133, p. 579-586, 2008.
- [8] DAS, M.; MANMATHA, R.; RISEMAN, E. **Indexing flowers by color names using domain knowledge-driven segmentation**, Proceedings Fourth IEEE Workshop on Applications of Computer Vision (WACV'98), p. 94-99, 1998.
- [9] DAS, M.; MANMATHA, R.; RISEMAN, E. **Indexing flower patent images using domain knowledge**, IEEE Intelligent Systems, v. 14, p. 24-33, 1999.
- [10] DOUGHERTY, J.; KOHAVI, R.; SAHAMI, M. **Supervised and Unsupervised Discretization of Continuous Features**. Machine Learning: Proceedings of the Twelfth International Conference, 1995.
- [11] DOUGHERTY, E. R.; LOTUFO, R. A. **Hands-on morphological image processing**, SPIE Press, 2003.
- [12] DURAK, N.; NASRAOUI, O.; SCHMELZ, J. **Coronal loop detection from solar images**, Pattern Recognition, v. 42, p. 2481-2491, 2009.
- [13] FARIA, R. T.; VICENTE, A. P. R. M.; MARQUES, T. M; FONSECA, I. C. B.; SILVA, G. L.; TAKAHASHI, L. S. A., **Seleção de genótipos de *Dendrobium* (*Orchidaceae*) na fase de propagação in vitro**. Semina, Ciências agrárias, Londrina, v. 25, n. 2, p. 221-226, 2004.
- [14] FILHO, O. M.; NETO, H. V. **Processamento Digital de Imagens**, Editora Brasport, 1999.

- [15] FUKUNAGA, K. **Introduction to statistical pattern recognition**, 2 edition, Academic Press, 1990.
- [16] GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**, Addison-Wesley Publishing Company, 1993.
- [17] _____. **Processamento de Imagens Digitais**, Edgard Blücher Ltda, 2000.
- [18] _____. **Digital Image Processing**, Prentice Hall, 2008.
- [19] GUNES, H.; PICCARDI, M. **Assessing facial beauty through proportion analysis by image processing and supervised learning**, International Journal of Human-Computer Studies, v. 64,p. 1184-1199, 2006.
- [20] HONG, A.; CHEN, G.; LI, J.; CHI, Z.; ZHANG, D. **A flower image retrieval method based on ROI feature**, Journal of Zhejiang University. Science, v. 5, p. 764-72, 2004.
- [21] JAIN, A. K.; DUIN, R. P. W.; MAO, J. **Statistical Pattern Recognition: Review**, IEEE Transactions on Pattern Analysis and Machine Intelligence, 22, 2000.
- [22] JANSSEN, I. et al. **Skeletal muscle mass and distribution in 468 men and women aged 18–88 yr**, J Appl Physiol, p. 81–88, 2000.
- [23] JOHN, G. H.; LANGLEY, P. **Static Versus Dynamic Sampling for Data Mining**, Proceedings of the Second International Conference on Knowledge Discovery and Data Mining, 1996.
- [24] JONES, W. E.; KUEHNLE, A. R.; ARUMUGANATHAN, K. **Nuclear DNA content of 26 orchid (Orchidaceae) genera with emphasis on *Dendrobium***, Annals of Botany, v. 82, n. 2, p. 189-194, 1998.
- [25] KARCHER, D.; RICHARDSON, M. **Quantifying turfgrass color using digital image analysis**, Crop Science, p. 943-951, 2003.
- [26] KAWABATA, S.; YOKOO, M.; NII, K. **Quantitative analysis of corolla shapes and petal contours in single-flower cultivars of lisianthus**, Scientia Horticulturae, v. 121, p. 206-212, 2009.
- [27] KOHAVI, R.; JOHN, G. H. **Wrappers for feature subset selection**, Artificial Intelligence, p. 273-324, 1997.
- [28] KOSCHAN, A; ABIDI, M. **Digital Color Image Processing**, Wiley-Interscience, 2008.
- [29] KUDO, M.; SKLANSKY, J. **Comparison of algorithms that select features for pattern classifiers**, Pattern Recognition Society, v. 33, p. 25-41, 2000.
- [30] LEEMANS, V. **On-line Fruit Grading according to their External Quality using Machine Vision**, Biosystems Engineering, v. 83, p. 397-404, 2002.

- [31] LENNA. **Lenna**, 1972. Disponível em: <<http://en.wikipedia.org/wiki/Lenna>>. Acesso em: 20 de Setembro de 2010.
- [32] LERAY, P.; GALLINARI, P. **Feature Selection with Neural Networks** Behaviormetrika, v. 26, 1998.
- [33] LIU, Y.; ZHANG, D.; LU, G. **Region-based image retrieval with high-level semantics using decision tree learning**, Pattern Recognition, v.41, p. 2554-2570, 2008.
- [34] LUTZ, M.; ASCHER, D.; WILLISON, F. **Learning python**, CA: O'Reilly & Associates, 1999.
- [35] LUTZ, M. **Programming Python**, O'Reilly, 2006.
- [36] MIAO, Z.; GANDELIN, M.; YUAN, B. **A new image shape analysis approach and its application to flower shape analysis**, Image and Vision Computing, v. 24, p. 1115-1122, 2006.
- [37] MUMFORD, D; SHAH, J. **Optimal Approximations by Piecewise Smooth Functions and Associated Variational Problems**, Pure Applied in Math, 1989.
- [38] NAGY, G.; ZOU, J. **Interactive visual pattern recognition**, International Conference on Pattern Recognition, Citeseer, p. 478–481, 2002.
- [39] NILSBACK, M.; ZISSERMAN, A. **A visual vocabulary for flower classification**, 2006 IEEE Computer Society Conference on Computer, v. 2, p. 1447-1454, 2006.
- [40] _____. **Automated flower classification over a large number of classes**, Computer Vision, Graphics & Image Processing (ICVGIP'08), Sixth Indian Conference o, p. 722–729, 2008.
- [41] _____. **Delving into the whorl of flower segmentation**, Proceedings of the British Machine Vision Conference, Citeseer, p. 570–579, 2007.
- [42] PEDRINI, H.; SCHWARTZ, W. R. **Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações**, Thomson Learning, 2008.
- [43] PERNER, P. **Image Mining: Issues, Frameworks and Techniques**, Engineering Applications of Artificial Intelligence, vol. 15, p. 205-216, 2002.
- [44] PRAKASH, S.; HOQUE, M. I.; BRINKS, T. **Low costs options for tissue culture technology in developing countries: Culture media and containers**, International Atomic Energy Agency, 2004. p. 29-40.
- [45] SAITOH, T.; KANEKO, T. **Automatic recognition of wild flowers**, Proceedings 15th International Conference on Pattern Recognition (ICPR-2000), p. 507-510, 2000.

- [46] SHIH, F.; CHENG, S. **Automatic seeded region growing for color image segmentation**, Image and Vision Computing, v. 23, p. 877-886, 2005.
- [47] SIEDLECKI, W.; SKLANSKY, J. **A note on genetic algorithms for large-scale feature selection**, Pattern Recognition Letters, v. 10, p. 335-347, 1989.
- [48] SOUZA, F. P. C. **Localização e leitura automática de caracteres alfanuméricos – uma aplicação na identificação de veículos**, Universidade Federal Do Rio Grande Do Sul, Curso de Pós-Graduação em Engenharia Elétrica, Porto Alegre, 2000.
- [49] SILVEIRA, L. M. **Harmonia Cromática - apontamentos para o ensino de uma metodologia de aplicação de cores em projetos gráfico e de móveis**, ARGENCOLOR, p. 471, 2004.
- [50] VICHATO, M. R. M. et al.; **Alongamento de plantas de *Dendrobium nobile* Lindl. com pulverização de ácido giberélico**, Ciênc. agrotec., v. 31, n.1, p. 16-20, 2007.
- [51] TAKAHASHI, L. S. A. **Desenvolvimento de cultivares de *Dendrobium nobile* (ORCHIDACEAE) para o norte do Paraná**. Tese (Doutorado em Agronomia), Universidade Estadual de Londrina, 2006.
- [52] THEODORIDIS, S.; KOUTROU, K. **Pattern Recognition**, Third Edition, Academic Press, 2006.
- [53] WITTEN, I. H.; FRANK, E. **Practical Machine Learning Tools and Techniques**, Second Edition, Elsevier, 2005.
- [54] YOSHIOKA, Y.; FUKINO, N. **Image-based phenotyping: use of colour signature in evaluation of melon fruit colour**, Euphytica, vol. 171, p. 409-416, 2009.
- [55] YOSHIOKA, Y.; IWATA, H.; OHSAWA, R.; NINOMIYA S. **Quantitative evaluation of flower colour pattern by image analysis and principal component analysis of *Primula sieboldii* E**, Euphytica, v. 139, p. 179-186, 2004.
- [56] ZOU, J.; NAGY, G. **Evaluation of model-based interactive flower recognition**, Proceedings of the 17th International Conference on pattern Recognition, Citeseer, p. 311–314, 2004.
- [57] ZHENJIANG, M.; GANDELIN, M.; BAOZONG Y. **An OOPR-based rose variety recognition system**, Engineering Applications of Artificial Intelligence, v. 19, p. 79-101, 2006.