

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
CURSO SUPERIOR DE ENGENHARIA DE COMPUTAÇÃO**

**LUIS FERNANDO GALONETTI**

**ANÁLISE E RECONHECIMENTO DE IMAGENS FOLIARES**

**TRABALHO DE CONCLUSÃO DE CURSO**

**CORNÉLIO PROCÓPIO**

**2016**

**LUIS FERNANDO GALONETTI**

**ANÁLISE E RECONHECIMENTO DE IMAGENS FOLIARES**

Trabalho de conclusão de curso apresentado à disciplina de Trabalho de Conclusão de Curso, do curso de Engenharia de Computação da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de Engenheiro de Computação.

Orientador: Prof. Dr. Claiton de Oliveira

**CORNÉLIO PROCÓPIO**

**2016**



Ministério da Educação  
Universidade Tecnológica Federal do Paraná  
Câmpus Cornélio Procópio  
Nome da Diretoria  
Nome da Coordenação  
Nome do Curso



---

## TERMO DE APROVAÇÃO

### ANÁLISE E RECONHECIMENTO DE IMAGENS FOLIARES

por

**LUIS FERNANDO GALONETTI**

Este Trabalho de Conclusão de Curso de graduação foi julgado adequado para obtenção do Título de Bacharel em Engenharia de Computação e aprovado em sua forma final pelo Programa de Graduação em Engenharia de Computação da Universidade Tecnológica Federal do Paraná.

Cornélio Procópio, 10/06/2016

---

Prof. Dr. Claiton de Oliveira

---

Profa. Dra. Priscila Tiemi Maeda Saito

---

Prof. Dr. Pedro Henrique Bugatti

"A Folha de Aprovação assinada encontra-se na Coordenação do Curso"

## **AGRADECIMENTOS**

Todos esses anos de faculdade me trouxeram ótimas experiências, grandes amizades e momentos que levarei por toda a vida. Aos meus queridos amigos, profundo sentimento de gratidão e respeito. À minha família, agradeço por todo o apoio, vocês são incríveis!

Ao professor Dr. Claiton de Oliveira agradeço pela oportunidade e pela orientação deste trabalho.

## RESUMO

GALONETTI, Luis Fernando. ANÁLISE E RECONHECIMENTO DE IMAGENS FOLIARES. 55 f. Trabalho de conclusão de curso – Curso Superior de Engenharia de Computação, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2016.

O processo de indexação e recuperação de imagens tem aplicações em diversas áreas do conhecimento como medicina, botânica, robótica, indústria, entre outros. No entanto, a escolha e aplicação de técnicas e metodologias de análise e classificação de imagens não é algo trivial. Em muitos casos, a utilização de técnicas combinadas pode significar melhoria nos resultados. Dessa forma, este trabalho de conclusão de curso teve como objetivo realizar um estudo e o desenvolvimento de métodos de análise e reconhecimento de imagens foliares. Os métodos implementados compõem uma aplicação para a extração de características. Os resultados obtidos foram comparados com outros métodos já implementados em trabalhos relacionados.

**Palavras-chave:** processamento de imagens, reconhecimento de padrões, plantas, classificação

## **ABSTRACT**

GALONETTI, Luis Fernando. ANALYSIS AND RECOGNITION OF LEAF IMAGES. 55 f. Trabalho de conclusão de curso – Curso Superior de Engenharia de Computação, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2016.

The process of indexing and retrieval has applications in several areas of knowledge such as medicine, botany, robotics, industry, among others. However, the choice and application of techniques and methods of analysis and classification of images is not trivial. In many cases, the use of combined techniques can mean improvement in results. Thus, research aims to conduct a study and develop methods of analysis and recognition of leaf images. Implemented methods will form a framework for the implementation of subsequent analyzes. The results will be compared with other methods already implemented in related work.

**Keywords:** image processing, pattern recognition, plants, classification

## LISTA DE FIGURAS

FIGURA 1	– Representação do sistema de cores RGB em formato cubo .....	15
FIGURA 2	– Representação do Histograma de uma imagem .....	16
FIGURA 3	– Segmentação baseada em bordas .....	18
FIGURA 4	– Operadores baseados em primeira derivada .....	18
FIGURA 5	– Esqueleto gerado para espécie Pistacia-lentiscus .....	20
FIGURA 6	– Aproximação poligonal gerada para espécie Arbutus-unedo .....	21
FIGURA 7	– Fecho convexo gerado para espécie Crataegus-monogyna .....	22
FIGURA 8	– a) Fronteira digital (b) Re-amostragem (c)Código da Cadeia de 8-direções	23
FIGURA 9	– Assinaturas de distancia em função do ângulo. Em (a), $r(\theta)$ é constante. Em (b), a assinatura consiste de repetições do padrão. ....	24
FIGURA 10	– Ângulo para o cálculo da matriz de co-ocorrência .....	25
FIGURA 11	– Estrutura de uma árvore de decisão .....	30
FIGURA 13	– Exemplo de imagens da base .....	35
FIGURA 14	– Representação do fluxo principal de extração de características .....	38
FIGURA 16	– Amostra de espécies da base de imagens do teste .....	40
FIGURA 17	– Discrepância entre elementos da mesma espécie .....	41
FIGURA 18	– Textura da 5 espécies: Buxus-sempervirens; Daphne-cneorum; Juniperus- oxycedrus; Nerium-oleander; Ruscus-aculeatus .....	41
FIGURA 19	– Coloração de 5 espécies:Daphne-cneorum; Euphorbia-characias; Populus- tremula; Pistacia-terebinthus; Quercus-petraea .....	42
FIGURA 20	– Comparação entre diferentes espécies e técnicas implementadas .....	45
FIGURA 21	– Amostra de espécies selecionadas .....	45
FIGURA 22	– Desempenho dos classificados nos experimentos .....	48
FIGURA 23	– Ranking dos classificadores com base na taxa de acurácia .....	48
FIGURA 24	– Comparativo entre características e técnicas utilizadas .....	50
FIGURA 25	– Comparativo entre os melhores resultados .....	50

## LISTA DE TABELAS

TABELA 1	– Matriz de Confusão .....	31
TABELA 4	– Resultados Experimento 1 .....	40
TABELA 5	– Resultados Experimento 2 .....	43
TABELA 6	– Resultados Experimento 3 .....	44
TABELA 7	– Resultado do Experimento com seleção de espécies .....	46
TABELA 8	– Resultados Experimento 4 .....	47
TABELA 9	– Seleção de Atributos .....	49
TABELA 10	– Resultados da seleção de atributos .....	49



## LISTA DE SIGLAS

QCCH	Quantized Compound Change Histogram
BIC	Border/Interior pixel Classification
CGCH	Cumulative Global Color Histogram
ARFF	Attribute-Relation File Format
VCF	Vetor de Características de Forma
VCT	Vetor de Características de Textura
VCC	Vetor de Características de Cor
VCFT	Vetor de Características de Forma e Textura
VCFC	Vetor de Características de Forma e Cor
VCTC	Vetor de Características de Textura e Cor
VCFTC	Vetor de Característica de Forma, Textura e Cor
VCF+E	Vetor de Características de Forma + Esqueletização
VCF+FC	Vetor de Características de Forma + Fecho Convexo
VCFTC+E	Vetor de Características de Forma, Textura e Cor + Esqueletização
VCFTC+FC	Vetor de Características de Forma, Textura e Cor + Fecho Convexo

## SUMÁRIO

<b>1 INTRODUÇÃO</b>	<b>11</b>
1.1 PROBLEMA	12
1.2 OBJETIVOS	12
1.2.1 Objetivo Geral	12
1.2.2 Objetivos Específicos	12
1.3 JUSTIFICATIVA	13
1.4 ORGANIZAÇÃO DO TEXTO	13
<b>2 FUNDAMENTAÇÃO TEÓRICA</b>	<b>14</b>
2.1 PROCESSAMENTO DE IMAGENS DIGITAIS	14
2.2 IMAGENS DIGITAIS	14
2.2.1 Espaço de Cores RGB	14
2.3 VIZINHANÇA DE UM PIXEL	15
2.4 HISTOGRAMA	16
2.5 FILTRAGEM DE IMAGENS	16
2.5.1 Filtro Passa-baixas	17
2.5.2 Filtro Passa-altas	17
2.6 SEGMENTAÇÃO	17
2.6.1 Detecção de Bordas	18
2.7 EXTRAÇÃO DE CARACTERÍSTICAS	19
2.7.1 Descritores Visuais	19
2.8 REPRESENTAÇÃO E DESCRIÇÃO	20
2.8.1 Esqueletização	20
2.8.2 Aproximação Poligonal	21
2.8.3 Fecho Convexo	22
2.8.4 Código da Cadeia	22
2.8.5 Assinatura	23
2.8.6 Descritores de Fourier	24
2.8.7 Matriz de Co-Ocorrência	25
2.8.8 Descritores de Haralick	26
2.8.9 Histograma de alteração quantificada	27
2.8.10BIC (Border/Interior Pixel Classification)	28
2.8.11Cumulative Global Color Histogram (CGCH)	29
2.9 CLASSIFICAÇÃO	29
2.9.1 Validação e Análise de Precisão	31
2.9.1.1 Validação Cruzada	31
2.9.1.2 Matriz de Confusão	31
2.10 TRABALHOS RELACIONADOS	32
<b>3 MATERIAIS E MÉTODOS</b>	<b>34</b>
3.1 DEFINIÇÃO DAS CARACTERÍSTICAS	34
3.2 BASE DE IMAGENS	34
3.3 IMPLEMENTAÇÃO DAS TÉCNICAS E MÉTODOS PROPOSTOS	35

3.4 CLASSIFICAÇÃO E SELEÇÃO COM WEKA .....	37
<b>4 RESULTADOS E DISCUSSÕES .....</b>	<b>39</b>
4.1 EXPERIMENTO 1 .....	39
4.2 EXPERIMENTO 2 .....	42
4.3 EXPERIMENTO 3 .....	43
4.3.1 Experimento 3 com seleção de espécies .....	45
4.4 EXPERIMENTO 4 .....	46
4.5 VISÃO GERAL DOS RESULTADOS .....	47
4.6 SELEÇÃO DE ATRIBUTOS .....	49
4.7 COMPARAÇÃO COM TRABALHO CORRELATOS .....	50
<b>5 CONSIDERAÇÕES FINAIS .....</b>	<b>52</b>
5.1 TRABALHOS FUTUROS .....	53
<b>REFERÊNCIAS .....</b>	<b>54</b>

## 1 INTRODUÇÃO

A partir de 2012, cerca de 2,5 exabytes de dados (1 exabyte equivale a  $10^{18}$  bytes) são criados a cada dia, e esse número está dobrando a cada 40 meses ou mais (MCAFEE; BRYNJOLFSSON, 2012). Boa parte destas informações são arquivos multimídias (imagens e vídeos digitais) e não estão disponibilizados de forma estruturada. Quando deseja-se realizar uma consulta é preciso que estes dados estejam indexados e rotulados. O processo de indexação e recuperação de arquivos multimídias não é algo trivial, assim diversos grupos de pesquisa, tanto acadêmicos como científicos, interessaram-se no desenvolvimento de tecnologias e ferramentas que realizassem essa atividade.

O processamento de imagens digitais, de forma geral, segue cinco etapas básicas, iniciando com a aquisição da base, em seguida, o pré-processamento, segmentação, representação e descrição, e por fim, a etapa de reconhecimento e interpretação (GONZALEZ; WOODS, 2000). A extração de características e sua posterior classificação permite que a etapa de recuperação aconteça de forma dinâmica, de acordo com a busca realizada. Com isso, nos deparamos com a importância do processo de aquisição de características de uma imagem. Este processo, normalmente é realizado com o auxílio de ferramentas, assim, o uso destas que forneçam dados que realmente representem essas imagens torna-se o ponto-chave deste processo.

Várias aplicações em diversas áreas como medicina, botânica, robótica, indústria, entre outros, abordam processos de recuperação de imagens. Este trabalho, em particular, concentra-se na análise de imagens foliares, também chamadas de bioimagens. Tal escolha apoia-se no fato de que, segundo Giulietti e al. (2005), o Brasil possui cerca de 56.000 espécies de plantas, correspondendo a 19% da flora mundial. Parte destas espécies não estão catalogadas, o que revela a necessidade de ferramentas capazes de auxiliar nesta tarefa. Outro fator é a crescente aplicação de técnicas de processamento de imagens voltado à agricultura de precisão, conforme abordado em Campos et al. (2014).

## 1.1 PROBLEMA

O crescente avanço na quantidade de dispositivos capazes de realizar a captura de imagens, contribui para o aumento de dados multimídias. Com a necessidade de se processar, indexar e classificar toda essa informação, o uso de métodos que auxiliam neste processo é imprescindível. Em processamento de imagens, a etapa de reconhecimento e classificação, não é um processo simples e requer o auxílio de diversas técnicas e ferramentas.

Em muitos casos, a utilização de técnicas combinadas pode significar melhoria nos resultados, porém para determinar quais destes devem ser utilizados em conjunto, estudos que atestem seu desempenho, devem ser realizados. No caso da análise de imagens de plantas, o qual é o foco deste trabalho, este processo não é diferente, assim, a verificação de quais técnicas de pré-processamento são mais indicadas, qual técnica é mais apropriada para a extração de características, ou ainda, qual modelo de classificador apresenta um melhor desempenho, são questões que demandam estudo e pesquisa para serem respondidas.

## 1.2 OBJETIVOS

### 1.2.1 OBJETIVO GERAL

Este trabalho de conclusão de curso tem como objetivo geral o estudo e desenvolvimento de métodos de análise e reconhecimento de imagens foliares.

### 1.2.2 OBJETIVOS ESPECÍFICOS

Para atingir o objetivo geral, os seguintes objetivos específicos foram definidos:

- implementar a extração dos esqueletos da folha, por meio da técnica de esqueletização;
- implementar a aproximação poligonal na extração das características de forma;
- implementar a técnica do fecho convexo;
- desenvolver o descritor BIC (*Border/Interior pixel Classification*);
- desenvolver o descritor CGCH (*Cumulative Global Color Histogram*);
- classificar as imagens por meio de suas características utilizando diferentes classificadores;
- analisar os resultados obtidos com a utilização da ferramenta.

### 1.3 JUSTIFICATIVA

O interesse em pesquisas relacionadas a paisagens e a flora do Brasil remonta ao século XVI, quando botânicos europeus visitaram o país para realizar estudos (GIULIETTI; AL., 2005). Hoje em dia, com novas tecnologias e técnicas avançadas, o interesse em estudos da flora, ainda persistem. Quando visto pela ótica da computação, precisamente pela área de visão computacional, existem diversos estudos com foco na análise de imagens foliares e o reconhecimento deste tipo de imagem, torna-se útil em diversas aplicações relacionadas a medicina, botânica, agricultura, entre outros.

Na classificação de imagens, um dos grandes desafios é o processo de extração de características. Nesta etapa, é necessário o uso de ferramentas e por isso, o desenvolvimento destas aplicações torna-se relevante. Temos ainda que a classificação automatizada tem-se tornado uma excelente ferramenta de apoio a tomada de decisão, e em alguns casos alcançado resultados superiores aos obtidos por seres humanos. Além disso, esse trabalho contribui com a continuação da pesquisa desenvolvida por Brilhador (2013), seguindo como um complemento ao trabalho realizado.

### 1.4 ORGANIZAÇÃO DO TEXTO

Este trabalho está organizado da seguinte forma: no Capítulo 2 serão apresentados os principais conceitos teóricos e trabalhos relacionados que embasam esta pesquisa; no Capítulo 3 será apresentada a metodologia adotada para o desenvolvimento das atividades propostas; no Capítulo 4 os resultados e discussões; por fim no Capítulo 5 as considerações finais.

## 2 FUNDAMENTAÇÃO TEÓRICA

Anterior a realização de algumas etapas deste trabalho, foi necessário um estudo dos principais conceitos que embasam a pesquisa. Estes serão apresentados a seguir.

### 2.1 PROCESSAMENTO DE IMAGENS DIGITAIS

O processo que envolve como entrada e retorno uma imagem digital pode ser definido como processamento de imagens digitais (GONZALEZ; WOODS, 2000). Usualmente, os processos de visão computacional precisam de uma etapa de pré-processamento e as imagens de interesse, em certas situações, necessitam de tratamento para se adequar ao formato ou tamanho desejado. Precisam ainda passar pelo processo de filtragem para a remoção de ruídos provenientes do processo de aquisição da imagem.

### 2.2 IMAGENS DIGITAIS


Uma imagem digital pode ser definida como uma função bidimensional,  $f(x,y)$ , em que  $x$  e  $y$  são coordenadas espaciais no plano. A amplitude de  $f$  até qualquer par de coordenadas  $(x,y)$  representa a intensidade ou o nível de cinza da imagem neste ponto. Quando  $x$ ,  $y$  e os valores da amplitude são valores finitos, valores discretos, temos uma imagem digital. Uma imagem digital é composta de um número finito de elementos, cada um dos quais possui uma localização e um valor. Esses elementos são conhecidos como elementos de imagem, ou ainda de pixels (do inglês picture elements) (GONZALEZ; WOODS, 2000).

#### 2.2.1 ESPAÇO DE CORES RGB

O modelo de espaço de cores RGB (*red, green and blue*) é um dos mais conhecidos entre os modelos de cores, especialmente para dados de 8 bits. A teoria do espaço de cores de RGB baseia-se no princípio de que diversos efeitos cromáticos são obtidos pela projeção da luz branca através de filtros vermelho, verde e azul e pela superposição de círculos nas cores

projetadas. Assim, a adição da cor vermelha, verde e azul geram novas cores, quanto mais luz, mais clara será a cor (PENHARBEL et al., ).

Tradicionalmente, o sistema de cores RGB é representado por um cubo de lado R, comprimento G e altura B. A Figura 1 mostra a representação do formato RGB, na forma de um cubo.



**Figura 1: Representação do sistema de cores RGB em formato cubo**

**Fonte: Google Imagens**

### 2.3 VIZINHANÇA DE UM PIXEL

O relacionamento entre um pixel e seus vizinhos pode acontecer de três formas, as quais apresentam como características:

- Conectividade 4: um pixel  $p$  na coordenada  $(x, y)$  tem quatro vizinhos considerando que os pixels vizinhos podem estar acima, abaixo, ou aos lados do pixel central, o qual possui as coordenadas:

$$(x + 1, y)(x - 1, y), (x, y + 1)(x, y - 1)$$

- Conectividade 8: a vizinhança considera os oito pixels vizinhos, além das posições citadas acima, considera-se também as diagonais, que são dados pelas coordenadas:

$$(x + 1, y + 1)(x + 1, y - 1), (x - 1, y + 1)(x - 1, y - 1)$$

- Conectividade M: modifica-se a conectividade 8, de modo a produzir diferentes formas de conexões, usualmente aplicada para a identificação de bordas.


A identificação de rótulos em imagens ou regiões da imagem, pode ser determinada com o uso da conectividade entre pixels, para tanto, é preciso percorrer toda a imagem pixel



a pixel localizando características em comum, como intensidade dos níveis de cinza ou dos canais.

## 2.4 HISTOGRAMA

O histograma de uma imagem digital com níveis de cinza no intervalo  $[0, L - 1]$  é uma função discreta  $h(r_k) = n_k$ , em que  $r_k$  é o  $K$ -ésimo valor de intensidade e  $n_k$  é o número de pixels da imagem com intensidade  $r_k$ . Resumidamente o histograma de uma imagem é a representação do agrupamento dos pixels que possuem a mesma intensidade (GONZALEZ; WOODS, 2000).



**Figura 2: Representação do Histograma de uma imagem**

**Fonte: Adaptado de (MARENGONI; STRINGHINI, 2009)**

É comum a prática de normalizar o histograma, aplicando a divisão de cada valor pelo total de pixels da imagem. Histogramas são a base para inúmeras técnicas de processamento no domínio espacial. Sua manipulação pode ser usada para melhoramento da definição de uma imagem, para compressão, segmentação ou ainda para a descrição de uma imagem.

## 2.5 FILTRAGEM DE IMAGENS

Filtros são ferramentas básicas para a remoção de ruídos, que neste caso, são aqueles que aparecem no processo de aquisição da imagem. Os filtros podem ser do tipo espaciais, que atuam diretamente na imagem, ou de frequência, onde a imagem é transformada para o domínio da frequência usando a transformada de Fourier e então filtrada neste domínio e em seguida, transformada de volta para o domínio do espaço (MARENGONI; STRINGHINI, 2009). Os filtros são normalmente classificados em 3 categorias:

- Passa-baixas: atenua as altas frequências que estão relacionadas com a informação de detalhes da imagem.

- Passa-altas: realça as altas frequências e são normalmente usados para realçar os detalhes na imagem.
- Passa-faixa: seleciona um intervalo de frequências do sinal para ser realçado.

### 2.5.1 FILTRO PASSA-BAIXAS

O efeito visual de um filtro passa-baixas é o de suavização da imagem, tendo em vista que as altas frequências, que correspondem às transições abruptas, são atenuadas. A suavização tende também, pelas mesmas razões, a minimizar o efeito do ruído em imagens (GONZALEZ; WOODS, 2000).

### 2.5.2 FILTRO PASSA-ALTAS

Para filtros passa-altas, o efeito é, em geral, o de tornar mais nítidas as transições entre regiões diferentes, conhecidas como bordas. Porém, um efeito indesejado desses filtros é o de enfatizar o ruído presente na imagem (GONZALEZ; WOODS, 2000).

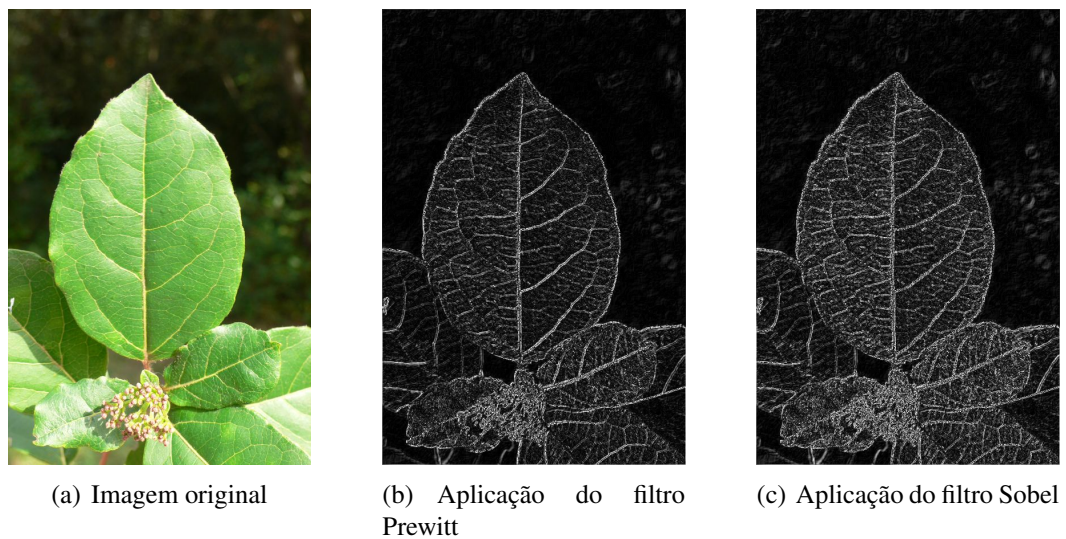
## 2.6 SEGMENTAÇÃO

Casanova (2013) define que a etapa de segmentação refere-se ao processo de dividir uma imagem digital em múltiplas regiões (conjunto de pixels) ou objetos, com o objetivo de simplificar e/ou mudar a representação de uma imagem para facilitar a sua análise. Segundo Gonzalez e Woods (2000) a segmentação está relacionada ao processo de particionar uma imagem em suas partes constituintes ou em objetos. Geralmente, esta tarefa é uma das mais difíceis no processamento de imagens digitais.

As metodologias utilizadas para a segmentação baseiam-se em determinados parâmetros. Com isso, temos as seguintes abordagens:

- Conhecimento global: busca por limiares nas intensidades;
- Baseado em bordas: busca por descontinuidade entre pixels vizinhos;
- Baseada em regiões: busca por similaridade entre pixels vizinhos;

A Figura 3 demonstra o resultado da aplicação de filtros baseados em bordas.



**Figura 3: Segmentação baseada em bordas**

**Fonte: Autoria Própria**

### 2.6.1 DETECÇÃO DE BORDAS

Uma mudança abrupta no nível de intensidade dos pixels, é caracterizada como sendo a borda de uma imagem. Detectores de borda são definidos para localizar este tipo de mudança nos pixels e quando estes estão localizados próximos uns aos outros, podem formar uma borda ou um contorno, definindo uma região ou objeto (MARENGONI; STRINGHINI, 2009). Métodos de detecção de bordas são extremamente utilizado para segmentar imagens. Eles utilizam como base, as variações abruptas (locais) de intensidades entre os pixels (GONZALEZ; WOODS, 2000). Essas variações podem ser determinadas pelas derivadas primeira e/ou derivada segunda.

Com isso, os operadores mais comuns com relação a derivada de primeira, são os operadores de Prewitt e de Sobel, a Figura 4(b)(c) apresenta as máscaras de cada um destes operadores para a detecção de bordas verticais e horizontais.

$Z_1$	$Z_2$	$Z_3$						
$Z_4$	$Z_5$	$Z_6$	-1	-1	-1	-1	0	1
$Z_7$	$Z_8$	$Z_9$	0	0	0	-1	0	1
			1	1	1	-1	0	1

(a) Máscara genérica

-1	-2	-1	-1	0	1
0	0	0	-2	0	2
1	2	1	-1	0	1

(b) Máscara do operador de Prewitt

-1	-2	-1	-1	0	1
0	0	0	-2	0	2
1	2	1	-1	0	1

(c) Máscara do operador de Sobel

**Figura 4: Operadores baseados em primeira derivada**

**Fonte: Adaptado de (MARENGONI; STRINGHINI, 2009)**

## 2.7 EXTRAÇÃO DE CARACTERÍSTICAS

Realizar a escolha correta, de uma técnica de extração de características é um fator extremamente importante para atingir boas taxas de reconhecimento. A extração de características pode ser definida como a captura das informações, que são mais relevantes para fazer uma classificação, de um dado fornecido como entrada.

De acordo com (AMARAL; THOMAZ, 2012) são divididos em 3 grupos, os métodos de extração de características, sendo eles:

- Métodos Locais: possuem duas abordagens principais, a primeira utiliza-se de características geométricas, como distância e forma. A segunda abordagem baseia-se na aparência dos elementos independentes, ou seja, utiliza informações globais de regiões específicas;
- Métodos Globais: também conhecidos como holísticos, representam cada amostra como uma matriz bidimensional, o que possibilita o desenvolvimento de sistemas autônomos utilizando técnicas de aprendizagem;
- Métodos híbridos: conciliam informações locais e globais, visando preservar as vantagens e reduzir as desvantagens de ambos. Com isso, necessita de uma análise mais aprofundada sobre quais características deverão ser utilizadas em conjunto.

### 2.7.1 DESCRITORES VISUAIS

Os descritores são utilizados para transformar a representação visual de uma imagem para uma representação numérica. Buscam calcular de forma eficiente valores que possam descrever uma imagem. Para isso, baseiam-se em características tais como forma, textura e cor.


- Forma: definem desde informações simples como comprimento, perímetro, área, além de informações mais complexas, podem ser baseados em contorno ou região;
- Textura: em imagens digitais, a textura é representada pela variação dos níveis de cinza de uma região ou do todo, de forma que representa a distribuição espacial dos elementos ou dos pixels de uma imagem em uma região;
- Cor: uma das características mais utilizadas no processo de caracterização de imagens, a aplicação e análise do histograma é fundamental para estudar essa propriedade.

## 2.8 REPRESENTAÇÃO E DESCRIÇÃO

Após o processo de segmentação de uma imagem utilizando, por exemplo, alguns dos métodos apresentados anteriormente, o composto de pixels segmentados resultante geralmente é representado e descrito de maneira correta para ser processado posteriormente. A representação de uma região envolve basicamente duas opções: em termos de suas características externas (contorno) ou mediante suas características internas (pixels que constituem a região). Com base nas características escolhidas para representação determina-se uma maneira de descrevê-las (GONZALEZ; WOODS, 2000). A seguir serão apresentados as técnicas de representação (esqueletização, aproximação poligonal e fecho convexo) e alguns descritores de imagens baseados em forma (Código da Cadeia, Assinatura e Descritores de Fourier), textura (Descritores de Haralick e Histograma de Alteração Quantificada) e cor (BIC e CGCH).

### 2.8.1 ESQUELETIZAÇÃO

O conceito de esqueletização foi inicialmente proposta por Blum (1967) e consiste em um processo de reduzir a figura analisada a uma cadeia simples, de apenas um pixel, conforme visto na Figura 5. O esqueleto de uma região pode ser definido pela transformada do eixo médio (MAT, de medial axis transform), proposto por Blum (1967). A MAT de uma região  $R$  com borda  $B$  é definida da seguinte maneira: para cada ponto  $p$  em  $R$ , encontramos seu vizinho mais próximo em  $B$ . Se  $p$  tiver mais de um vizinho, diz-se que ele pertence ao eixo médio (esqueleto) de  $R$ .



**Figura 5: Esqueleto gerado para espécie *Pistacia-lentiscus***

**Fonte: Autoria Própria**

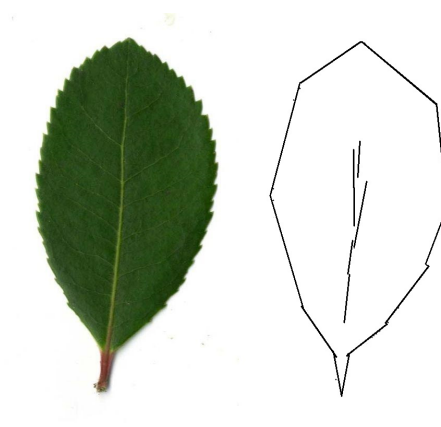
O seguinte conceito se faz interessante para a compreensão da MAT, de "conceito de fogo na planície". Considerando uma região da imagem como se fosse uma planície com grama

uniforme e seca, e imagine que há fogo ao longo de suas fronteiras. Todas as frentes de fogo avançam para dentro da região com mesma velocidade. A MAT da região é o conjunto de pontos alcançado por mais de uma frente de fogo ao mesmo tempo. Normalmente utilizam-se algoritmos de afinamento que eliminam iterativamente pontos da fronteira de uma região, respeitando algumas restrições: (1) não remover os pontos extremos, (2) não quebrar a conectividade e (3) não causar uma erosão excessiva da região (GONZALEZ; WOODS, 2000).

### 2.8.2 APROXIMAÇÃO POLIGONAL

Para que um objeto seja representado podemos utilizar o seu contorno ou a sua região. A representação pelo contorno é a escolha mais natural, nosso sistema visual focaliza os contornos e ignora a uniformidade de regiões. Comumente, usa-se simplificar o contorno de um objeto por sua aproximação poligonal com o propósito de diminuir os possíveis artefatos e ruídos que possam gerar erros em etapas posteriores de processamento (CARVALHO, 2008).

Define-se aproximação poligonal do contorno de um objeto, a ação de encontrar pontos significantes ao longo do contorno do objeto de maneira que estes pontos constituam uma boa aproximação do contorno original. Sua principal vantagem é a compactação dos dados originais, tornando a representação altamente mais eficiente para o cálculo de descritores. Um dos atributos mais importantes que podem ser obtido de um contorno é a curvatura, esta ainda permite a redução do número de pontos do contorno, enquanto ainda mantém a informação necessária para o reconhecimento da forma (CARVALHO, 2008). A Figura 6 mostra a aproximação poligonal para uma espécie de planta, para o qual utilizou um ângulo de 45 graus para a inclinação das retas.




**Figura 6: Aproximação poligonal gerada para espécie Arbutus-unedo**

**Fonte: Autoria Própria**

### 2.8.3 FECHO CONVEXO

Um conjunto  $A$  é considerado convexo se o segmento de linha reta que une quaisquer dois pontos em  $A$  ficar totalmente dentro de  $A$ . O fecho convexo  $H$  de um conjunto arbitrário  $S$  é o menor conjunto convexo que contém  $S$  (GONZALEZ; WOODS, 2000). Ainda segundo (FREITAS, 2000) o fecho convexo de um conjunto de pontos em duas dimensões é definido como o menor polígono convexo que contém todos os pontos. Cada ponto do conjunto ou é um vértice desse polígono (o fecho) ou está no plano.

Em processamento de imagens, o fecho convexo torna-se útil para a representação de formas poligonais complexas por meio de um polígono mais simples. A Figura 7 mostra o fecho convexo, representado pela linha que contorna a folha.



**Figura 7: Fecho convexo gerado para espécie *Crataegus-monogyna***


**Fonte: Autoria Própria**

Com isso, finaliza-se aqui a fundamentação referente às técnicas de representação. Em seguida serão apresentados os descritores utilizados neste trabalho.

### 2.8.4 CÓDIGO DA CADEIA

Para representar o contorno de um objeto utiliza-se códigos da cadeia (*chain codes*), que consiste por seqüência conectada de segmentos de linhas retas de comprimento e direção específicos, normalmente baseado em conectividade de 4 ou 8 segmentos. Utiliza-se um esquema de numeração para codificar a direção de cada segmento, conforme demonstrado na Figura 8.

As imagens digitais são representadas em matrizes com um espaçamento igual nas direções horizontal e vertical, portanto, um código da cadeia pode ser gerado seguindo uma determinada fronteira, em um sentido (horário ou anti-horário) e atribuindo uma direção para os



**Figura 8: a) Fronteira digital (b) Re-amostragem (c)Código da Cadeia de 8-direções**

**Fonte: Adaptado de (GONZALEZ; WOODS, 2000)**

segmentos que conectam cada conjunto de pixels. Contudo, esta abordagem torna-se inaceitável por motivos: a cadeia resultante tende a apresentar tamanho elevado; e as alterações ao longo do contorno causadas por ruídos ou por má segmentação causam alteração no código resultante.

Uma abordagem para contornar esses problemas é utilizar a re-amostragem da fronteira. O Código da cadeia também é dependente do seu ponto de início, para normalizar isto, existem diversas técnicas como a substituição do ponto inicial arbitrário de um sequência de valores para um ponto inicial pertencente a sequencia que forme um inteiro de menor magnitude, considerando-se que o código seja circular (GONZALEZ; WOODS, 2000). Outra metodologia é representar o código da cadeia pelo histograma de direções, o qual traz informações relacionadas a variação da fronteira de um objeto.

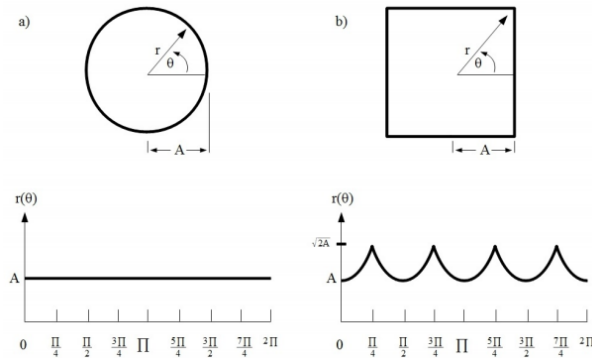
### 2.8.5 ASSINATURA

A assinatura é uma representação de uma fronteira de maneira unidimensional, podendo ser gerada de diversas formas. A mais simples é pelo gráfico de distância da fronteira ao centroide em função do ângulo, conforme visto na Figura 9.

A assinatura demonstrada na Figura 9 é invariante a translação e dependente da rotação e escala com relação a fronteira extraída. Para normalização em relação a rotação pode-se aplicar uma técnica simples que tem como princípio selecionar o mesmo ponto para gerar a assinatura. Uma maneira simples e garantir que o ponto inicial seja o ponto mais distante do centroide. Uma outra alternativa é extrair o Código da cadeia e aplicar a normalização apresentada na seção do Código da cadeia.

Com relação a mudança de escala, considerando que elas sejam uniformes quanto ao eixo pertencente a fronteira e que as amostragens capturadas possuem o mesmo tamanho de intervalo entre elas, então o resultado da assinatura será proporcionalmente diferente em relação a escala das duas imagens. Ainda com relação a escala, para remover as dependências





**Figura 9: Assinaturas de distancia em função do ângulo. Em (a),  $r(\theta)$  é constante. Em (b), a assinatura consiste de repetições do padrão.**

**Fonte: (GONZALEZ; WOODS, 2000)**

de tamanho, pode-se seguir duas técnicas, sendo a primeira mais simples, a qual consiste em normalizar os valores representados na assinatura para o mesmo domínio entre 0 e 1, a outra mais robusta consiste em dividir cada amostragem pela variância da assinatura (GONZALEZ; WOODS, 2000).

### 2.8.6 DESCRITORES DE FOURIER

Os descritores de Fourier são formados pelos coeficientes da transformada discreta de Fourier (DFT). O descritor tem como característica expressar as informações globais da curvatura do objeto extraído da imagem. A transformada discreta de Fourier baseia-se no teorema de Fourier que tem como princípio que toda função contínua pode ser decomposta em uma função de frequências de senos e cossenos. Os dados de entrada de uma DFT são sequências de números discretos ou contínuos (GONZALEZ; WOODS, 2000).

A sequência de números podem ser obtidas de um plano cartesiano através das coordenadas do contorno do objeto. Essas coordenadas podem ser representadas pela função unidimensional definida como:

$$s(k) = x(k) + jy(k)$$

Sendo que  $K = 0, 1, 2, \dots, N - 1$  é número de pontos do contorno,  $x$  é a coordenada real e  $y$  a coordenada imaginária de um plano cartesiano. Pode se utilizar a distância do centroide para formar o eixo real da função.

A transformada discreta de Fourier para o elemento  $s(k)$  é definida como:

$$a(u) = \frac{1}{N} \sum_{k=0}^{N-1} s(k) \exp[-j2\pi uk]/N$$

Os coeficientes  $a(u)$  são chamados de descritores de Fourier do contorno, por meio destes coeficientes é possível aplicar a transformada inversa de Fourier para reconstruir  $s(k)$ :

$$s(k) = \sum_{u=0}^{N-1} a(u) \exp[j2\pi uk]/N$$

A essência da forma de um objeto é armazenada pelos descritores de Fourier de baixa frequência, enquanto os de altas frequência capturam os detalhes mais finos da forma. Com isso, para a reconstrução da forma de um objeto não são necessários todos os coeficientes, podendo considerar apenas os coeficiente de baixa frequência para sua reconstrução. Esses descritores devem ser insensíveis à translação, rotação e diferentes escalas.

### 2.8.7 MATRIZ DE CO-OCORRÊNCIA

A matriz de co-ocorrência considera a relação entre dois pixels por vez, um chamado de pixel referência e o outro de pixel vizinho. O pixel vizinho escolhido em 4 diferentes ângulos  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$  (direita, esquerda acima, abaixo ou diagonal) assim gerando 4 matrizes de co-ocorrência para análise da textura. Há também a distancia em pixel entre o pixel de referência e o vizinho (HARALICK; SHANMUGAM, 1973).

A matriz de co-ocorrência pode ser especificada por uma matriz de frequências relativas na qual dois elementos de textura vizinhos, separados por uma distancia  $d$  em uma orientação  $\theta$  ocorrem em uma imagem, um com uma intensidade 1 e outra com uma intensidade  $j$ . Desta forma, a matriz representa em cada elemento o número de vezes que ocorreu uma transição do nível de cinza de  $A$  para  $B$  considerando a distancia e a direção.




Figura 10: Ângulo para o cálculo da matriz de co-ocorrência

### 2.8.8 DESCRITORES DE HARALICK

Os descritores de Haralick foram apresentados em 1973 e propõem medidas estatísticas e utilizam a distribuição de níveis de cinza, calculados a partir das matrizes de co-ocorrência, para avaliar as diferentes intensidades, podendo ser definidas como: fina, grossa, lisa, ondulada, irregular ou linear. Os 13 descritores propostos estão relacionados abaixo:

- Segundo momento angular (*Angular Second Moment*)

$$f1 = \sum_i \sum_j p(i, j)^2$$

- Contraste (*Contrast*)

$$f2 = \sum_{n=0}^{Ng-1} n^2 \left\{ \sum_{i=1}^N g \sum_{j=1}^N gp(i, j) \right\}_{|i-j=N|}$$

- Correlação ou Variância (*Correlation*)

$$f3 = \frac{\sum_i \sum_j (i, j)p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$$

- Variância da soma (*Sum of Square: Variance*)

$$f4 = \sum_i \sum_j (i - \mu)^2 p(i, j)$$

- Momento Diferença Inverso (*Inverse Difference Moment*)

$$f5 = \sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j)$$

- Soma das médias (*Sum average*)

$$f6 = \sum_i^{2Ng} i p_{x+y}(i)$$

- Soma da Variância (*Sum variance*)

$$f7 = \sum_i^{2Ng} (i - f_6)^2 p_{x+y}(i)$$

- Soma da Entropia (*Sum entropy*)

$$f8 = \sum_i^{2Ng} p_{x+y}(i) \log\{p_{x+y}(i)\}$$

- Entropia (*Entropy*)

$$f9 = - \sum_i \sum_j p(x, y) \log(p(x + y)(i))$$

- Diferença da Variância (*Difference variance*)

$$f10 = \text{variance of } p_{x-y}$$

- Diferença da Entropia (*Difference Entropy*)

$$f11 = \sum_{i=0}^{Ng-1} p_{x-i}(i) \log(p_{x-y}(i))$$

- Informação da Medida de correlação 1 (*Information measure of correlation 1*)

$$f12 = \frac{HXY - HXY1}{\max\{HX, HY\}}$$

- Informação da Medida de correlação 2 (*Information measure of correlation 2*)

$$f13 = (1 - \exp[-2.0(HXY2 - HXY)])^{\frac{1}{2}}$$

$$HXY = - \sum_i \sum_j p(i, j) \log(p(i, j))$$

Adotou-se o histograma completo como característica referente a textura da imagem.

### 2.8.9 HISTOGRAMA DE ALTERAÇÃO QUANTIFICADA

Para a análise de textura, Chao-Bing e Quan Lin propuseram um método conhecido como histograma da alteração quantificada (HUANG; LIU, 2007). Este método possui a lógica de verificar todas as combinações de variações do nível de cinza de um determinado pixel entre os seus vizinhos nas quatro direções e com a diferença da variação são usados para a construção de um histograma de 40 posições (bins).

Por tratar-se de alterações das intensidades, o método é livre de variação entre rotação e translação da imagem. Para o cálculo deste histograma é tomado um pixel como referencia em uma determinada coordenada  $(i, j)$ . A partir disso é tomado um raio  $r$  formando então um conjunto  $Nr(i, j)$ .

Para calcular as variações é adotado uma imagem em escala de cinza onde  $y_r$  e  $r$  o raio desejado para verificar a variação. Considerando as coordenadas espaciais é possível definir as seguintes equações:

$$|y_r(i - r, j) - y_r(i + r, j)| = H_r^y(i, j)$$

É referente a variação na horizontal;

$$|y_r(i, j - r) - y_r(i, j + r)| = V_r^y(i, j)$$

É referente a vertical;

$$|y_r(i - r, j - r) - y_r(i + r, j + r)| = D_r^y(i, j)$$

É referente a diagonal; e

$$|y_r(i + r, j - r) - y_r(i - r, j + r)| = A_r^y(i, j)$$

É referente a anti-diagonal. É importante ressaltar que essas medidas são obtidas em relação a um pixel central  $(i, j)$  e se repete em todos os pixels da imagem. Após obter os valores é calculado a média dos valores utilizando a equação:

$$v(i, j) = [H_r^y(i, j) + V_r^y(i, j) + D_r^y(i, j) + A_r^y(i, j)]/4$$

Depois da média é construído o histograma não uniforme utilizando as seguintes regras:

- se  $v(i, j) \in [0; 15, 5]$  são divididos uniformemente em 16 posições (0,1,...,15);
- se  $v(i, j) \in ]15, 5; 35, 5]$  são divididos uniformemente em 10 posições (16,17,...,25);
- se  $v(i, j) \in ]35, 5; 85, 5]$  são divididos uniformemente em 10 posições (26,27,...,35);
- se  $v(i, j) \in ]85, 5; 115, 5]$  são divididos uniformemente em 3 posições (36,37,38);
- se  $v(i, j) \in ]115, 5; 225]$  é dividido uniformemente em 1 posição (39);

#### 2.8.10 BIC (BORDER/INTERIOR PIXEL CLASSIFICATION)

O algoritmo abordado pelo BIC utiliza o espaço de cores RGB uniformemente quantizado em um número de cores, geralmente  $4 \times 4 \times 4 = 64$ . Esse descritor gera uma representação compacta e consiste em separar os dados da imagem em dois histogramas, um para os pixels de borda e outro para os pixels de interior. Um pixel é considerado interior se seus 4 vizinhos tiverem a mesma cor (após a requantização da imagem), caso contrário será borda. A vizinhança de 4 é usada, ao invés da de 8, pois diminui a complexidade da análise, sem perdas percentuais em termos de eficiência. Em seguida, os dois histogramas são concatenados, e esse vetor representa

as características extraídas pelo BIC (STEHLING et al., 2002). Se o número de pixels interior de uma cor é menor que os de bordas, então pelo menos uma das características é verdadeira:

1. A cor é distribuída em regiões relativamente grandes e com formato irregular.
2. A cor é distribuída em pequenas regiões conectadas tais que a borda de cada região é maior que seu interior.
3. A cor é parte de uma região rica em informações de textura. Se o número de pixels de borda de uma cor é menor que o de interiores, então a cor é distribuída em largas e heterogêneas regiões com formato regular.


#### 2.8.11 CUMULATIVE GLOBAL COLOR HISTOGRAM (CGCH)

O Histograma de cor acumulado ou CGCH tem um algoritmo de extração de características que quantiza o espaço de cor em uma quantidade uniforme de bins e percorre a imagem calculando a quantidade de pixels que pertence a cada bin. O valor de um bin é acumulado no bin seguinte. Desta maneira, o último bin do histograma possui a soma dos valores de todos os bins anteriores acrescido dos valores do próprio bin. Ou seja, computa o histograma acumulado (PENATTI, 2009).

## 2.9 CLASSIFICAÇÃO

A classificação é a forma de se analisar um conjunto de dados e com isso extrair modelos que levam a definição ou a uma categorização (classe). A classificação pode ser do tipo: *aprendizagem supervisionada* - na qual o conjunto de treinamento contém classes para exemplos e desta forma pode-se conhecer os valores desejados como saída e *aprendizagem não supervisionada* - onde a indicação das classes de entradas em que são divididas, não são informadas, sendo necessário o uso de técnicas probabilísticas para definição das classes (DUDA et al., 2001). São métodos que utilizam a classificação supervisionada:

- **Classificação por árvore de decisão:** para classificar os dados, este método utiliza o conceito de árvore, tem-se um conjunto de atributos como entrada e executando uma sequência de testes, onde cada nó define um teste em um dos atributos; os possíveis resultados necessários para atingir o próximo nó ou folha, são as ramificações; as folhas são as predições das classes finais, a saída do classificador, conforme Figura 11. Entre os algoritmos de classificação, árvore de decisão, é um dos mais simples e bem sucedidos (RUSSELL; NORVIG, 2004).



**Figura 11: Estrutura de uma árvore de decisão**

**Fonte: Adaptado de (BRILHADOR, 2013)**

- **Classificador Bayesiano:** supõe que os valores dos atributos são independentes uns dos outros em relação a uma classe, desta forma é comumente descrito na literatura como um classificador ingênuo. A classificação é feita baseada no Teorema de Bayes para calcular a probabilidade da classe, dado o atributo de entrada, sendo feito de maneira indutiva, com o cálculo da probabilidade condicional de cada atributo, dado a classe em questão. A equação abaixo, apresenta a regra de Bayes, tal que  $d$  é o valor observado e  $h_1$  são as hipóteses.

$$v(h_1, d) = \alpha P(d|h_1)P(h_1).$$

- **Ibk (*Instance-Based Learning Algorithms*):** seu aprendizado é baseado na analogia, onde o conjunto de treinamento é formado por vetores de  $n$ -dimensões e cada elemento no conjunto representa um ponto no espaço  $n$ -dimensional. É classificado um algoritmo do tipo *K-Nearest Neighbors* (K-NN). A classificação de uma instância desconhecida é realizada com base nas classes dos K-elementos mais próximos, ou seja, os elementos que apresentarem o grau de similaridade mais elevado com relação a instância desconhecida. O processo de rotulação considera a classe que apresenta a maior frequência entre os k-vizinhos.
- **Redes Neurais Artificiais:** é um modelo matemático baseado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência, a função do neurônio é coletar, processar e enviar sinais elétricos. Uma rede neural é constituída por conjuntos de nós ou camadas, os quais estão interligados entre si por vínculos, e estes são os responsáveis pela propagação das informações entre os nós. Uma condição, quando verdadeira, torna-se ativa e realiza a propagação dos dados. Os componentes de uma rede neural são os sinais  $x_n$ , os pesos sinápticos  $w_n$ , a junção aditiva  $J(x)$  que é um somatório simples das N entradas já com seus respectivos pesos e a função de ativação, a qual fornece um valor binário para ativação ou não, representando a saída  $S(x)$ .

- *Support Vector Machines* (SVM): Máquinas de Vetores de Suporte são embasadas pela teoria de aprendizado estatístico, que estabelece uma série de princípios que devem ser seguidos na obtenção de classificadores com boa generalização, definida como a sua capacidade de prever corretamente a classe de novos dados do mesmo domínio em que o aprendizado aconteceu (LORENA; CARVALHO, 2007). Seu objetivo é determinar os limites de decisão de forma que produzam uma separação ótima entre as classes através da minimização do erro.

## 2.9.1 VALIDAÇÃO E ANÁLISE DE PRECISÃO

Para a análise dos resultados gerados foi necessário utilizar métodos para a validação das classificações. As próximas subseções apresentam os métodos utilizados.

### 2.9.1.1 VALIDAÇÃO CRUZADA

A validação cruzada (Cross Validation) consiste em dividir a base de dados em  $K$  partes ou folds,  $D_1, D_2, \dots, D_k$ , de tamanhos aproximadamente iguais. O conjunto de treinamento e de teste é executado pelo algoritmo de classificação  $K$  vezes e em cada performance, reserva-se uma parte  $D_i$  para o conjunto de testes e o restante para o treinamento, ou seja, não há necessidade de separar as amostras para fase de treinamento ou teste. Para a obtenção do valor da acurácia total, calcula-se a média dos resultados obtidos em cada etapa, obtendo-se assim uma estimativa da qualidade do modelo de conhecimento gerado. O valor escolhido para  $K$  pode variar entre 2 e  $N$ , sendo 10 o mais utilizado, conhecido como *Ten-Fold Cross-Validation*.

### 2.9.1.2 MATRIZ DE CONFUSÃO

A matriz de confusão é uma matriz de erros gerados por um classificador, onde os dados variam entre verdadeiro positivo, falso positivo, verdadeiro negativo e falso negativo, conforme observado na Tabela 1.

**Tabela 1: Matriz de Confusão**

Classes Reais	Classes Preditas	
Classe 1	Verdadeiro Positivo ( $V_P$ )	Falso Negativo ( $F_N$ )
Classe 2	Falso Positivo ( $F_P$ )	Verdadeiro Negativo ( $V_N$ )

Métricas de qualidade para as classificações, como a acurácia e a taxa de erros podem ser obtidas por meio da matriz de confusão:



$$Acuracia : Acc = \frac{V_P + V_N}{V_P + F_P + V_N + F_N}, TaxadeErro : E = \frac{F_P + F_N}{V_P + F_P + V_N + F_N}$$

A acurácia e a taxa de erro são métricas de análise de desempenho, porém não são indicadas quando as instâncias entre as classes estão desbalanceadas, podendo inferir em dados enganosos.

## 2.10 TRABALHOS RELACIONADOS

Brilhador et al. (2013) realizou uma significativa pesquisa onde propôs o desenvolvimento de um *framework* capaz de agrupar técnicas de descrição e classificação, afim de caracterizar bioimagens. Seus experimentos mostraram que o *framework* desenvolvido alcançou resultados notáveis de precisão em relação a classificação de espécies de plantas. Porém, maiores resultados não foram alcançados devido a falta de características que poderiam permitir um maior detalhamento na discretização de folhas.

Colonhezi (2013) desenvolveu um software de código livre capaz de extrair características de imagens com ênfase em textura, com o uso de descritores de Haralick e Histograma de Variação Quantificada. Apresentou também uma análise de diferentes formas de classificação para auxiliar na recuperação de folhas de várias espécies, também realizou uma análise sobre o impacto de métodos de seleção de atributos. Os resultados obtidos demonstraram alta taxa de classificação, além da contribuição de um software de código livre. O trabalho não implementou técnicas para a eliminação de ruídos em imagens e partes não interessantes para a classificação, o que poderia aumentar o foco nas características mais importantes de cada classe.

Carvalho (2008) apresentou um trabalho que realizava um estudo a respeito de métodos de aproximação poligonal. Propôs dois métodos, sendo um aplicado diretamente no contorno e outro obtido a partir da função tangencial do contorno original. Como resultado, ambos os métodos mostraram-se eficientes na remoção de ruídos e artefatos, enquanto que características relevantes para etapas de pós-processamento eram mantidas. Os métodos desenvolvidos em seu trabalho foram aplicados para o problema de classificação de lesões de mama e os resultados encontrados mostraram que o uso de aproximação poligonal gera a compactação dos dados e uma melhor representação do contorno inicial.

Iwata e Saitoh (2013) propôs uma técnica de reconhecimento via representação esparsa para a identificação automática de plantas. Para a modelagem das folhas, utilizou-se

um dicionário representando as imagens de treinamento de cada espécie. Cada dicionário foi treinado utilizando um conjunto de descritores, de maneira que cada descritor fosse representado por uma combinação linear. Para o teste, calculou-se a correlação entre a imagem e cada dicionário para tentar identificar cada imagem. Como resultado, o reconhecimento eficiente pode ser alcançado além da ferramenta proposta, levando a uma representação mais compacta e rica de imagens de folhas em comparação as abordagens tradicionais. Como trabalhos futuros, pretende-se implementar o sistema em uma aplicação móvel.

Hsiao et al. (2014) abordou um método de reconhecimento de árvores com base em imagens de folhas através da análise da forma e características das cores da folha. O método proposto necessitava de duas imagens, a primeira da parte superior da folha e a segunda da parte posterior, e ambas deviam possuir o fundo branco. Primeiramente, uma região da folha é extraída automaticamente com o uso de um método com base em cortes gráficos. Em seguida, algumas características de forma, cor e tamanho são calculados a partir da região extraída e então comparadas com um conjunto de árvores aleatórias. Os resultados demonstraram que a precisão do reconhecimento para imagens da parte de trás das folhas foram maiores que imagens frontais. Verificou-se também que para a identificação de um conjunto maior de espécies, seria necessário a inclusão de outras características, como a margem e as nervuras da folha. Como trabalhos futuros, sugere-se implementação de um aplicativo.

### 3 MATERIAIS E MÉTODOS

Neste capítulo serão descritas as etapas seguidas e as decisões tomadas para o desenvolvimento do trabalho.

#### 3.1 DEFINIÇÃO DAS CARACTERÍSTICAS

O foco principal deste trabalho é a extração de características de forma, as quais podem ser divididas em 3 tipos: contorno, região e transformadas. Para isso, foram utilizados os descritores de contorno para a representação das imagens, sendo eles o Código da Cadeia, Assinatura em função da distância do ângulo, e os Descritores de Fourier. Implementou-se também 3 técnicas de representação, relacionadas ao contorno de objetos: aproximação poligonal, fecho convexo e esqueletização.

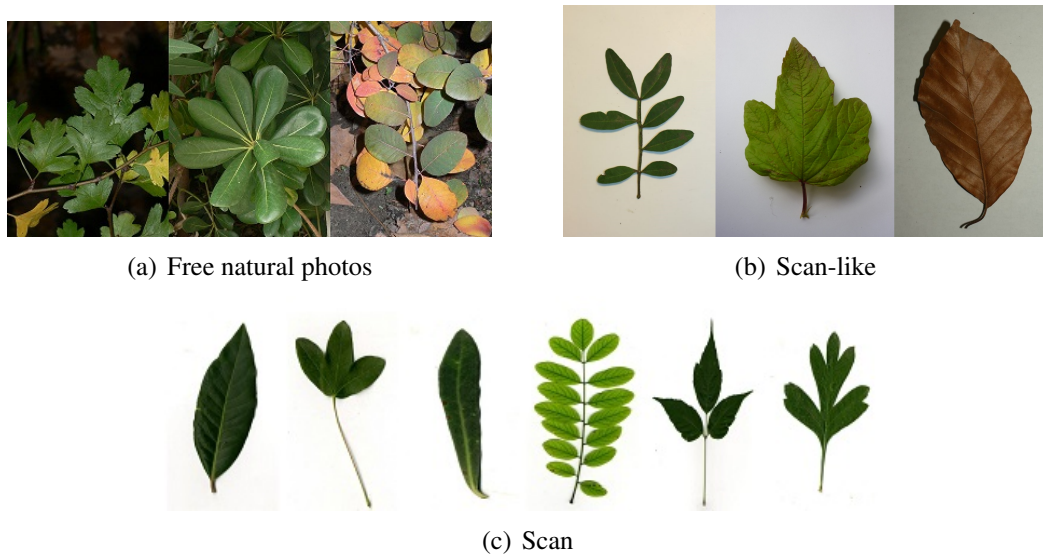
Embora o foco deste trabalho seja em atributos relacionados a forma, como tentativa de tornar a aplicação mais completa, foram implementados 2 descritores de textura, sendo eles os Descritores de Haralick e Histograma de alteração quantificada, do inglês *Quantized Compound Change Histogram* (QCCH). E por fim, implementou-se mais 2 descritores de cor, o Border/Interior Classification (BIC) e o Cumulative Global Color Histogram (CGCH), tornando a aplicação completa com relação a gama de descritores baseados em características primitivas, contendo descritores de textura, cor e forma.

#### 3.2 BASE DE IMAGENS

A base de imagens utilizada no trabalho faz parte do concurso de identificação de plantas ImageCLEF 2012, o qual faz parte da CLEF 2012 (LLC, 2012). Este conjunto de dados baseia-se no *Pl@ntLeaves dataset 2* e todos os dados foram disponibilizados com licença *creative commons*. O tamanho da base é de 11.527 imagens, de 126 espécies diferentes de árvores francesas oriundas do Mediterrâneo. A base conta ainda com uma subdivisão em três grupos de imagens:

- Scan (57%);
- Scan-like (24%);
- Free natural photos (19%).

As imagens *scan* são obtidas a partir de um scanner. As do segundo grupo, são fotografadas com a folha sobre um papel com a cor branca, e as *free natural photos* são fotografadas em seu ambiente natural.



**Figura 13: Exemplo de imagens da base**

**Fonte: Autoria Própria**

Neste trabalho, utilizou-se as classes de imagens do tipo scan, apresentadas na Figura 13(c). Ao todo são 4.870 imagens alocadas em 126 espécies distintas, porém elas não estão divididas uniformemente, de modo que algumas espécies apresentam grandes quantidade de imagens e outras apenas poucas unidades. Desta forma, foi necessário realizar uma separação, para isso, calculou-se a média aritmética da quantidade de espécies, verificou-se quais possuíam uma quantidade inferior a esta média, e então foram descartadas. O número de espécies foi reduzido para 53 e a quantidade de imagens para 3.655. Para a geração dos arquivos de treino e teste, dividiu-se 80% para o primeiro e 20% para o segundo.

### 3.3 IMPLEMENTAÇÃO DAS TÉCNICAS E MÉTODOS PROPOSTOS

Após o término do estudo e da pesquisa preliminar, iniciou-se a implementação dos métodos e das técnicas propostas. Para isso, uma aplicação desktop, implementada na linguagem C/C++ foi desenvolvida. A ferramenta de desenvolvimento QtCreator 5.5.1 foi utilizada

integrada ao OpenCV 3.1.0, que é uma biblioteca open-source de visão computacional, para a extração e processamento de dados a partir de imagens digitais. Sua integração como Qt Creator foi realizada seguindo os passos indicados no guia desenvolvido por Horikoshi (2015).

Para eliminar os ruídos presentes nas imagens da base, utilizou-se duas técnicas de filtragem, o Filtro da Média e da Mediana, tendo sido utilizado o segundo, com uma máscara tamanho 7x7, por ter apresentado melhor resultado. Em seguida, passou-se para o desenvolvimento dos algoritmos de extração do objeto, etapa de segmentação, sendo desenvolvidas 3 técnicas de limiarização: Máxima entropia, método de Otsu e também a possibilidade de informar o valor do limiar manualmente. A técnica utilizada neste trabalho foi o método de Otsu, pois este apresentou os melhores resultados quando aplicados nas imagens da base.

Após isso pode-se iniciar a implementação do algoritmo para a esqueletização, do fecho convexo e da aproximação poligonal, respectivamente. Para o primeiro, seguiu-se os procedimentos apresentados por Gonzalez e Woods (2000), que consiste em desenvolver um algoritmo iterativo para marcar determinados pontos da imagem, avalia-los de acordo com regras específicas e eliminar esses pontos. O algoritmo realiza diversas iterações e por isso, demanda um maior custo em sua execução.

Para o algoritmo do cálculo do fecho convexo, utilizou-se como base o material apresentado por Mallick (2015), além de diversas funções da biblioteca OpenCV. Primeiramente utilizou-se a função *FindContours*, para encontrar o contorno do objeto de interesse, neste caso a folha, e com isso utilizou-se o vetor de posições do contorno resultante como parâmetro de entrada para a função *ConvexHull*, responsável por encontrar o fecho convexo de cada ponto. Realizando estes passos, o fecho convexo era calculado e armazenado em uma nova imagem. Por último, para a aproximação poligonal utilizou-se a função *approxPolyDP*, também pertencente ao OpenCV, para auxiliar no cálculo da aproximação. Para tanto detectava-se as bordas utilizando o Detector de Canny, acessado pela função *Canny* e em seguida encontrava-se os contornos, calculava-se a aproximação de acordo com o ângulo informado, ao fim, computava a matriz resultante obtendo a aproximação poligonal.

Desta forma, iniciou-se a etapa de implementação dos descritores, começando pelos de forma, sendo o primeiro deles o Código da Cadeia, juntamente com o uso do histograma de direções para representar as características, pois o uso direto do Código da Cadeia pode resultar em uma cadeia muito grande de valores, sendo o seu histograma uma boa simplificação para sua representação. Em seguida, desenvolveu-se a Assinatura em função da distância do ângulo e para a sua representação utilizou-se as medidas de dispersão sobre o sinal da assinatura, de formar a tornar a representação da assinatura invariante com relação ao ponto inicial e também

para simplificar a representação do vetor de características resultante. Os Descritores de Fourier foram os últimos descritores de forma a serem implementados, que basicamente consistia em percorrer o objeto aplicando a Transformada de Fourier em cada conjunto de pontos do contorno.

Os descritores de textura e cor foram os próximos a serem inseridos na aplicação. O descritor de Haralick foi desenvolvido posterior ao algoritmo para o cálculo da Matriz de Co-Ocorrência. Após isso, desenvolveu-se o código referente ao Histograma de alteração quantificada (QCCH), finalizando os descritores de textura. O descritor BIC e o CGCH foram os dois últimos a serem adicionados na aplicação. Com isso, a aplicação possui ao todo a possibilidade de escolha entre 7 tipos de descritores, além da combinação com 3 técnicas de pré-processamento, esqueletização, fecho convexo e aproximação poligonal, embora esta última não tenha sido implementada eficientemente, funcionando apenas para algumas espécies de plantas.

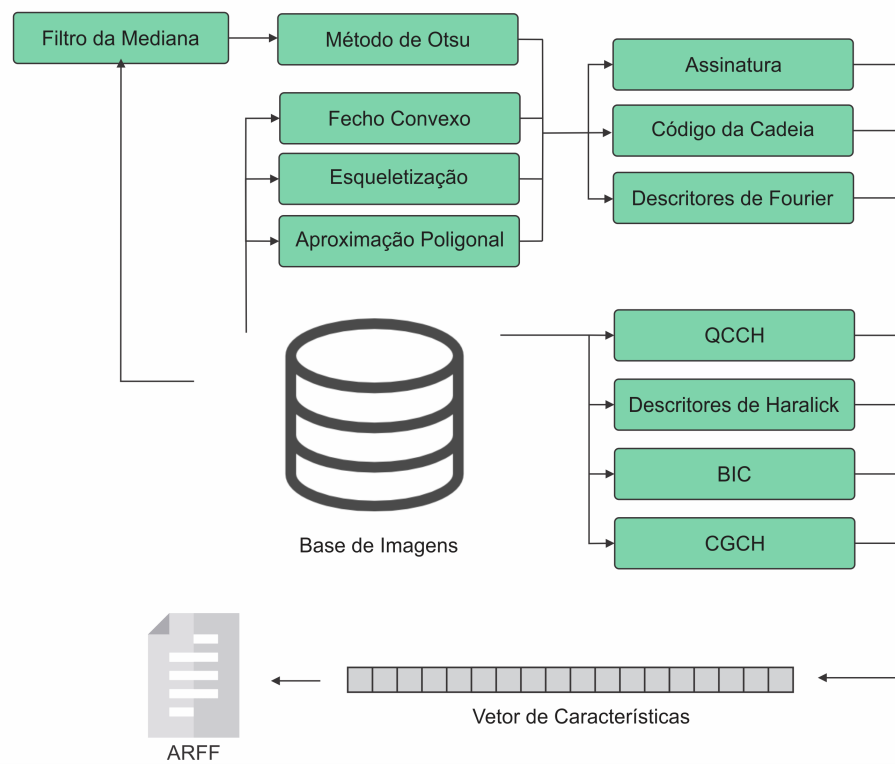
Por fim, desenvolveu-se a parte da aplicação responsável pelo gerenciamento e criação do arquivo de saída, contendo as características extraídas da base. A interface permite ao usuário escolher qual técnica e quais descritores deseja combinar. Também é possível informar o local onde encontra-se a base de imagens e o diretório para o arquivo de saída, que é formatado no padrão ARFF. Este processo pode ser visualizado na Figura 14.

### 3.4 CLASSIFICAÇÃO E SELEÇÃO COM WEKA

Após a extração das características das imagens o próximo passo é a classificação. A aplicação disponibilizará uma opção para gerar um arquivo de saída nos padrões definidos para uso na ferramenta de classificação Weka.

Esta ferramenta, segundo Waikato (2010) é um conjunto de algoritmos de aprendizado de máquina para tarefas de mineração de dados. Os algoritmos podem ser aplicados diretamente para um conjunto de dados ou chamado a partir de seu próprio código Java. Weka contém ferramentas para pré-processamento de dados, classificação, regressão, clustering, regras de associação, e visualização. É também bem adequada para o desenvolvimento de novos sistemas de aprendizagem máquina.

Assim, nesta parte do trabalho, deverá ser possível analisar o grau de acurácia obtido para cada classificador aplicado ao conjunto de características e verificar qual apresenta o melhor resultado, dentro de cada cenário proposto. Os métodos para análise foram apresentados na subseção 2.9.1.



**Figura 14: Representação do fluxo principal de extração de características**

**Fonte: Autoria Própria**

## 4 RESULTADOS E DISCUSSÕES

Para a realização dos testes, foram esquematizados 5 cenários, sendo cada um representado pelos experimentos:

- **Experimento 1:** comparativo entre os classificadores utilizando características de textura, cor e forma de maneira individual;
- **Experimento 2:** combinação de descritores de forma e textura; forma e cor; textura e cor; forma, textura e cor;
- **Experimento 3:** descritores de forma com a aplicação da técnica do fecho convexo e descritores de forma com aplicação da técnica de esqueletização;
- **Experimento 4:** combinação de todos os descritores (3 de forma, 2 de textura e 3 de cor) juntamente com as técnicas de pré-processamento: esqueletização e fecho convexo.
- **Experimento 5:** utilização da técnica de seleção de atributos com aplicação de um classificador. Para validar os resultados, aplicou-se a técnica de validação cruzada (subseção 2.9.11) com o valor de K igual a 10 (*Ten-Fold Cross Validation*).

### 4.1 EXPERIMENTO 1

Neste primeiro caso foram utilizados 3 vetores de características distintos, denominados Vetor de Características de Forma (VCF), Vetor de Características de Textura (VCT) e Vetor de Características de Cor (VCC), organizados da seguinte maneira:

**VCF:**[1-5] medidas de dispersão em função da assinatura, [6-13] histograma do código da cadeia, [14-139] descritores de Fourier. Totalizando 140 atributos com a classe rótulo de cada instância.

**VCT:** [1-40] Histograma de alteração quantificada, [41-92] descritores de Haralick, totalizando 93 atributos contando com a classe.



VCC: [1-128] histograma dos pixels de borda e interior gerado pelo BIC, [129-192] histograma acumulado pelo CGCH, totalizando 193 atributos com a classe.

Com isso, aplicou-se a classificação utilizando os seguintes métodos: IBK, Naives Bayes, J48, Random Forest, MultiLayer Perceptron e Support Vector Machines, métodos descritos na seção 2.12.

**Tabela 4: Resultados Experimento 1**

Classificador	Acurácia (%)			Média
	VCF	VCT	VCC	
RandomForest	62,2	83,5	88,9	78,2
MultilayerPerceptron	12,1	83,7	30,9	42,2
IBK	42,2	78,9	75,6	65,6
SVM	30,2	75,2	65,5	57,0
J48	42,6	67,6	67,6	59,3
NaiveBayes	27,3	61,2	59,4	49,3

Fonte: Autoria Própria

Uma análise dos valores apresentados na Tabela 4 demonstra que as características de textura e cor são superiores às de forma. Para tanto, faz-se necessário realizar uma análise mais detalhada entre cada espécie. Ao analisar 5 espécies diferentes que compõem a base de imagens, conforme visto na Figura 16, nota-se uma grande semelhança entre seus formatos. O contorno observado, de modo geral, é semelhante e isto indica que os descritores implementados encontraram dificuldade em distinguir essas espécies, pois as características que são representadas por estes estão relacionadas com a forma global do objeto (BRILHADOR, 2013).



**Figura 16: Amostra de espécies da base de imagens do teste**

Fonte: Autoria Própria

Outro fator que influenciou no baixo valor de acurácia atingido pelos classificadores foi a variação na forma das instâncias que compõem um mesmo conjunto de espécie, não havendo uma padronização e definição de uma classe majoritária (BRILHADOR, 2013). Conforme visto na Figura 17(a), para a espécie *Pittosporum-tenuifolium*, é visível a variação de padrão entre


algumas amostras de folhas. E na Figura 17(b), verifica-se deformidades e anomalias nas folhas da espécie *Buddleja-davidii*, influenciando diretamente no contorno.



**Figura 17: Discrepância entre elementos da mesma espécie**

**Fonte: Autoria Própria**

Com relação a cor e a textura, embora estas tenham alcançado melhores resultados, ainda existem fatores que influenciaram de maneira negativa na discretização das espécies, como por exemplo a variação na coloração e o efeito de reflexão de luz que ocorre durante a etapa de aquisição da imagem (COLONHEZI, 2013). Já os fatores que contribuíram de maneira positiva, temos que diversas espécies possuem um estilo de textura único, sendo altamente distintos entre si, ou seja, possuem baixo grau de similaridade, isso permite que cada classe tenha características bem definidas e distintas. Este motivo pode ser confirmado observando-se a Figura 18, onde são apresentadas 5 amostras da base, com ênfase na textura.



**Figura 18: Textura da 5 espécies: Buxus-sempervirens; Daphne-cneorum; Juniperus-oxycedrus; Nerium-oleander; Ruscus-aculeatus**

**Fonte: Autoria Própria**

De modo similar com o que ocorre com a textura, as características de cor também apresentam resultados relevantes. As classes também apresentam baixo grau de similaridade com relação a essas características. Embora a cor predominante das imagens da base seja o verde, ele está presente em diversos tons, além das espécies que apresentam coloração diversificada, conforme visto na Figura 19.



**Figura 19: Coloração de 5 espécies: Daphne-cneorum; Euphorbia-characias; Populus-tremula; Pistacia-terebinthus; Quercus-petraea**

**Fonte: Autoria Própria**

## 4.2 EXPERIMENTO 2

Neste experimento foram utilizados 4 vetores de características distintos, denominados Vetor de Características de Forma e Textura (VCFT), Vetor de Características de Forma e Cor (VCFC), Vetor de Características de Textura e Cor (VCTC) e Vetor de Característica de Forma, Textura e Cor (VCFTC) organizados da seguinte maneira:

**VCFT:** [1-5] medidas de dispersão em função da assinatura, [6-13] histograma do código da cadeia, [14-139] descritores de Fourier, [140-179] Histograma de alteração quantificada, [180-231] descritores de Haralick. Totalizando 232 atributos contabilizando com a classe rótulo de cada instância.

**VCFC:** [1-5] medidas de dispersão em função da assinatura, [6-13] histograma do código da cadeia, [14-139] descritores de Fourier, [140-267] histograma dos pixels de borda e interior gerado pelo BIC, [268-331] histograma acumulado pelo CGCH, totalizando 332 atributos com a classe.

**VCTC:** [1-40] Histograma de alteração quantificada, [41-92] descritores de Haralick, [93-220] histograma dos pixels de borda e interior gerado pelo BIC, [221-284] histograma acumulado pelo CGCH, totalizando 285 atributos com a classe.

**VCFTC:** [1-5] medidas de dispersão em função da assinatura, [6-13] histograma do código da cadeia, [14-139] descritores de Fourier, [140-179] Histograma de alteração quantificada, [180-231] descritores de Haralick, [232-359] histograma dos pixels de borda e interior gerado pelo BIC, [360-423] histograma acumulado pelo CGCH, totalizando 424 atributos com a classe.

Com isso, aplicou-se a classificação utilizando os seguintes métodos: IBK, Naives

Bayes, J48, Random Forest, MultiLayer Perceptron e Support Vector Machines, métodos descritos na seção 2.12.

Uma rápida análise dos valores apresentados na Tabela 5 demonstra que a junção de características resulta em um melhor valor de acurácia, para a maioria dos casos. No experimento anterior, o uso de características de cor e textura provaram bons resultados, e neste experimento, percebe-se que o uso combinado dessas características promoveu um ganho significativo para o valor de acurácia. Os melhores resultados foram para o VCTC, que agregava características de textura e cor, e para o VCFTC, que agrupava todas as características, sendo que ambos apresentaram uma taxa superior à 90%, para o classificador RandomForest. Os demais resultados podem ser vistos na Tabela 5.

**Tabela 5: Resultados Experimento 2**

Classificador	Acurácia (%)				Média
	VCFT	VCFC	VCTC	VCFTC	
RandomForest	86,1	89,5	92,1	92,0	89,9
SVM	83,8	79,6	83,9	88,0	83,8
IBK	82,2	80,4	82,9	84,8	82,6
J48	67,0	68,1	74,6	72,3	70,5
NaiveBayes	48,7	45,9	73,3	57,0	56,2
MultilayerPerceptron	25,2	14,8	47,9	14,5	25,6

Ao longo dos testes realizados torna-se evidente que as características de textura e cor exercem uma maior influência na caracterização das imagens. Como dito anteriormente, o fato das classes possuírem um estilo de textura diversificado entre cada espécie, contribuiu de maneira positiva. Quando associado à características de cor, que também partilham destas qualidades, melhoraram a definição da classe majoritária, facilitando a caracterização entre as espécies. Dentre as 4 combinações realizadas para o Experimento 2, pode-se perceber um ganho quando comparado aos resultados do Experimento 1, onde as características eram utilizadas individualmente. Com isto tem-se que a combinação de descritores contribuiu para o aumento na taxa de acurácia dos classificadores.

### 4.3 EXPERIMENTO 3

No Experimento 3 aplicou-se a técnica do fecho convexo e da esqueletização, de modo que fossem gerados 2 vetores de características distintos, denominados Vetor de Características de Forma + Esqueletização (VCF+E) e Vetor de Características de Forma + Fecho Convexo (VCF+FC), organizados da seguinte maneira:

**VCF+E:**[1-5] medidas de dispersão em função da assinatura, [6-13] histograma do

código da cadeia, [14-139] descritores de Fourier. Totalizando 140 contabilizando com a classe rótulo de cada instância.

**VCF+FC:**[1-5] medidas de dispersão em função da assinatura, [6-13] histograma do código da cadeia, [14-139] descritores de Fourier. Totalizando 140 contabilizando com a classe rótulo de cada instância.

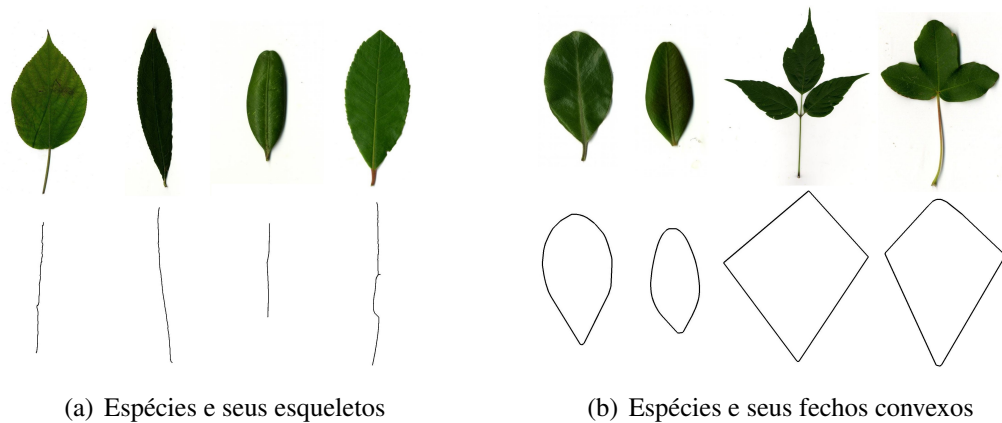
Com isso, aplicou-se a classificação utilizando os seguintes métodos: IBK, Naives Bayes, J48, Random Forest, MultiLayer Perceptron e Support Vector Machines, métodos descritos na seção 2.12.

Os resultados obtidos para este experimento não foram satisfatórios, quando comparados aos experimentos anteriores. Os valores de acurácia apresentaram uma queda significativa com o uso das técnicas de esqueletização e do fecho convexo. O melhor resultado foi de 36% para a combinação de características de forma com o fecho convexo, para o classificador IBK, e para a esqueletização, o melhor resultado foi de 34,6% para o classificador RandomForest, conforme apresentado na Tabela 6.

**Tabela 6: Resultados Experimento 3**

Classificador	Acurácia (%)		Média
	VCF+E	VCF+FC	
IBK	29,1	36,0	32,6
RandomForest	34,6	35,7	35,2
NaiveBayes	23,1	29,3	26,2
SMO	24,5	28,6	26,6
J48	23,4	28,0	25,7
MultilayerPerceptron	14,4	16,4	15,4

A aplicação de técnica de esqueletização pode não ter sido satisfatória, dado o fato de que o esqueleto gerado para diferentes espécies de plantas tenham alto grau de similaridade, como visto na Figura 20(a), que apresenta o esqueleto gerado para quatro classes diferentes. Embora sejam distintas, o esqueleto possui uma grande semelhança e isto faz com que as características do contorno do esqueleto geradas pelo descritor de forma, sejam próximas, resultando no baixo grau de acurácia encontrado pelos classificadores. O mesmo acontece com o fecho convexo, onde espécies diferentes apresentam fecho com certo grau de similaridade, como pode ser verificado na Figura 20(b).



**Figura 20: Comparação entre diferentes espécies e técnicas implementadas**

Com isso, podemos dizer que a combinação da técnica de esqueletização e do fecho convexo com características de forma, não promoveu a melhoria na acurácia nos classificadores, dentro do cenário escolhido para este experimento. A aplicação destas técnicas podem ser satisfatória para base de imagens que possuam espécies bem diferentes, com relação ao seu formato.

#### 4.3.1 EXPERIMENTO 3 COM SELEÇÃO DE ESPÉCIES

Baseando-se nos resultados obtidos no Experimento 3, decidiu-se refazer-lo, porém realizando uma seleção nas espécies. Escolhendo-se de maneira aleatória, as que apresentavam uma maior distinção entre os formatos de suas folhas, na Figura 21, podemos visualizar algumas espécies selecionadas para este experimento e perceber que elas apresentam formatos bem característicos. Com a realização da seleção de espécies, houve-se uma redução na quantidade de classes, de um total de 53 espécies para 26.



**Figura 21: Amostra de espécies selecionadas**

**Fonte: Autoria Própria**

Com isso, aplicou-se a classificação utilizando os seguintes métodos: IBK, Naives Bayes (NB), J48, Random Forest (RF), MultiLayer Perceptron (MLP) e Support Vector Machines (SVM), métodos descritos na seção 2.11.

**Tabela 7: Resultado do Experimento com seleção de espécies**

Classificador	Acurácia (%)			Média
	VCF	VCF+E	VCF+FC	
RandomForest	74,7	57,4	56,5	62,9
IBK	72,1	61,6	44,7	59,5
J48	63,9	48,0	36,6	49,5
SMO	57,4	52,3	43,5	51,1
MultilayerPerceptron	43,8	30,1	24,0	32,6
NaiveBayes	34,4	44,0	35,7	38,0

A seleção de espécies provocou, de modo geral, um aumento na taxa de acerto para os classificadores, em relação ao Experimento 3, e esta execução confirma as conclusões obtidas nos experimentos anteriores. Como neste cenário havia uma maior separabilidade entre as classes, as características extraídas pelos descritores de forma, puderam representar melhor cada classe. Contudo, verifica-se que quando aplicado a esqueletização ou o fecho convexo, a taxa de acurácia diminui, isto pode ser verificado no classificador RandomForest, que para o VCF apresentou uma taxa de 74,7%, e em seguida diminuiu para 57,4%, com a esqueletização. Sendo assim, confirma-se que a aplicação destas técnicas de representação do contorno não são eficientes. Os motivos para tal, foram discutidos anteriormente.

#### 4.4 EXPERIMENTO 4

Neste cenário de testes, selecionou-se todos os 7 descritores disponíveis na aplicação com a combinação das técnicas do fecho convexo e esqueletização, gerando 2 vetores de características distintos, organizados desta maneira:

**VCFTC+E:** [1-5] medidas de dispersão em função da assinatura, [6-13] histograma do código da cadeia, [14-139] descritores de Fourier, [140-179] Histograma de alteração quantificada, [180-231] descritores de Haralick, [232-359] histograma dos pixels de borda e interior gerado pelo BIC, [360-423] histograma acumulado pelo CGCH, totalizando 424 atributos com a classe.

**VCFTC+FC:** [1-5] medidas de dispersão em função da assinatura, [6-13] histograma do código da cadeia, [14-139] descritores de Fourier, [140-179] Histograma de alteração quantificada, [180-231] descritores de Haralick, [232-359] histograma dos pixels de borda e interior gerado pelo BIC, [360-423] histograma acumulado pelo CGCH, totalizando 424 atributos com a classe.

Uma análise dos resultados apresentados na Tabela 8 mostram que a combinação das

**Tabela 8: Resultados Experimento 4**

Classificador	Acurácia (%)		Média
	VCFTC+E	VCFTC+FC	
RandomForest	90,3	90,9	90,6
SVM	85,9	86,7	86,3
IBK	81,2	84,0	82,6
NaiveBayes	75,6	70,6	73,1
J48	71,9	70,2	71,1
MultilayerPerceptron	17,2	11,3	14,3

técnicas de pré-processamento juntamente com características de forma, textura e cor resultam em um bom valor de acurácia. Estes resultados não são os melhores alcançados neste trabalho, porém demonstram que as técnicas do fecho convexo e da esqueletização podem apresentar melhores resultados quando combinados com outras características.


No experimento anterior, onde utilizou apenas características de forma, os resultados para o fecho convexo e esqueletização não foram significativos, porém neste cenário, quando foram combinados com outras características, os valores de acurácia atingiram uma taxa aceitável, superiores a 90%. O classificador MultilayerPerceptron foi o único a apresentar mau desempenho, com taxas extremamente baixas.

#### 4.5 VISÃO GERAL DOS RESULTADOS

Para cada experimento calculou-se a média do valor de acurácia obtida por cada classificador. Com isso, pode-se calcular a média das médias e selecionar o melhor resultado alcançado. Desta forma, organizou-se um gráfico elencando o desempenho obtido pelos classificadores ao longo dos experimentos, vide Figura 22.

Assim verifica-se que o classificador que apresentou o melhor desempenho, dentro dos cenários propostos para este trabalho, foi o Random Forest, alcançando o melhor resultado em todos os experimentos realizados. Outro classificador que obteve destaque foi o IBK. O MultilayerPerceptron além de ter apresentado o pior desempenho, ainda levou o maior tempo durante a etapa de construção do modelo de classificação.

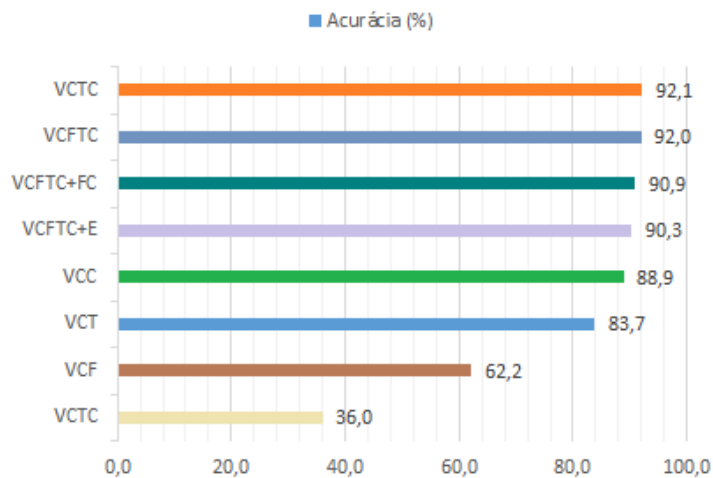




**Figura 22: Desempenho dos classificados nos experimentos**

Fonte: Autoria Própria

Com relação a combinação, elencou-se os vetores de características que apresentaram os melhores resultados, conforme verifica-se na Figura 23. Enfatiza-se os resultados alcançados pela combinação de propriedades de textura e de cor, atingindo taxas superiores a 90%.



**Figura 23: Ranking dos classificadores com base na taxa de acurácia**

Fonte: Autoria Própria

Com isso, finaliza-se a etapa de verificação dos resultados das técnicas e métodos implementados, seguindo para a última parte deste trabalho, onde aplicou-se a técnica de seleção de característica como tentativa de melhorar o desempenho para os classificadores.

## 4.6 SELEÇÃO DE ATRIBUTOS

Para a execução deste último cenário de testes, selecionou-se os vetores de características que apresentaram os melhores resultados nos experimentos anteriores, utilizando como critério, o valor da taxa de acurácia, sendo selecionados os que atingiram valor igual ou superior a 88%.

Com a escolha realizada pode-se então aplicar a técnica de seleção de atributos para cada um dos vetores, utilizou-se o filtro *AttributeSelection*, disponível na ferramenta Weka, que resultou em uma versão simplificada, contendo uma menor quantidade de atributos. Os resultados podem ser visto na Tabela 9.

**Tabela 9: Seleção de Atributos**

Vetor de Características	Quantidade de Atributos	
	Inicial	Seleção
VCC	193	27
VCFC	332	42
VCFTC	424	65
VCTC	285	55
VCFTC+E	424	66
VCFTC+FC	424	67

Para a classificação, utilizou-se os métodos já apresentados anteriormente. Com o intuito de tornar a visualização dos resultados mais simples e objetiva, destacou-se com a cor verde, na Tabela 10, os resultados que apresentaram aumento com o uso da seleção de atributos.

**Tabela 10: Resultados da seleção de atributos**

Classificador	Acurácia (%)					
	VCC	VCFC	VCTC	VCFTC	VCFTC+E	VCFTC+FC
RandomForest	90,2	92,8	93,8	<b>94,9</b>	93,9	93,6
SMO	60,2	79,0	81,4	<b>84,8</b>	83,2	83,4
IBK	76,3	82,6	86,6	<b>87,9</b>	84,2	86,1
J48	70,4	69,9	75,3	<b>75,6</b>	75,4	73,8
NaiveBayes	64,6	75,5	78,2	<b>82,7</b>	79,8	79,5
MultilayerPerceptron	78,4	82,9	87,1	<b>90,0</b>	88,1	88,2

Sendo assim, verifica-se que as classificações realizadas após a seleção de características, resultaram em uma melhoria geral na taxa de acurácia, com exceção do classificador SVM, que apresentou uma queda. Os demais, apresentam um considerável aumento, e isto indica que a seleção de atributos consegue ser eficiente na escolha dos atributos que possuem melhor representatividade, de modo que ao excluir outros, atua como um filtro, removendo os atributos ruidosos que interferem na classificação.

Por fim, conclui-se que para este trabalho o melhor resultado alcançado foi para a combinação de características de forma, textura e cor. O classificador que apresentou o melhor desempenho, de modo geral, foi o Random Forest.

#### 4.7 COMPARAÇÃO COM TRABALHO CORRELATOS

Nesta seção, serão realizadas algumas comparações deste trabalho com outros que também possuem foco na análise e caracterização de imagens de plantas. A base de imagens utilizada nos trabalhos foi a mesma (apresentada na seção 3.2.), assim como boa parte dos classificadores. A Figura 24 apresenta um quadro comparativo demonstrando as características analisadas por cada trabalho, além de quais técnicas de representação foram utilizadas.

Autor	Características analisadas			Técnicas de Representação		
	Textura	Forma	Cor	Aproximação Poligonal	Fecho Convexo	Esqueletização
(GALONETTI, 2016)	X	X	X	X	X	X
(BRILHADOR, 2013)	X	X				
(COLONHEZI, 2013)	X					

**Figura 24: Comparativo entre características e técnicas utilizadas**

Fonte: Autoria Própria

De forma geral, este trabalho agrega com relação a análise de características de cor e no uso de técnicas de representação. Com relação as melhores taxas de acurácia obtidas em cada trabalho, temos:

Autor	Acurácia (%)	Classificador	Características
(GALONETTI, 2016)	94,9	Random Forest	<b>Forma + Textura + Cor</b>
(BRILHADOR, 2013)	89,7	Random Forest	<b>Forma + Textura</b>
(COLONHEZI, 2013)	78,8	Adaboost J48	<b>Textura</b>

**Figura 25: Comparativo entre os melhores resultados**

Fonte: Autoria Própria

O trabalho realizado por Colonhezi (2013) teve suas contribuições para a caracterização de imagens foliares, permitindo que Brilhador (2013) pudesse agrupar em seu trabalho características de forma combinadas com textura, resultando em ganhos na taxa de acurácia. Este corrente trabalho pôde, além de utilizar as características de forma e textura, incluir novas informações relacionadas à cor e, ainda verificar a contribuição da utilização de técnicas de representação de imagens.

Os resultados foram apresentados em cada cenário de experimento, porém é interessante ressaltar que a combinação realizada neste trabalho proporcionou em ganho quando comparado aos demais, e acentua a contribuição realizada na continuação da pesquisa iniciada por Colonhezi (2013). O uso das técnicas de representação demonstraram taxa de acurácia superior as encontradas nos outros trabalho, porém, dentro dos cenários desenvolvidos para este trabalho, elas não apresentaram os maiores resultados.

O uso da técnica de aproximação poligonal não pode ser verificada neste trabalho, dado que o algoritmo desenvolvido não apresentou bons resultados. Contudo, a importância deste trabalho não foi afetada, tendo em vista que a combinação de características demonstrou-se ser mais influente que a aplicação de técnicas de representação. Com relação ao custo computacional, a aplicação da esqueletização demanda um esforço maior, resultando em maior tempo para a geração dos arquivos de saída. Esse fator pode ser determinante em aplicações desenvolvidas para dispositivos móveis, por exemplo, onde o processamento é inferior e limitado, quando comparado a um desktop.

Com relação a portabilidade, os trabalhos anteriores foram desenvolvidos utilizando a linguagem *Java*, enquanto este foi desenvolvido em *C/C++*. Em determinadas situações isso pode tornar-se uma barreira, contudo, a escolha da linguagem foi necessária para utilizar as funcionalidades oferecidas pela biblioteca *OpenCV*, a qual não foi considerada nos outros trabalhos.

## 5 CONSIDERAÇÕES FINAIS

Este trabalho de conclusão de curso teve como objetivo principal, o estudo e desenvolvimento de métodos para a análise de imagens. Para tanto, desenvolveu-se uma aplicação que possui técnicas de pré-processamento e descritores de imagens. A implementação das técnicas de esqueletização, aproximação poligonal e fecho convexo foram realizadas, porém o algoritmo para realizar a aproximação poligonal não apresentou bons resultados, gerando diversos ruídos nas imagens resultantes, e por isso não foi utilizado neste trabalho. Contudo, a aplicação desenvolvida permite uma vasta possibilidade de escolhas, entre 7 opções de classificadores combinadas com 3 técnicas de representação de imagem.

Com a realização deste trabalho, e o estudo referente as técnicas de representação, verifica-se que abordagens relacionadas ao contorno de objetos são sensíveis e por causa disto, facilmente influenciáveis. Ao lidar com a análise de forma, manter o seu modelo original, demonstrou ser a melhor escolha. Isto ficou claro quando utilizou-se técnicas que alteravam o contorno, como o uso do esqueleto de um objeto. Para o propósito deste trabalho, a técnica não demonstrou ser eficiente, já que o uso do contorno original apresentou melhores resultados. O mesmo vale para o fecho convexo. As características de textura e cor, mostraram ser mais robustas, ou seja, são menos suscetíveis as variações, além de terem contribuído para a melhoria na taxa de acurácia dos classificadores.

Quanto as classificações realizadas, conclui-se que o uso isolado de características de forma não é suficiente para atingir resultados significantes. O uso exclusivo de características de cor ou de textura, apresentou bons valores de acurácia, porém os melhores resultados foram obtidos quando ocorria a junção dessas características. A combinação das 3 propriedades (forma, textura e cor) demonstraram um ganho significativo no valor de acurácia dos classificadores. Os melhores casos, para este trabalho, foram as combinações de: textura e cor; forma, textura e cor; além disso, a combinação de todas as características com a aplicação do fecho convexo, também apresentou um resultado considerável. Ainda com relação aos classificadores, uma análise do valor médio de acurácia, mostrou que o RandomForest e o IBK foram os mais robustos, alcançando o melhor desempenho para a maioria dos casos de testes.

## 5.1 TRABALHOS FUTUROS

Como sugestão para trabalhos futuros, poderá ser acrescentando demais descritores de cor e de textura, tendo em vista que estes foram os que apresentaram os melhores resultados. Outra questão a ser considerada é a realização de testes com uma nova base de imagens, que apresente diferentes espécies de plantas das utilizadas neste trabalho. Além da implementação eficiente de um algoritmo para o cálculo da aproximação poligonal.

Com relação a mobilidade, uma abordagem interessante seria o desenvolvimento desta aplicação para dispositivos móveis. Para tanto, a implementação de um método de segmentação para a extração de folhas em ambientais naturais, torna-se necessário.

## REFERÊNCIAS

- AMARAL, V. do; THOMAZ, C. E. **Extração e Comparação de Características Locais e Globais para o Reconhecimento Automático de Imagens de Faces**. São Bernardo do Campo - São Paulo: [s.n.], 2012. 2012.
- BLUM, H. A Transformation for Extracting New Descriptors of Shape. In: WATHEN-DUNN, W. (Ed.). **Models for the Perception of Speech and Visual Form**. Cambridge: MIT Press, 1967. p. 362–380.
- BRILHADOR, A. **Combinando descritores de forma e textura para classificação de bioimagens: um estudo de caso aplicado a base de imagens ImageClef**. Cornélio Procópio: [s.n.], 2013. 2013.
- BRILHADOR, A. et al. Combining texture and shape descriptors for bioimages classification: A case of study in imageclef dataset. **18th Iberoamerican Congress on Pattern Recognition (CIARP)**, v. 8258, p. 1–8, 2013.
- CAMPOS, A. C. de et al. **Agricultura de precisão: resultados de um novo olhar**. 1. ed. [S.l.]: Embrapa, 2014. (10, v. 1).
- CARVALHO, J. D. de. **Métodos para a aproximação poligonal e o desenvolvimento de extractores de características de forma a partir da função tangencial**. Ubêrlandia - MG: [s.n.], 2008. 2008.
- CASANOVA, D. **Redes complexas em visão computacional com aplicações em bioinformática**. Instituto de Física de São Carlos: [s.n.], 2013. 2013.
- COLONHEZI, T. P. **Caracterização de Bioimagens**. Cornélio Procópio: [s.n.], 2013. 2013.
- DUDA, R.; HART, P.; STORK, D. **Pattern classification**. 2. ed. [S.l.]: Wiley, 2001.
- FREITAS, E. G. de. **Fecho Convexo 2D**. São Paulo: [s.n.], 2000. 2000.
- GIULIETTI, A. M.; AL. et. Biodiversidade e conservação das plantas no brasil. **Megadiversidade**, v. 1, 7 2005.
- GONZALEZ, R.; WOODS, R. **Processamento Digital De Imagens**. [S.l.: s.n.], 2000. ISBN 9788576054016.
- HARALICK, R. M.; SHANMUGAM, K. Computer classification of reservoir sandstones. **IEEE Transactions on Geoscience Electronics**, v. 11, p. 171–177, 1973.
- HORIKOSHI, W. C. **Guia de Instalação e integração do QtCreator e OpenCV**. Cornélio Procópio: [s.n.], 2015. 2015.
- HSIAO, J.-K. et al. Learning sparse representation for leaf image recognition. **2014 ICCE Taiwan**, 2014.

- HUANG, C.-B.; LIU, Q. An orientation independent texture descriptor for image retrieval. **International Conference on Communications, Circuits and Systems. ICCAS 2007**, 2007.
- IWATA, T.; SAITOH, T. Tree recognition based on leaf images. **SICE Annual Conference 2013**, 7 2013.
- LLC, M. **The ImageCLEF 2012 Plant Identification Task**. 2012. Disponível em: <<http://www.imageclef.org/system/files/TheImageCLEF2012PlantTaskOverview.pdf>>.
- LORENA, A. C.; CARVALHO, A. C. P. L. de. Uma introdução as support vector machines. **RITA**, v. 14, p. 43–67, 2007.
- MALLICK, S. **Learn OpenCV by Examples: Convex Hull**. 2015. Disponível em: <<http://opencvexamples.blogspot.com/2013/10/convex-hull.html>>.
- MARENGONI, M.; STRINGHINI, D. Tutorial: Introdução a visão computacional usando opencv. **RITA**, v. 16, 2009.
- MCAFEE, A.; BRYNJOLFSSON, E. Big data: The management revolution. **Harvard Business Review**, p. 60–68, 10 2012.
- PENATTI, O. A. B. **Estudo Comparativo de Descritores para Recuperação De Imagens por Conteúdo na Web**. Campinas: [s.n.], 2009. 2009.
- PENHARBEL, E. A. et al. **Filtro de Imagem Baseado em Matriz RGB de Cores Padrão para Futebol de Robôs**. 2011.
- RUSSELL, S. J.; NORVIG, P. **Inteligência Artificial**. 1. ed. [S.l.]: Editora Campus, 2004.
- STEHLING, R. O.; NASCIMENTO, M. A.; FALCAO, A. X. A compact and efficient image retrieval approach based on border/interior pixel classification. **11th ACM Int Conf Information Knowledge Management - CIKM'02**, p. 102–109, 2002.
- WAIKATO, U. of. **Weka 3: Data Mining Software in Java**. 2010. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>>.