UNIVERSIDADE FEDERAL DE GOIÁS – REGIONAL CATALÃO
UNIDADE ACADÊMICA ESPECIAL DE MATEMÁTICA E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM E OTIMIZAÇÃO

Guilherme Augusto Moraes de Deus

DESCRITORES DE TEXTURA LOCAL PARA IDENTIFICAÇÃO DE FUNGOS EM FOLHAS DE SOJA

DISSERTAÇÃO DE MESTRADO

CATALÃO – GO, 2018

sistema de bibliotecas ufg

PRPG
PRÓ-REITORIA DE PÓS-GRADUAÇÃO

UFG

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a Lei nº 9610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira, a partir desta data.

1. Identificação do material bibliográfico: **[X] Dissertação** **[ ] Tese**

2. Identificação da Tese ou Dissertação:

Nome completo do autor: Guilherme Augusto Moraes de Deus

Título do trabalho: Descritores de textura Local para Identificação de fungos em folhas de soja

3. Informações de acesso ao documento:

Concorda com a liberação total do documento [ ] SIM [X] NÃO[1]

Havendo concordância com a disponibilização eletrônica, torna-se imprescindível o envio do(s) arquivo(s) em formato digital PDF da tese ou dissertação.

Guilherme Augusto Moraes de Deus (autor)

Ciente e de acordo:

Prof. Dr. Marcos Aurélio Batista (orientador)

Data: 02 / 08 / 18

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. A extensão deste prazo suscita justificativa junto à coordenação do curso. Os dados do documento não serão disponibilizados durante o período de embargo.
Casos de embargo:
- Solicitação de registro de patente
- Submissão de artigo em revista científica
- Publicação como capítulo de livro
- Publicação da dissertação/tese em livro

[2]A assinatura deve ser escaneada.

Versão atualizada em maio de 2017.

GUILHERME AUGUSTO MORAES DE DEUS

DESCRITORES DE TEXTURA LOCAL PARA IDENTIFICAÇÃO DE FUNGOS EM FOLHAS DE SOJA

Dissertação apresentada como requisito parcial para a obtenção do título de Mestre em Modelagem e Otimização pela Universidade Federal de Goiás – Regional Catalão.

Orientador:
Prof. Dr. Marcos Aurélio Batista

CATALÃO – GO

2018

Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema de Bibliotecas da UFG.

de Deus, Guilherme Augusto Moraes
Descritores de textura Local para Identificação de fungos em folhas de soja [manuscrito] / Guilherme Augusto Moraes de Deus. - 2018.
80 f.: il.

Orientador: Prof. Dr. Marcos Aurélio Bastista.
Dissertação (Mestrado) - Universidade Federal de Goiás, Unidade Acadêmica Especial de Matemática e Tecnologia, Catalão, Programa de Pós-Graduação em Modelagem e Otimização, Catalão, 2018.
Bibliografia.
Inclui tabelas, lista de figuras, lista de tabelas.

1. Descritores. 2. CM. 3. GLCM. 4. HOG. 5. LBP. I. Bastista, Marcos Aurélio , orient. II. Título.

CDU 004

MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE GOIÁS
REGIONAL CATALÃO
Programa de Pós-Graduação em Modelagem e Otimização - PPGMO

Defesa Nº **30**

Ata de Defesa Pública – Dissertação de Mestrado

Aos 28 dias do mês de fevereiro do ano de 2018, às 17 h: 10 min, reuniram-se os componentes da banca examinadora, professores Dr. Marcos Aurélio Batista (presidente e orientador), Dr. Tércio Alberto dos Santos Filho, Dr. Marcos Napoleão Rabelo para, em sessão pública realizada na Sala 114, da Regional Catalão (RC), da Universidade Federal de Goiás (UFG), procederem com a avaliação do trabalho intitulado:" DESCRITORES DE TEXTURA LOCAL PARA IDENTIFICAÇÃO DE FUNGOS EM FOLHAS DE SOJA" em nível de Mestrado, área de concentração *Modelagem e Otimização*, de autoria de Guilherme Augusto Moraes de Deus, discente do Programa de Pós-Graduação em Modelagem e Otimização (PPGMO) da UFG/RC. A sessão foi aberta pelo presidente da banca, que fez a apresentação formal dos membros da banca. A seguir, a palavra foi concedida ao discente que, dentro do tempo regulamentar, procedeu a apresentação de seu trabalho. Terminada a apresentação, cada membro da banca arguiu o candidato, tendo-se adotado o sistema de diálogo sequencial. Terminada a fase de arguição, procedeu-se a avaliação do trabalho. Os membros da banca consideraram o trabalho final: (x) **Aprovado** ou ( ) **Reprovado**. Cumpridas as formalidades de pauta, às 18 h: 30 min a presidência da mesa encerrou a sessão e para constar, eu Marcos Aurélio Batista, lavrei a presente Ata que, depois de lida e aprovada, segue assinada pelos membros da banca examinadora e pelo discente e, posteriormente, será homologada pelo Colegiado do PPGMO.

Catalão-GO, 28 de fevereiro de 2018.

Prof. Dr. Marcos Aurélio Batista
Programa de Pós-Graduação em Modelagem e Otimização, UFG/RC.
(Presidente da Banca)

Prof. Dr. Marcos Napoleão Rabelo
Programa de Pós-Graduação em Modelagem e Otimização, UFG/RC.

Prof. Dr. Tércio Alberto dos Santos Filho
Ibiotec, UFG/RC.

Discente: Guilherme Augusto Moraes de Deus
Programa de Pós-Graduação em Modelagem e Otimização, UFG/RC.

Dedico este trabalho aos meus pais Renato e Fátima e aos meus irmãos Marcus e Dayanne, por todo amor, carinho, educação e incentivo que recebi.

Agradecimentos

Agradeço a Deus, por ter me iluminado durante os estudos.

Sou grato ao Prof. Dr. Marcos Aurélio Batista, pela confiança, a disponibilidade, e que com sabedoria e paciência me orientou. Ao Prof. Dr. Sérgio Francisco da Silva pelo imenso apoio.

Aos meus pais Fátima e Renato, que sempre lutaram pela construção de valores nobres junto ao meu caráter.

Aos meus irmãos Marcus e Dayanne por todo suporte e palavras de ânimo que me deram nos momentos de maior necessidade.

As minhas companheiras de estudos Lorrany e Liliane que sempre me ajudaram quando necessário.

A UFG por ter me disponibilizado a oportunidade para a realização desse mestrado. Aos professores que me fizeram agregar mais conhecimento.

A CAPES, pelo apoio financeiro.

"...Eles passarão... Eu passarinho!"

Mario Quintana

RESUMO

DE DEUS, GAMD. *Descritores de textura Local para Identificação de fungos em folhas de soja.* 2018. 88 f. Dissertação (Mestrado em Modelagem e Otimização) – Unidade Acadêmica Especial de Matemática e Tecnologia, Universidade Federal de Goiás – Regional Catalão, Catalão – GO.

As doenças das plantas podem prejudicar de inúmeras maneiras um país, seja com a considerável perda na qualidade da colheita, consequentemente, a perda econômica, a agressão ao meio ambiente e em alguns casos até agravamento da fome de sua população. Em muitos casos as plantas doentes são diagnosticadas mediante inspeção visual. Apesar de haver métodos mais avançados, a linha de frente da defesa ainda continua sendo o olho afiado dos agricultores, isso porque a maioria não tem acesso a assistência técnica especializada ou métodos avançados de diagnóstico. Os fungos a serem estudados são: a mancha parda (*Septoria glycines*), mancha olho-de-rã (*Cercospora sojina*) e a doença do míldio (*Peronosspora manshurica*). Sendo assim, esse trabalho apresenta métodos computacionais baseados em descritores locais de imagem que podem identificar e classificar esses tipos de doenças. Os descritores usados são: o LBP (*Local Binary Patterns*), LPQ (*Local Phase Quantization*), baseados em *Color Moments* (CM), GLCM (*Gray Level Co-ocurrence Matrix*), HOG (*Histogram of Oriented Gradients*). Para um estudo mais amplo os descritores foram concatenados, o que em alguns casos mostrou uma melhora considerável na classificação correta do estado da folha. Dois classificadores também foram comparados: o *Random Forest* e o *Naive Bayes*. O classificador que obteve um índice mais altos de acerto foi o Random Forest baseado na junção dos descritores *Color Moments* (CM), com o LPQ invariante a rotação, com acurácia de 93.5%.

Palavras-chaves: Fungos na Soja, Olho-de-rã, Míldio, Mancha Parda, Soja, CM, GLCM, HOG, LBP, LPQ, Navie Bayes, Random Forest.

ABSTRACT

DE DEUS, GAMD. *Descritores de textura Local para Identificação de fungos em folhas de soja.* 2018. 88 f. Master Thesis in Modelling and Optimization – Unidade Acadêmica Especial de Matemática e Tecnologia, Universidade Federal de Goiás – Regional Catalão, Catalão – GO.

Plant diseases can adversely affect a country in number of ways, either with the considerable loss in crop quality, consequently economic loss, environmental damage and in some cases even famine in its population. In many cases diseased plants are diagnosed by visual inspection. Although there are more advanced methods, the front line of defense still remains the keen eye of farmers, because most do not have access to specialized technical assistance or advanced diagnostic methods. The fungi to be studied are: Long Spot (Septoria glycines), Frog Eye Spot (Cercospora sojina) and Mildew disease (Peronsopora manshurica). Thus, this work presents computational methods based on local image descriptors that can identify and classify these types of diseases. The descriptors used are LBP (Local Binary Patterns), LPQ (Local Phase Quantization), based on CM (Color Moments), GLCM (Gray Level Co-occurrence Matrix), HOG (Histogram of Oriented Gradients). For a larger study the descriptors were concatenated, which in some cases showed considerable improvement in the correct classification of the leaf state. Two classifiers were also compared: Random Forest and Naive Bayes. The best hit was Random Forest based on the CM + LPQ-RI, with accuracy of 93.5 %.

Keywords: Fungus in Soybean, Eye of the Frog, Mild, Stain, Soy, CM, GLCM, HOG, LBP, LPQ, Navie Bayes, Random Forest.

LISTA DE FIGURAS

Figura 2.1 – Expansão na fronteira agrícola no Brasil 24
Figura 2.2 – Míldio (*Peronosspora manshurica*). 25
Figura 2.3 – Olho-de-Rã (*Cercospora sojina*). 25
Figura 2.4 – Mancha parda (*Septoria glycines*). 26
Figura 2.5 – Detalhe para míldio. 27
Figura 2.6 – Detalhe para mancha olho-de-rã. 28
Figura 3.1 – Espectro eletromagnético. 35
Figura 3.2 – Cubo RGB. 37
Figura 3.3 – Modelo de cor HSV. 38
Figura 3.4 – Representação de Histograma de imagens de feijão, canola e milho. 39
Figura 4.1 – Interação da energia eletromagnética com o objeto. 44
Figura 4.2 – O espectro eletromagnético. 45
Figura 4.3 – Imagens no visível de cana-de-açúcar. 45
Figura 4.4 – Irrigação por Pivô. 46
Figura 4.5 – Comparação entre imagem multiespectral de 4 banda com a hiperespectral com 363 47
Figura 5.1 – Exemplo de primitivas de textura 51
Figura 5.2 – Exemplo HOG. 56
Figura 5.3 – Exemplo de vizinhança 3×3. 57
Figura 5.4 – Padrões Locais Binários (LBP). 58
Figura 5.5 – Exemplo $LBP_{8,1}$. 58
Figura 5.6 – Exemplo LPQ. 59
Figura 5.7 – Exemplo de *Random Forest*. 61
Figura 6.1 – Folhas de soja. 64
Figura 6.2 – Imagens após o pré-processamento. 65
Figura 6.3 – Folhas com míldio. 74
Figura 6.4 – Folhas doentes com olho-de-rã. 75
Figura 6.5 – Folhas com mancha parda. 76
Figura 6.6 – Folhas saudáveis. 77

Figura 6.7 – Resultados PlantVillage. 78

LISTA DE TABELAS

Tabela 6.2 – Detalhes da Acurácia por Classe usando RF - Método CM_LPQ-RI 66
Tabela 6.3 – Detalhes da Acurácia por Classe usando NB - Método CM_LPQ-RI 66
Tabela 6.1 – Resultados da Acurácia 67
Tabela 6.4 – Detalhes da Acurácia por Classe usando RF - Método CM 68
Tabela 6.5 – Detalhes da Acurácia por Classe usando NB - Método CM 68
Tabela 6.6 – Matriz confusão NB - Método CM 68
Tabela 6.7 – Detalhes da Acurácia por Classe usando RF - Método COOC 69
Tabela 6.8 – Detalhes da Acurácia por Classe usando RF - Método COOC-LPQ-RI 69
Tabela 6.9 – Detalhes da Acurácia por Classe usando RF - Método GLCM 69
Tabela 6.10 –Detalhes da Acurácia por Classe usando RF - Método GLCM-CM 70
Tabela 6.11 –Detalhes da Acurácia por Classe usando RF - Método HOG 70
Tabela 6.12 –Detalhes da Acurácia por Classe usando RF - Método HOG-LPQ-RI 70
Tabela 6.13 –Detalhes da Acurácia por Classe usando RF - Método LBP 71
Tabela 6.14 –Detalhes da Acurácia por Classe usando RF - Método LBP-RI-LPQ-RI . . . 71
Tabela 6.15 –Detalhes da Acurácia por Classe usando RF - Método LBP 71
Tabela 6.16 –Matriz confusão dos descritores base (Usando RF) 72
Tabela 6.17 –Matriz confusão - CM-LPQ-RI (Usando RF) 73

SUMÁRIO

1 INTRODUÇÃO 21
1.1 Motivação 22
1.2 Objetivos 22
1.3 Estrutura do Trabalho 22

2 DOENÇAS DA SOJA 23
2.1 Míldio 24
2.2 Mancha Olho-de-rã 25
2.3 Mancha Parda 26
2.4 Sintomatologia 26
2.5 Manejo da Doença 28
2.6 Identificação Automática 29

3 SISTEMA DE VISÃO ARTIFICIAL 33
3.1 Imagem Digital 34
3.2 Cores 35
3.2.1 Modelo RGB 37
3.2.2 Modelo HSV 38
3.2.3 Histograma 38
3.3 Visão Computacional 40
3.4 Processamento digital de imagens 40

4 SENSORIAMENTO REMOTO 43
4.1 Modelos de Sensores 44
4.1.1 Visível 45
4.1.2 Infravermelho Próximo 46
4.1.3 Hiperespectral 46

5 DESCRITORES E CLASSIFICADORES 49
5.1 Textura 50
5.1.1 Abordagem Estatística 50
5.1.2 Abordagem Estrutural 51
5.1.3 Abordagem Espectral 51

5.2 Medidas de similaridade 52
5.3 Descritores Utilizados 53
5.3.1 *Color Moments* (CM) 53
5.3.2 *Gray Level Co-ocurrence Matrix* – GLCM 54
5.3.3 *Histogram of Oriented Gradients* – HOG 55
5.3.4 *Local Binary Patterns* – LBP 56
5.3.5 *Local Phase Quantization* – LPQ 58
5.4 Classificadores 59
5.4.1 *Naive Bayes* – NB 60
5.4.2 *Ramdom Forest* – RF 61

6 EXPERIMENTOS E RESULTADOS 63
6.1 Base de Dados 63
6.2 Experimento 64
6.3 Resultados 66
6.4 Discussão 73

7 CONCLUSÃO 81
7.1 Trabalhos Futuros 82

REFERÊNCIAS 83

Capítulo 1

INTRODUÇÃO

O cultivo da soja (*Glycine max (L.) Merrill*) destaca-se entre as atividades econômicas mundiais que apresentam crescimentos expressivos nas últimas décadas. Apesar da constante expansão territorial a produtividade agrícola é diretamente influenciada por fatores externos e internos durante o cultivo, sendo o principal deles, a incidência de doenças.

Desde o plantio até a colheita, a cultura de soja está exposta a vários tipos de pragas que afetam o seu desenvolvimento, podendo ser doenças ou insetos, capazes de trazer perdas econômicas significativas, comprometendo a produção e a qualidade dos grãos (HOFFMANN-CAMPO *et al.*, 2000).

Dentre as doenças que afetam negativamente a produção de soja as que serão analisadas no presente trabalho, estão: a mancha parda (*Septoria glycines*), mancha olho-de-rã (*Cercospora sojina*) e a doença do míldio (*Peronosspora manshurica*).

Atualmente, observa-se uma preocupação do produtor agrícola em aumentar a produção de suas lavouras de maneira a agredir menos o meio ambiente. Com isso, setores governamentais em parceria com empresas privadas têm se empenhado no desenvolvimento de novas tecnologias que os auxiliem na obtenção desses objetivos. Dessa forma, o monitoramento das doenças desde a fase do plantio até a colheita é importante para a identificação de doenças no estágio inicial, garantindo assim o menor dano a lavoura e o menor uso de fungicidas.

Este trabalho tem como objetivo colaborar para o aumento da produção de grãos de soja, auxiliando o produtor rural a identificar as doenças nas folhas de soja de maneira rápida e fácil, utilizando métodos de visão computacional.

Foram analisados métodos de descritores locais e classificadores para reconhecer as doenças nas folhas de soja. Os descritores também foram concatenados na intenção de obter um melhor resultado. Para fazer as classificações das imagens foram utilizados dois classificadores, o *Random Forest* e o *Naive Bayes*.

De modo geral, as propostas obtiveram resultados satisfatório usando o classificador o *Random Forest*, e a taxa de acurácia usando mais de um descritor encadeado se mostraram com desempenhos superiores se comparado ao uso de apenas um descritor.

1.1 Motivação

Com o aumento da população mundial, cada vez mais torna-se necessária a busca de tecnologias para o incremento da produção de alimentos, nesse contexto, a soja serve de base alimentar para mais de 20 tipos de alimentos (CUNHA *et al.*, 2015), sendo importante que o resultado da produção de uma lavoura de soja seja satisfatório.

Dessa forma, a utilização de técnicas de processamento digital de imagens é fundamental para a análise de imagens das lavouras a fim de identificar de forma precoce e instantânea indícios da formação de doenças que influenciam negativamente a produção.

1.2 Objetivos

- Objetivo geral: propor um método de classificação de imagem baseado em técnicas de descritores de imagens, que possibilite a implementação para a identificação de doenças em folhas em uma lavoura de soja.
- Objetivos específicos: a criação de uma base de imagens com doenças de foliares de soja, analisar a acurácia de cada classificador com base nos descritores propostos, encadear mais de um descritores para no intuito de obter um melhor resultado, comparar e determinar qual o melhor dos dois classificadores.

1.3 Estrutura do Trabalho

Este trabalho está estruturado da seguinte forma: O Capítulo 1 apresenta uma introdução sobre os aspectos gerais dos assuntos tratado, bem como sua motivação e a estruturação do trabalho. No Capítulo 2 é relatado mais detalhes sobre as doenças, os aspectos de seus respectivos sintomas assim como os métodos utilizados para sua identificação.

O Capítulo 3 traz os conceitos básicos sobre a visão artificial, o qual o conhecimento é importante para o entendimento do sistema. O Capítulo 4 apresenta os modelos de sensoriamento remoto, dos quais são obtidos as imagens. O Capítulo 5 são apresentado os descritores propostos para a analise e os classificadores *Ramdom Forest* e *Naive Bayes*.

No Capítulo 6 são descritos os experimentos e apresentado os resultados obtidos pelos classificadores propostos que fizeram uso das atribuições dos descritores. E por fim, no Capítulo 7 são comentadas as conclusões e apresentados os trabalhos futuros.

Capítulo 2

DOENÇAS DA SOJA

Atualmente o Brasil ocupa o segundo lugar entre os maiores exportadores de soja do mundo, atrás apenas dos Estados Unidos. Segundo o CONAB (Companhia Nacional de Abastecimento), o Brasil produziu 113,923 milhões de toneladas entre a safra de 2016/2017. É o setor agroindustrial que corresponde por cerca de 1/3 do PIB nacional e por aproximadamente 40% das exportações totais (ABREU, 2016).

No início do século XX, a soja era cultivada mais ao sul do país por pequenos produtores que a utilizavam como fonte de proteínas para suínos e adubo. A perspectiva era a de expandir a fronteira agrícola incrementando os avanços tecnológicos que incluíam pesquisas nas áreas de química, mecânica, e sobretudo, engenharia genética (ABREU, 2016).

Na década 1970 houve uma expansão na fronteira agrícola com tecnologias desenvolvidas pela Empresa Brasileira de Pesquisa Agropecuária (Embrapa) juntamente com Centro de Pesquisa Agropecuário do Cerrado (CPAC). Em parceria, desenvolveram sementes que se adaptaram ao cerrado brasileiro e ao clima tropical, que por muito tempo era visto como um ecossistema sem grande potencial para o desenvolvimento agrícola, a expansão da fronteira é ilustrado pela Figura 2.1, onde mostra os aspectos da produção agrícola através das décadas.

O crescimento do cultivo da soja no Brasil tem aumentado consideravelmente ao longo das quatro últimas décadas, e um dos pivôs pelo aumento da produtividade no campo resultou no uso constante de novas tecnologias e pesquisas aplicadas na área. Porém, são diversas as enfermidades que podem dificultar a obtenção da máxima produtividade no cultivo da soja. São aproximadamente 40 doenças causadas por fungos, bactérias, nematoides e vírus que já foram identificadas no Brasil (NUNES, 2009).

Figura 2.1 – Expansão na fronteira agrícola no Brasil

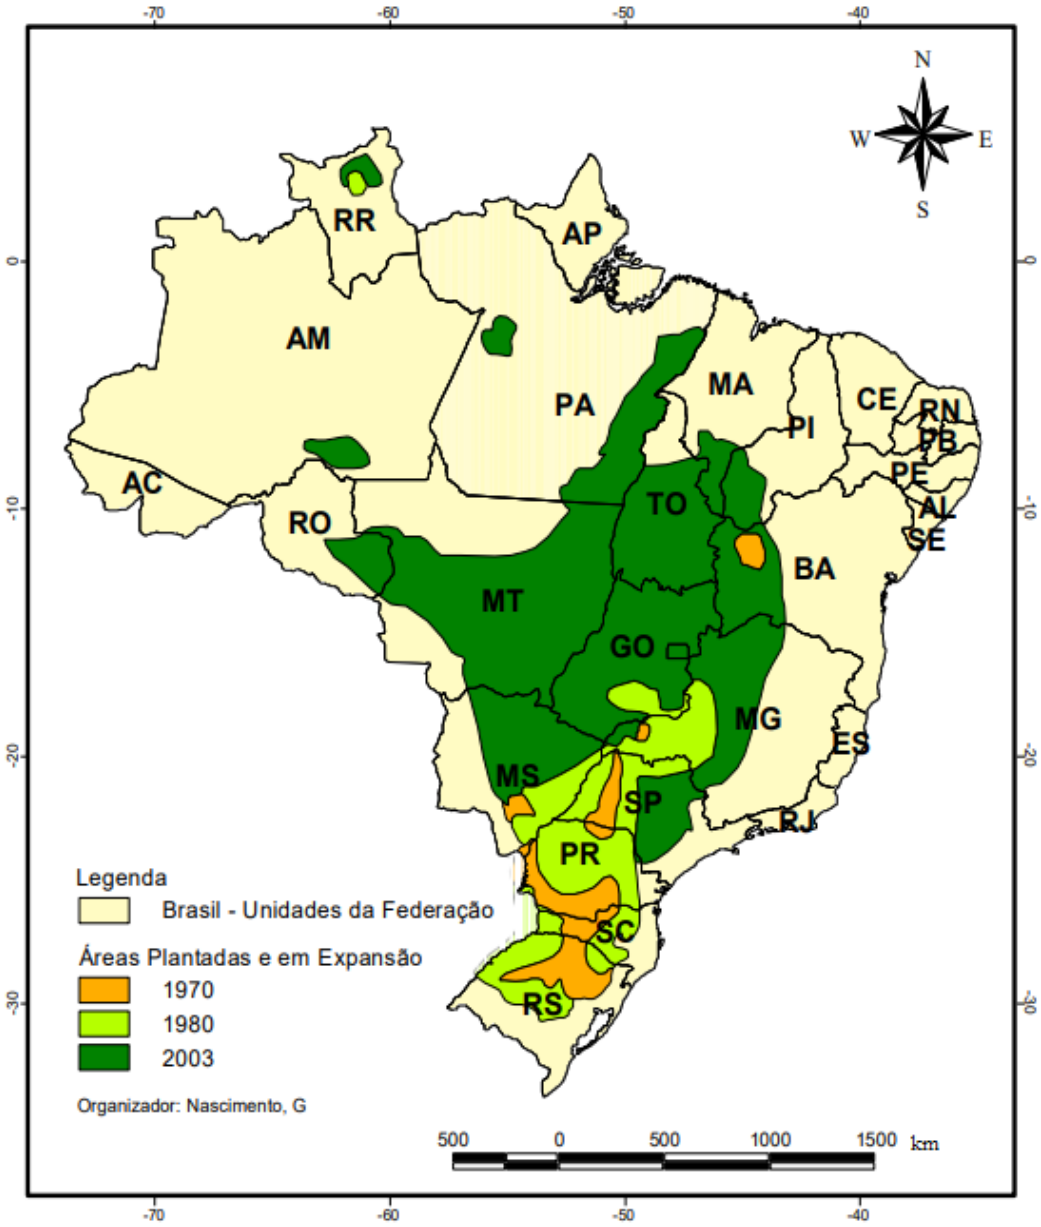

Fonte: (KIRT, 2003).

2.1 Míldio

O míldio da soja (*Peronosspora manshurica*), Figura 2.2, é uma doença amplamente disseminada no Brasil, a estimativa da perda na produção causado por essa doença é cerca de 8 a 14%, quando ocorrem em cultivares suscetíveis (GRIGOLLI, 2015). Os danos causados pelo míldio é a formação de pontuação amarelas, que podem atingir de 3 a 5 mm de diâmetro. Com o desenvolvimento da doença, ocorrem a crestamento foliar e, em sequência, as lesões tornam-se necróticas.

Figura 2.2 – Míldio (*Peronosspora manshurica*).

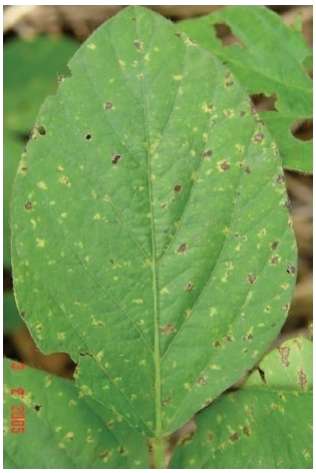

Fonte: (HENNING *et al.*, 2005).

2.2 Mancha Olho-de-rã

A mancha olho-de-rã (*Cercospora sojina*), Figura 2.3, é uma doença que causou epidemia em plantações de soja no Brasil na década de 70, mas com desenvolvimento e melhoramento genético de cultivares resistentes a ocorrência da doença se tornou mais esporádico. Sendo uma doença que afeta a parte aéreas da planta, hastes, vagens e sementes, comprometendo a qualidade e o rendimento dos grãos (REIS; DANELLI; CASA, 2012).

Vizinha do Brasil, a Argentina é a terceira maior produtora mundial de soja, e a doença mancha olho-de-rã, é uma das doenças que mais assolam os produtores no país vizinho, em 2010 uma praga fez com que os agricultores tivessem perdas de 10 a 15% na produção de grãos (CAMERA; DEUNER; REIS, 2012).

Figura 2.3 – Olho-de-Rã (*Cercospora sojina*).

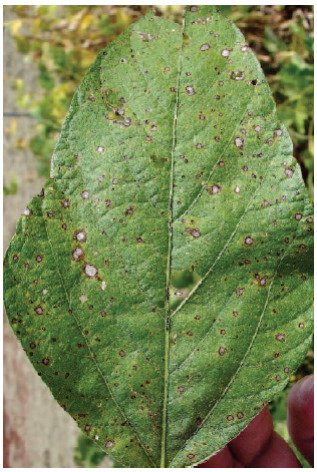

Fonte: (HENNING *et al.*, 2005).

2.3 Mancha Parda

A mancha parda (*Septoria glycines*), Figura 2.4, é provavelmente a doença de soja mais difundida do mundo, sendo considerada de ocorrência preocupante nas regiões mais quentes e chuvosas do cerrado, com danos entre 8 a 15% de perdas na produção (GUIMARÃES, 2008).

Figura 2.4 – Mancha parda (*Septoria glycines*).

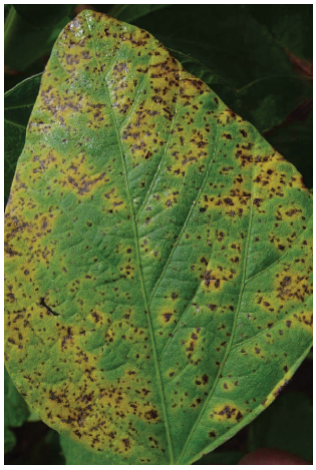

Fonte: (HENNING *et al.*, 2005).

Os primeiros sintomas da doença aparecem cerca de duas semanas após a emergência e é inicialmente observada nas face superior das folhas primárias, surgindo pontuações pardas, menores que 1 mm de diâmetro, as quais evoluem e formam manchas com halos amareladas e centro de contorno angular e assim como o míldio, posteriormente necrosam.

Para os três tipos de doenças a principal ferramenta de controle disponível, atualmente, são os fungicidas, que têm controlado a doença de maneira satisfatória, desde que aplicados em época adequada (NUNES, 2009). Porém, o uso de agrotóxicos podem causar danos ao meio ambiente e a saúde dos envolvidos na aplicação.

Os outros meios são a resistência genética e as práticas culturais, na resistência genética é feito o cruzamento entre as espécies no intuito de aumentar as defesas das plantas e as práticas culturais são métodos que proporcionam as melhores condições de desenvolvimento da cultura, como a rotação de cultura e o vazio sanitário (DEBIASI *et al.*, 2016).

2.4 Sintomatologia

Sintomatologia é o conjunto de sintomas que definem uma doença, no caso das doenças estudadas, elas são observadas na face ventral da folha (SARAN, 2014).

Há dois tipos de cultivares de soja, a que é resistente ou tolerante à doença e a que é suscetível. Os cultivares resistentes ou tolerantes, são aqueles que sofreram melhoramento genético ou o cruzamento convencional entre as espécies de soja. O cultivar suscetível é aquele em que a resistência genética não foi atualizada/evoluído (FIALLOS, 2011). E os três tipos de fungos reagem de forma diferente sobre os dois tipos de cultivares, tendo um maior impacto nos cultivares suscetíveis.

A primeira evidência da ocorrência do míldio é indicada pelos sintomas foliares presentes no primeiro par de folhas (unifoliadas), com duas semanas de idade, no limbo foliar destas, observa-se uma área manchada com a coloração verde-clara até amarelada, mostrado na Figura 2.5. Após 7 a 10 dias o surgimento dos sintomas, o fungo inicia a fase de frutificação na fase inferior das lesões (MELO; DANELLI; CASA, 2010).

Figura 2.5 – Detalhe para míldio.

Fonte: adaptado de (HENNING *et al.*, 2005).

A doença se desenvolve e as lesões se tornam marrom-acinzentadas até marrom escuras, com margens esverdeadas ou amareladas. Folhas severamente atacadas pelo fungo tornam-se marrom podendo se soltar da planta, causando a desfolha (PICININI; FERNANDES, 2003).

A principal forma de disseminar o patógeno e fonte de inóculo inicial são pelas sementes contaminadas. As plântulas originadas de sementes infectadas são raquíticas e com folhas manchadas (GRIGOLLI, 2015).

Os sintomas da mancha olho-de-rã podem ocorrer em qualquer estágio da planta. Entretanto, é mais comum no florescimento da planta. Atingindo as folhas, haste, vagem e semente. Iniciando com pequenos pontos na parte superior da folha, que evoluem para manchas com bordas castanho-avermelhada e no centro castanho-claros, como mostra a Figura 2.6.

Figura 2.6 – Detalhe para mancha olho-de-rã.

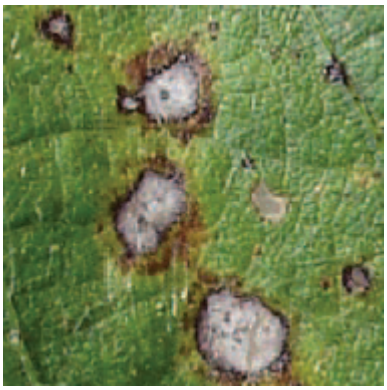

Fonte: adaptado de (HENNING *et al.*, 2005).

O fungo é disseminado através da semente infectada e dos esporos levados pelo vento, podendo sobreviver também em restos da cultura. A doença é favorecida por condições de alta temperatura e ambiente úmido (SARAN, 2014).

Normalmente os sintomas da mancha parda, aparecem cerca de duas semanas após a emergência, sendo pequenos pontos ou manchas com contornos angulares, da cor parda na face superior das folhas. Na soja, é uma das primeiras doenças a aparecer nos campos de cultivo, manifestando no início de formação das vagens. A infecção da doença se agrava quanto mais úmido é o ambiente, caso o período de 6 a 36 horas. Nos casos mais severos, causa desfolha e maturação precoce (GUIMARÃES, 2008).

Os efeitos causados pelas doenças é a queda prematura das folhas, impedindo a plena formação dos grãos. Quanto mais cedo ocorrer a desfolha, menor o rendimento da planta, como menor o tamanho dos grãos, seu peso e consequentemente sua qualidade. Dessa forma, as consequências dos fungos em uma lavoura de soja podem ser desastrosas caso a doença não seja tratada rapidamente (SARAN, 2014).

2.5 Manejo da Doença

Para controlar a doença existem três meios básicos que são aplicados para evitar epidemias das doenças da soja: fungicidas, resistência genética e práticas culturais. Atualmente, o uso de controles químicos é a única tática altamente efetiva, porém o manejo de longo prazo irá provavelmente depender mais da alteração genética, em combinação com fungicidas e mudanças nas práticas culturais (GODOY *et al.*, 2014).

O manejo usado para evitar ou conter o avanço do míldio, envolve a rotação de culturas com espécies não hospedeiras do patógeno, destruição dos restos culturais, uso de cultivares resistentes, e o tratamento de sementes com fungicidas, sendo a última a mais eficiente atualmente (SILVA *et al.*, 2016).

No Brasil foram identificadas 25 raças da mancha olho-de-rã, são espécies que sofreram mutações. Para controlar a doença é adotado o uso de cultivares resistentes e tratamento de semente com fungicidas (GRAVINA *et al.*, 2003).

Para controlar a mancha parda, os métodos ideais são: a rotação de cultura, e aplicação de fungicida na parte aérea, entre os estágios de formação de grãos e das vagens.

Na Seção 2.6 serão apresentados alguns trabalhos que propõem técnicas de identificação automática de plantas, sementes e doenças.

2.6 Identificação Automática

Com a carência de tecnologias que possam identificar e classificar a doença com eficiência e exatidão, estudos para a implementação de novas técnicas começaram a despontar (REINEHR; SOUTES, 2016). A Embrapa Instrumentação tem contribuído com o desenvolvimento de softwares destinados à análise e diagnósticos de imagens captadas no campo, seja por via terrestre, aérea ou também via satélite, os principais desenvolvimentos nacionais são:

Utilizando técnicas de processamento digital de imagens para o reconhecimento de dois tipos de plantas invasoras, sendo uma de folha larga (*Euphorbia heterophylla L.*) e a outra de folha estreita (*Digitaria saguinalis Scop*) em plantações de milho, Santos (SANTOS, 2009) obteve resultados de 84.24% de acertos para a folha larga e 80.17% de acerto em identificar a folha estreita.

Barbosa (BARBOSA, 2009) propõe em seu trabalho desenvolver e avaliar o desempenho de um sistema com a finalidade de reconhecer e identificar a planta de milho e a planta daninha, baseando em descritores geoestatísticos obtidos a partir do uso dos descritores de Haralick. As plantas daninhas avaliadas foram a leiteira (*Euphorbia heterophylla L.*), capim-milhã (*Digitaria horizontalis Willd*) e timbête (*Cenchrus echinatus L.*). Para forma a base de imagens foram adquiridos 9 imagens, seis foram utilizadas para a extração de características e treinamento e as três restantes foram utilizados para a validação do descritor. As imagens foram recortadas em 100 blocos de 68×68 pixels. A exatidão global alcançada pelo método foi de 80.66%.

O software Diagnose Virtual, que faz as análises das imagens em um ambiente virtual WEB em busca de diagnosticação de doenças. Utilizando-se de mecanismos de inferência sobre o conhecimento de especialistas, o sistema atual contempla dois módulos denominados Especialista e Produtor. No módulo Especialista é possível configurar e alimentar o sistema com a base de conhecimento, no módulo Produtor, permite a entrada das informações que auxiliam o produtor a identificar doenças e apresenta as medidas viáveis para o tratamento (MANGINI; SANTOS, 2009). Porém, esse software necessita estar conectado à

internet para serem feitas as análises.

Dentre os programas desenvolvidos pela Embrapa, se destaca o AFSoft, é uma ferramenta que tem a função de fazer a análise foliar para culturas em geral. A partir das imagens capturadas, é feita análise e quantificação automática de deficiências nutricionais, bem como a identificação de doenças e ataques de insetos. A captura da imagem pode ser feita por câmera fotográfica, scanner ou câmera de vídeo. A identificação de regiões nas folhas é feita a partir de técnicas de processamento de imagens digitais. O AFSoft também permite que se faça a realização de análise em lote de imagens, que utilizam técnicas baseadas em inteligência artificial para classificar os padrões encontrados nas folhas, criando um banco de dados com a função de identificar e quantificar os problemas que afetam a cultura, tornando possível um diagnóstico preciso (JORGE; SILVA, 2009).

Outro trabalho similar ao AFSoft, porém voltado ao uso exclusivo na cultura de soja, para a identificação da ferrugem asiática foi proposto na X SBIAgro (X Congresso Brasileiro de Agroinformática), que ocorreu de 21 a 23 de outubro de 2015 em Ponta Grossa. No artigo, é considerada a criação de um software capaz de identificar a doença nas folhas de soja através da análise de imagem digital utilizando técnicas de redes neurais. O que se mostrou um projeto viável e possível com o desenvolvimento de um protótipo (CASSOL; AGOSTI, 2015).

Ainda no X SBIAgro, foi apresentado um trabalho que usa descritores de imagens para a identificação de tipos de plantas, foram analisados a combinação dos descritores HOG, SIFT e SURF e cada descritor individualmente, a taxa de acertos foram: 88.40% para o HOG, 90.40% para o SIFT, 90.40% para o SURF e a combinação dos três descritores a taxa foi de 95.6%. Para fazer as classificações foram usados o SVM, a base de dados continham 1000 imagens no total, sendo de 20 espécies diferentes (ARAÚJO; JR; FALATE, 2015).

Em fase experimental, o aplicativo *mobile* Detector de Pragas desenvolvido em 2015 por pesquisadores da Universidade Federal de Mato Grosso do Sul (UFMS), disponível na Play Store, visando a aplicação no agronegócio, que tem por objetivo indicar a possibilidade da existência de determinada praga e apresentar informações sobre a mesma. Mesclando os recursos da computação móvel com a visão computacional, através de reconhecimento de padrões em imagens das plantas.

Descritores locais são utilizados em conjunto com o histograma de palavras visuais BOVW (*"Bag of Visual Words"*), sendo usados para reconhecer a ferrugem asiática em folhas de soja. Os descritores usados foram: SIFT (*"Scale-invariant feature transform"*) DSIFT (*"Dense scale-invariant feature transform"*), PHOW (*"Pyramid histograms of visual words"*), SURF (*"Speeded-UP robust features"*) e o HOG (*"Histogram of oriented gradients"*) (PIRES *et al.*, 2016). O banco de imagens continham imagens de folhas de soja com 4 estágios da ferrugem asiática, para o classificador usado foi o SVM. E foi constatado que o descritor com maior acurácia para foi o PHOW.

Em seu trabalho, Viana (VIANA, 2017) propôs o uso do descritor SIFT e momentos de cor para a identificação de espécies de plantas a partir da imagem da folha. Foi usado o classificador SVM e a taxa de acurácia apenas para o SIFT foi de 77.71% com a adição dos momentos de cor a taxa da acurácia aumentou para 80.21%.

A inovação na agricultura foi um dos fatores preponderantes para o aumento da produção agrícola. Devido ao implemento de novas tecnologias foram possíveis novos horizontes para a agricultura. Entretanto, como visto neste capítulo, algumas doenças podem diminuir o rendimento da safra. Foram analisados três tipos de doenças que influenciam negativamente, assim como os sintomas que elas apresentam, a maneira de controlar cada uma das doenças, os métodos existentes para fazer a identificação automática e alguns estudos com temas relacionados. Para um melhor entendimento das técnicas utilizadas o próximo capítulo traz os conceitos básicos sobre a visão artificial.

Capítulo 3

SISTEMA DE VISÃO ARTIFICIAL

A visão é um dos sentidos mais importantes para os humanos, com ela um espectador é abastecido com vastas informações sobre o meio ambiente ao seu redor. Essa maneira de se obter informações também é de interesse das máquinas, sendo desenvolvido sistema artificiais que visam obter essa percepção.

A visão computacional em si é uma ciência recente, uma das primeiras referências sobre o assunto data de 1955, onde Selfridge mencionou: "... *eyes and ears for the computer*" que traduzido é: "...olhos e ouvidos para o computador" (SELFRIDGE, 1962).

O sistema visual humano é o modelo a ser alcançado pela visão artificial, por ser um sistema onde sua principal característica é a eficiência e com capacidades cognitivas natos do ser humano, tem a capacidade de inferir sobre informação incompleta, reconhecer padrões, etc (PEDRINI; SCHWARTZ, 2008). Os sistemas de visão artificial, por meio de imagens obtidas por equipamentos que fazem a captura, como *scanners*, câmeras de fotografia ou vídeo, entre outros equipamentos, têm como objetivo a extração de informação, a construção de descrição explícitas e claras da imagem estudada (BALLARD; BROWN, 1982).

Na década de 70, começaram os primeiros trabalhos mais aprofundados de Visão Computacional aliada à Inteligência Artificial. Acreditavam que era possível representar em pouco tempo o sentido da visão humana de forma cabal em uma máquina. Entre os estudos da época se destacaram "*The Psychology of Computer Vision*" (A Psicologia da Visão Computacional) e "*A framework for representing knowledge*" (Uma ferramenta para representar o conhecimento), ambos de 1975. Porém, com pesquisas nas décadas subsequentes, foi constatado que a complexidade de reproduzir com exatidão o sistema visual humano era maior que o imaginado inicialmente, principalmente pela falta de informações e de modelos que representassem a forma como as imagens são interpretadas no cérebro humano. Alguns cientistas tenta entender o funcionamento do cérebro humano, especificamente o córtex visual para que seja possível replicar o conhecimento na Visão Computacional.

Como adaptar o sistema visual humano totalmente em um único sistema artificial é

computacionalmente inviável, por sua complexidade, realizar algumas aproximações é perfeitamente possível. Nesse caso, apenas algumas características são reproduzidas, obtendo apenas as informações relevantes do estudo (ALBUQUERQUE; ALBUQUERQUE, 2001).

3.1 Imagem Digital

Basicamente uma imagem é a representação de uma cena por meio da reflexão da luz na área enquadrada e adquirida por meio de mecanismos sensíveis a luz, uma imagem digital é uma representação bidimensional, que permite o seu processamento, transferência, impressão ou reprodução (BALAN, 2009).

Tanto a produção, quanto a montagem e a manipulação da imagem poderiam demandar um grande tempo e se tornarem um trabalho exaustivo se considerarmos algumas décadas atrás. Um exemplo são as caixas pretas cobertas com tecidos que eram utilizadas em meados do século XIX como aparato fotográfico. Com a evolução dos computadores, revolucionou-se o meio de processamento de informação, e abriu-se novas possibilidades e métodos para a manipulação das imagens. A partir de seu advento as imagens passaram a ser armazenadas e processadas de uma nova forma: digitalmente, ao contrário do armazenamento e técnicas analógicas utilizadas até então. Voltado a cálculos matemáticos, o computador realiza com eficiência grande parte dos trabalhos envolvendo imagens digitais, sem falar nos softwares cada dia mais eficazes que auxiliam na manipulação da imagem.

A popularização e a proliferação de aparatos para a criação de imagens nos dias atuais são incontestáveis e permitem que essas imagens sejam transformadas e manipuladas por diversos equipamentos e técnicas de maneira intensa, provenientes da revolução digital. Com isso, a maior parte das aplicações de imagens envolvem o uso de imagens digitais.

As imagens digitais possuem duas características essenciais, que são capazes de serem calculadas por um computador e capazes de interagir (dialogar) com aquele que as crias ou aquele que as olha: a imagem digital codificada tem aspectos dimensionados por pixels e suas características são definidas automaticamente por cálculos. A imagem possui informação que pode ser convertida com apenas algumas mudanças no padrão numérico-binário. Ou seja, a criação codificada que pode ser reconhecida pelo sistema computacional. Atualmente, os programas de manipulação e desenvolvimento de imagens têm tornado possível uma produção infinita de possibilidades, tanto para os usuários comuns quanto aos usuários profissionais que buscam expandir suas experiências nas interfaces computacionais (CHOUCHOT, 2003).

3.2 Cores

A cor é uma característica importante para a análise de imagens realizada pelos seres humanos, por meio dela é possível associar significados e identificar objetos em uma cena. Assim, na análise feita através de máquinas esta também é uma característica a ser levada em consideração. A descoberta sobre as cores foi feita por Isaac Newton (1642-1727) em 1666 e foi denominada de "Teoria de Cores", ele constatou que um feixe de luz branca (do sol) ao atravessar um prisma de vidro poderia ser decomposto em um espectro contínuo de cores, variando do violeta ao vermelho ou as cores do arco-íris. E com uma lente e outro prisma é possível recompô-las em luz branca (MENESES *et al.*, 2012).

Entretanto, esse intervalo criado com a decomposição da luz branca passando pelo prisma, denominado de faixa visível do espectro, corresponde apenas a uma pequena região do espectro eletromagnético cujo comprimento da onda é capaz de sensibilizar o olho humano. O aspecto total do espectro é composto por radiações eletromagnéticas que incluem as ondas de rádio, micro-ondas, os raios infravermelhos, os raios X e os raios gama. Na Figura 3.1 é mostrado todo o espectro dando ênfase para a faixa visível.

Figura 3.1 – Espectro eletromagnético.

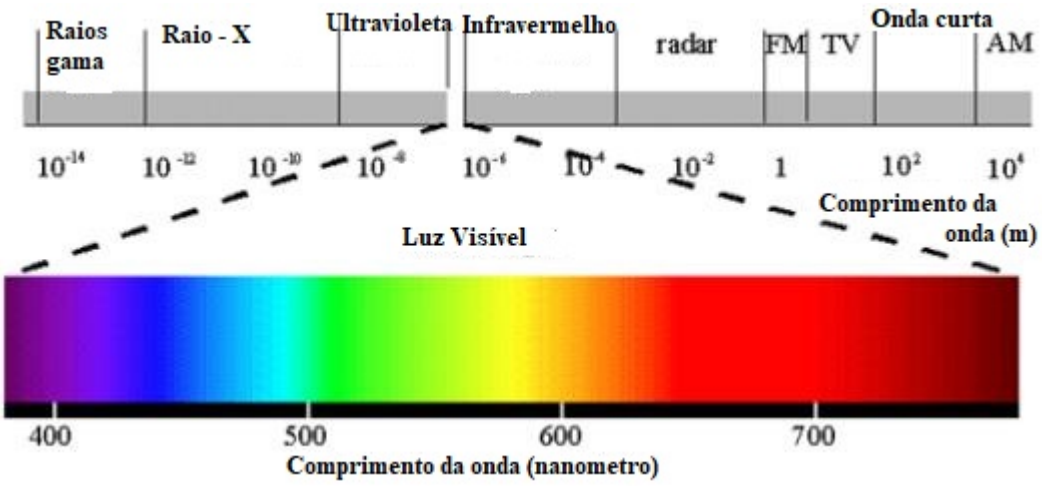

Fonte: adaptado de (YORK UNIVERSITY, 2013).

Ao percorrer o espaço, a luz se comporta como uma onda e emite características específicas de energia eletromagnética. Na região visível, os menores comprimentos de onda estão associados à cor violeta e os de maior comprimento à cor vermelha, passando pelas ondas de cores azuis, verde, amarelo e laranja. Esse tipo de associação é feito pelo sistema visual humano.

Na formação das cores se destacam dois processos que são de suma importância (PEDRINI; SCHWARTZ, 2008). Os processos aditivo e o processo subtrativo:

- No processo aditivo na formação de uma cor, as ondas correspondente a dois ou mais raios luminosos são combinadas e somadas.

- O processo subtrativo da formação de cor ocorre quando a luz que os olhos recebem é proveniente de material transparente (filtro), corantes ou pigmentos, onde parte da energia luminosa incidente é absorvida e parte é transmitida.

Isaac Newton acreditava que o olho humano continha células fotossensíveis às diversas faixas do espectro visível. De fato, quando a luz atravessa os meios ópticos oculares, excita moléculas fotossensíveis dos fotorreceptores da retina que, por sua vez, iniciam o processo de codificação da informação presente nos raios luminosos até que após extenso processamento neural em vários níveis da retina, do tálamo e do córtex cerebral, ocorre a percepção da cor (BACKHAUS, 1998).

Em 1801, o físico Thomas Young (1773-1829) propôs os modelo tricromático para a percepção do olho humano. No modelo, os cones (células fotossensíveis que compõem a retina juntamente com os bastonetes) são subdivididos em três categorias, cujos valores de sensibilidade situam-se próximos do vermelho, verde e azul. Com isso, todas as sensações de cor percebida pelo olho humano são, na verdade, combinações das intensidades dos estímulos recebidos pelos três tipos de cones. Na época, parte da comunidade cientifica ficou relutante em aceitar o trabalho de Young sobre o modelo tricromático. Entretanto, vários experimentos de percepção de cor foram realizados pelo físico alemão Hermann Von Helmholtz (1821-1894) e contribuíram grandemente para apoiar a teoria de Young, que mais tarde ficou conhecida como teoria de Young- Helmholtz (HENNO, 2010).

As características para distinguir uma cor de outra são brilho, matiz e a saturação. O brilho ou a luminância, incorpora a noção de intensidade cromática da radiação. O matiz é um atributo associado com o comprimento da onda dominante numa mistura de várias ondas de luz. E a saturação expressa a pureza do matiz ou, de modo similar, o grau de mistura do matiz original com a luz branca. Assim, as cores puras são completamente saturadas. O matiz e a saturação, quando tomados juntos são denominados de crominância. No modelo de cores desenvolvidas pela CIE (Comissão Internacional de Iluminação), as cores são especificadas pela combinação das cores primárias

Modelos, ou espaços de cores em um formato padronizado, são usados para atender os diferentes dispositivos gráficos ou aplicações que requerem a manipulação de cores. O universo de cores que podem ser reproduzidas por um modelo é chamado de espaço ou gamute de cores. Não há um modelo que descreva todos os aspectos referente as cores, portanto, modelos diferentes são utilizados para especificar às características das cores. Um modelo de cor é essencialmente uma representação tridimensional na qual cada cor é especificada por um ponto no sistema de coordenadas tridimensionais.

O modelo que será utilizado para a representação de cores para o processamento digital de imagens é o RGB, onde as cores primárias são o vermelho (R, "*red*"), o verde (G, "*green*") e o azul (B, "*blue*").

3.2.1 Modelo RGB

O nome do modelo e a abreviação RGB vem das três cores primárias, ("*red*", "*green*" e "*blue*" em inglês). E só foi possível devido ao desenvolvimento tecnológico de tubos de raios catódicos, com o qual foi possível fazer o display de cores ao invés de uma fosforescência monocromática (incluindo a escala de cinza), como nos filmes preto e branco e nas imagens de televisões monocromáticas.

O modelo de cores RGB é um modelo aditivo no qual as cores primárias vermelha, verde e azul são combinados de várias maneiras de modo a reproduzirem outras cores.

Este modelo de cores é baseado em um sistema de coordenadas cartesianas, em que o espaço de cores é um cubo. As cores primárias estão em três vértices do cubo como mostrado na Figura 3.2. As cores primárias complementares ciano, magenta e amarelo estão em outros três vértices. O vértice junto à origem é o preto e o mais afastado da origem corresponde à cor branca.

Figura 3.2 – Cubo RGB.

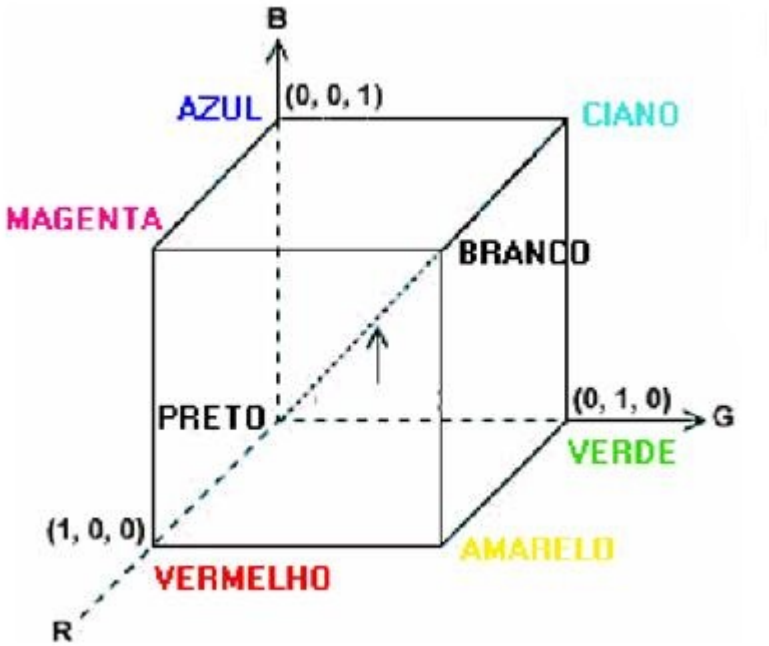

Fonte: (SOUTO, 2000).

A escala de cinza se estende através de uma das diagonais do cubo, ou seja, a reta que une o ponto mais distante da origem (cor branca), até a origem do vértice (cor preta).

O modelo de cores RGB, por si só, não define o que significa suas cores primárias espectroscopicamente, por isso o resultado de misturá-los não são tão exatos e sim relativos na média da percepção do olho humano, ou seja, cada pessoa percebe as cores a sua maneira (PEDRINI; SCHWARTZ, 2008). O processo de composição cromática pode ser interpretado como a absorção ou reflexão, em proporções variáveis, dos componentes vermelho, verde e azul da radiação eletromagnética visível incidente (QUEIROZ; GOMES, 2006).

3.2.2 Modelo HSV

O modelo de cor HSV (*Hue, Saturation* e *Value* ou: Tonalidade, Saturação e Valor, respectivamente), é baseado na percepção da cor do ponto de vista do observador. As três propriedades que definem as cores no sistema HSV são:

- **Matiz (Tonalidade):** refere ao tipo de cor (frequência dominante), abrangendo todas as cores do espectro visível. Os valores para a matiz variam de 0 a 360 graus.
- **Saturação:** é a pureza relativa, atinge valores de 0 a 100%, quanto maior esse valor, mais pura é a cor, quanto menor, mais interferência essa cor sofre.
- **Valor:** Define o brilho ou a intensidade da cor, os valores podem variar entre 0 a 100%.

A Figura 3.3 ilustra o modelo HSV. Onde **H** é o ângulo em torno do eixo que determina a tonalidade, ou seja, o tom de cada cor, a saturação **S** é medida em relação ao eixo vertical **V** que é o eixo que representa e o brilho e a intensidade da cor.

Figura 3.3 – Modelo de cor HSV.

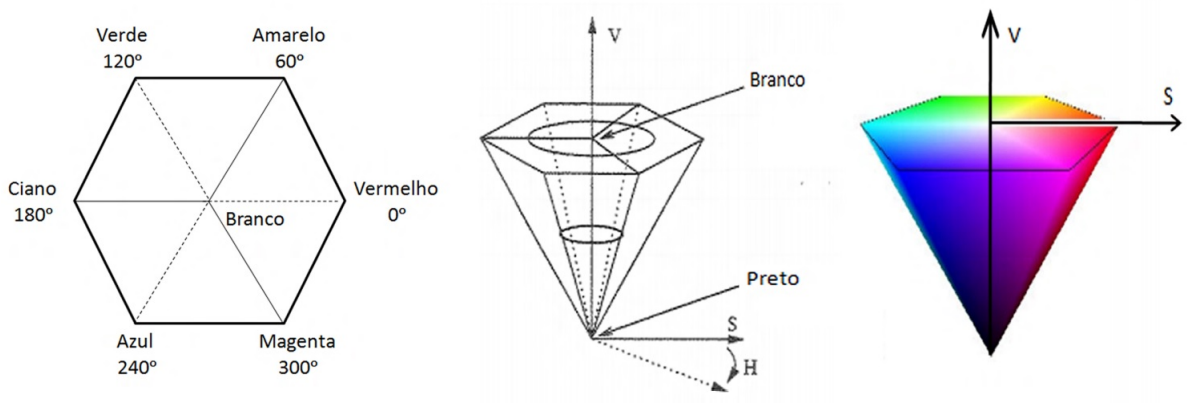

Fonte: (SANTOS, 2012).

3.2.3 Histograma

O histograma é um gráfico que irá representar a função estatística da imagem para cada nível de tonalidade, fornece uma determinada luminosidade. Histogramas represen-

tam a distribuição de intensidade dos valores de cada pixel da imagem, na Figura 3.4, é apresentado imagens de semente e seus respectivos histogramas. Com base nessa informação é possível determinar se a imagem a ser trabalhada está em um contraste ideal, se é escura ou muito clara (GONZALEZ; WOODS, 2010).

Um histograma colorido (RGB), é constituído por pilhas (*bins*), cada pixel da imagem tem uma cor que é produzida por uma combinação de cores primárias (vermelho, verde e azul). Um histograma RGB é produzido quando o computador percorre a imagem e contabiliza em quantos e quais níveis cinza os pixels estão. Logo após, o histograma deve ser normalizado, dividindo o valor total encontrado para cada *bin* pelo número total de pixels que a imagem possui (ALBANEZ, 2016).

Figura 3.4 – Representação de Histograma de imagens de feijão, canola e milho.

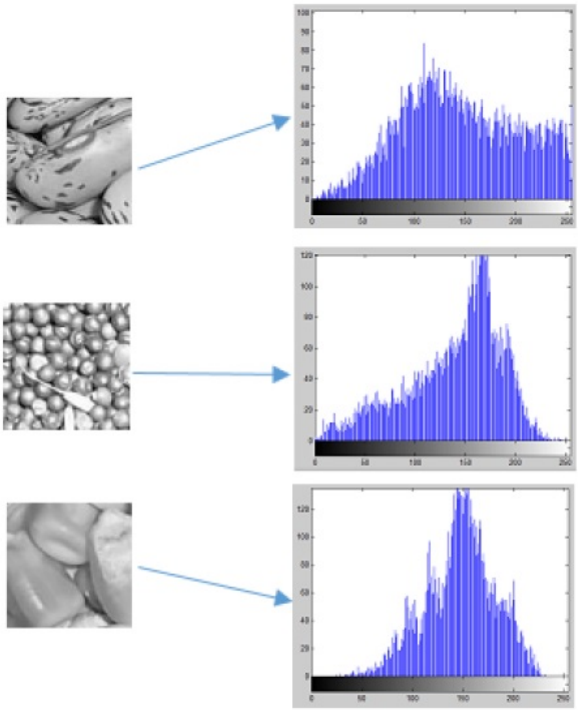

Fonte: (BORDIGNON, 2015).

A função que define o histograma de uma imagem digital com k níveis de cinza é dada pela equação 3.1.

$$hist(k) = \frac{n_k}{n} \tag{3.1}$$

Sendo k o nível de cinza, n_k é a quantidade de pixels da imagem no nível de cinza k e n é o número total de pixels que a imagem possuí, isto é, $n = M \times N$ (GONZALEZ; WOODS, 2010).

3.3 Visão Computacional

A visão computacional procura auxiliar a resolução de problemas, tentando imitar a capacidade de cognição humana e a capacidade de tomar decisões de acordo com a informação obtida, trata-se de um conjunto de métodos e técnicas que implementam sistemas computacionais com a capacidade de interpretar imagens.

A visão computacional é dividida em dois níveis de abstração para simplificar o estudo e são normalmente estabelecidos como processamento de imagens (baixo nível) e a análise de imagens (alto nível). A princípio o processamento de imagens seria apenas aplicar técnicas a fim, principalmente, de melhorar/realçar/obter algum efeito na imagem, contudo, quase sempre esse termo é utilizado de forma abrangente, englobando até mesmo a análise. A análise de imagens visa extrair informações de imagens e pode ser baseada na forma, na textura, nos níveis de cinza ou nas cores.

Há outra importante distinção a ser feita, que é entre o processamento de imagens e a computação gráfica. Os dois estudos seguem caminhos com direções opostas: um busca melhorar e extrair informação, a outra busca sintetizar informação, embora que as técnicas envolvidas em cada caso possam ser as mesmas (ALBUQUERQUE; ALBUQUERQUE, 2010). Enquanto a computação gráfica parte de uma informação precisa para obter uma imagem ou um filme, o processamento de imagens parte da imagem, que é obtida por uma câmera, ou de uma sequência de imagens para assim poder obter a informação.

3.4 Processamento digital de imagens

O processamento digital de imagens é uma forma de processamento de dados em que a entrada ou a saída são imagens. Utilizando essa técnica é possível conseguir informações das imagens e melhorar a qualidade visual de certos aspectos estruturais facilitando assim a interpretação por meio de máquinas.

O processamento de imagens é uma área relativamente nova e em franco crescimento. Diversos temas são abordados: a compreensão de imagens, a análise em mais de uma resolução e também frequências, a análise estática, codificação, transmissão de imagens entre outros.

O estudo de processamento de imagens deriva da disciplina de processamento de sinais. Os sinais assim como as imagens possuem informações, e para extrair essas informações é necessário transformá-las, aplicando métodos sucessivos com o objetivo de obter de maneira sintetizada a informação existente. Um dos problemas do processamento de imagens é que depende de muitas disciplinas e conhecimento em diversos domínios para resolver um problema de maneira satisfatória. Entre as áreas de conhecimento estão a geometria computacional, visualização científica, psicofísica, estatística, teoria da informação

dentre muitos outros (PEDRINI; SCHWARTZ, 2008).

Neste Capítulo foi apresentando uma visão geral dos conceitos básicos envolvidos em Visão Computacional. Os conceitos servem para o entendimento do trabalho como um todo e mostram algumas das características e funcionalidade que uma imagem digital possa ter. No Capítulo 4 são apresentados os modelos de sensoriamento remoto, dos quais as imagens podem ser obtidas.

Capítulo 4

SENSORIAMENTO REMOTO

O ambiente terrestre está em constante mudança devido às atividades humanas. Para compreender melhor os fenômenos que causam tais alterações, é preciso que se façam observações em escalas temporais e espaciais através de equipamentos dedicados a coletar as informações necessárias para o monitoramento e a modelagem destes fenômenos.

Com objetivo de auxiliar e expandir a percepção sensorial do ser humano, o Sensoriamento Remoto (SR) adquire informações que, a princípio, estão além da capacidade humana, como é o caso da obtenção de imagens aéreas ou espaciais e das regiões do espectro eletromagnético não visível. Os sensores que usam imagens podem medir a radiação eletromagnética em um amplo intervalo de comprimento de ondas, baseados na espectroscopia de refletância, e são entendidos como dispositivos que permitem a detecção, aquisição e análise de informações dos objetos que compõem a superfície terrestre, usando as medidas da reflexão da radiação eletromagnética (REM) (BATISTA; DIAS, 2005). E por meio de softwares, fazem o tratamento de imagens, permitem diagnósticos eficientes e criam alternativas inteligentes para os desafios enfrentados face às mudanças que se sucedem.

A quantidade da energia eletromagnética refletida é resultado da interação entre o objeto e a energia eletromagnética incidente. Essas interações são determinadas pelas propriedades físicas, químicas e biológicas, bem como da estrutura atômica dos seus átomos expressas nos segmentos de bandas, através de características da curva de refletância, que são características de cada objeto, e podem ser identificadas nas imagens e nos dados dos sensores remotos. Assim, a energia eletromagnética refletida pelos objetos terrestres é a base de dados para todo o processo de sua identificação (MORAES, 2002).

A energia eletromagnética ao atingir a superfície de um objeto (energia incidente), sofre reação com o material que o compõe, ocorrendo a reflexão, absorção ou a transmissão, que pode ser total ou apenas parcial, como ilustra a Figura 4.1.

Figura 4.1 – Interação da energia eletromagnética com o objeto.

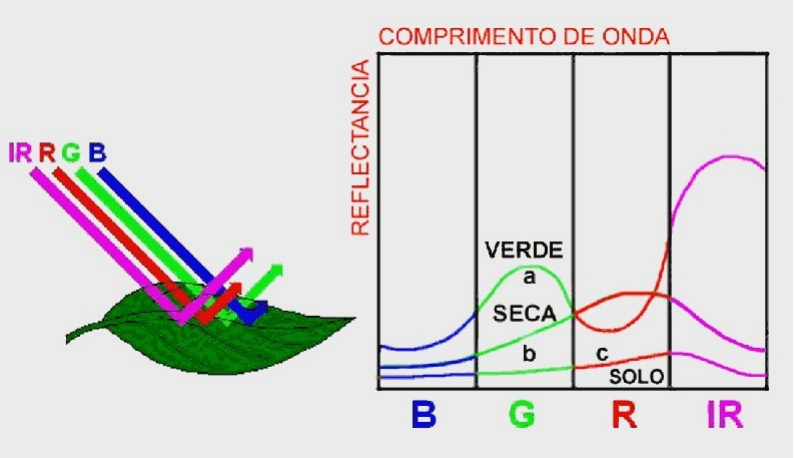

Fonte: (STEFFEN, 2000).

A assinatura espectral é o conjunto dos valores sucessivos da refletância do objeto ao longo do espectro eletromagnético. E a assinatura determina a forma, a feição e a localização de cada banda que caracteriza o objeto. Cada objeto tem uma característica diferente ao interagir com a energia incidente, o que torna possível a distinção e o reconhecimento de cada um pelos sensores remotos, pois são reconhecidos devido à variação da refletância (FORMAGIO *et al.*, 1989).

4.1 Modelos de Sensores

A radiação eletromagnética de cada comprimento de onda interage de forma e intensidade distinta sobre os objetos. A característica para definir o uso de um sensor é delimitar qual o comprimento de onda da imagem será adquirida. As imagens são definidas em pequenos intervalos do comprimento da onda, chamados de bandas espectrais (MENESES *et al.*, 2012).

Normalmente a vegetação sadia apresenta alta absorção da energia eletromagnética na região do espectro visível, que é capturada pela clorofila para a realização da fotossíntese. O uso de sensores óticos comumente usados na agricultura são: o visível, o sensor infravermelho próximo e o sensor termal, que possibilitam medir a refletância do comportamento espectral da cultura, solo, ou água ao longo da radiação eletromagnética, seu comprimento estende-se de 0,3μm a 1,5μm como mostra a Figura 4.2 (MORAES, 2002).

Estudando o padrão espectral da vegetação é possível identificar o seu estado de saúde e estágio fisiológico, identificar estresse hídrico, nutricional bem como detectar a transpiração, a redução de absorção de gás carbono ou a redução de fotossíntese (BATISTA; DIAS, 2005).

Figura 4.2 – O espectro eletromagnético.

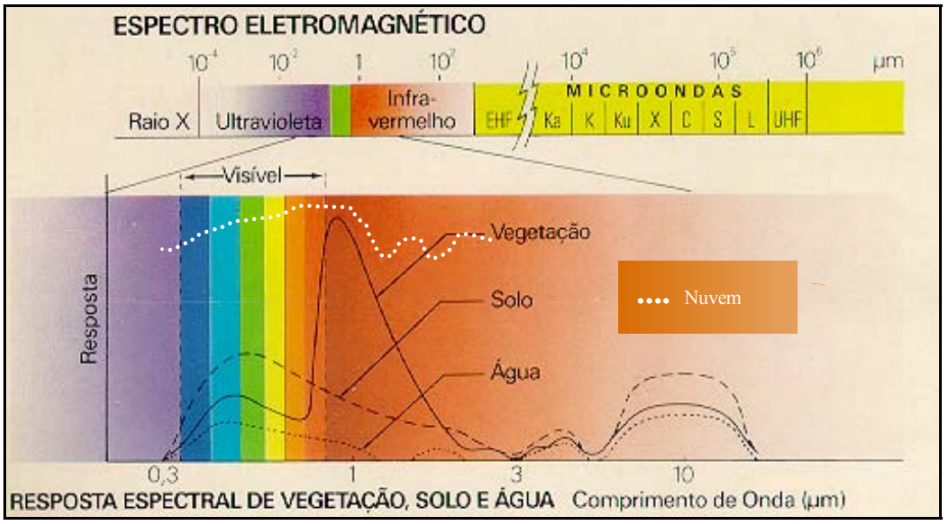

Fonte: (MORAES, 2002).

4.1.1 Visível

A radiação do visível é composta por vários comprimentos de onda (RGB), abrangendo a região de 0,4 a 0,7 μm do espectro eletromagnético. As cores que vemos num objeto dependem dos comprimentos de onda que são refletidos por ele. As plantas absorvem muito da radiação visível que incide sobre elas (MENESES *et al.*, 2012). A Figura 4.3 ilustra uma imagem capturada com um sensor visível, da cultura de cana-de-açúcar, na imagem é possível observar o contraste da plantação com o solo o que possibilita identificar as falhas de plantio.

Figura 4.3 – Imagens no visível de cana-de-açúcar.

Fonte: (ALVES; FERREIRA; GALLIS, 2015).

4.1.2 Infravermelho Próximo

Os sensores infravermelhos próximo abrangem a região de 0,7 a 1,3μm do espectro eletromagnético. E são úteis para a identificar o estresse nutricional, indicadores fisiológicos e estrutura da copa da vegetação, aspectos que não são facilmente detectados pela imagem no espectro visível. Também costumam ser designadas por infravermelho termal, por compreender a região onde se encontra o pico de emissão de qualquer corpo na faixa de temperatura de –50ºC à 50ºC (FREITAS; LOMBARDO, 2007).

O sensor baseado no infravermelho próximo tem a capacidade de calibrar índices, ou seja, colocar em evidência uma determinada característica da vegetação. Dentre as já desenvolvidas estão: determinar o vigor da planta, senescência[1], estresse hídrico, entre outros. A Figura 4.4, mostra uma parte irrigada por um pivô usando o sensoriamento por infravermelho.

Figura 4.4 – Irrigação por Pivô.

Fonte: (JORGE; INAMASU, 2014).

4.1.3 Hiperespectral

Os sensores hiperespectrais revolucionaram os estudos sobre Sensoriamento Remoto. Estudos iniciados entre as décadas de 80 e 90, mostraram as vastas aplicações bem como o grande potencial no mapeamento do objeto a ser estudado. Os sensores hiperespectrais, são capazes de registrar centenas de bandas espectrais contínuas no espectro da reflectância (MENESES *et al.*, 2012).

Uma imagem hiperespectral é um hipercubo de dados, que possui capacidade para analisar o espectro nos alvos com exatidão, além de proporcionar o desenvolvimento de índices associados às propriedades da vegetação que não eram possíveis apenas com a análise da imagem multiespectral, devido ao seu pequeno número de banda. A Figura 4.5 compara a diferença entre imagens multiespectral de 4 bandas e hiperespectral com 363 bandas, com os respectivos espectros de reflectância.

[1] Processo de envelhecimento da planta.

Figura 4.5 – Comparação entre imagem multiespectral de 4 banda com a hiperespectral com 363

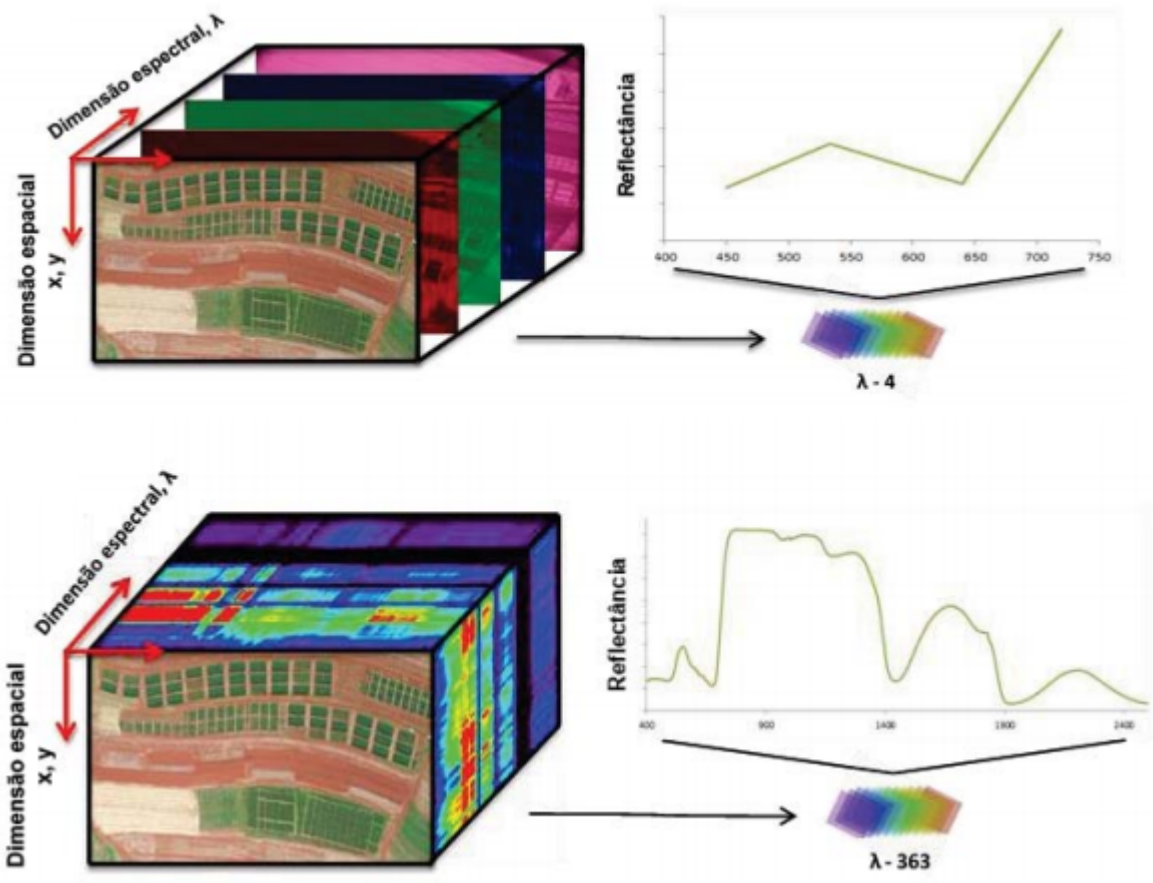

Fonte: (FURLANETTO *et al.*, 2017).

Quando aplicada à vegetação, os sensoriamentos hiperespectrais, possibilitam estudos detalhados dos padrões espectrais, os quais são associados à diversas características da planta e a fatores que irão afetar seu desenvolvimento, como a capacidade de identificar a clorofila, celulose, amido, água, além de possibilitar a identificação e classificação do comportamento de outros bioquímicos que exercem influência em determinadas espécies.

Assim, muitos estudos têm conseguido resultados positivos para encontrar as medidas dos elementos químicos e biofísicos que estão relacionados à vegetação (JORGE; INAMASU, 2014).

Este capítulo apresentou uma introdução ao sensoriamento remoto, expondo as características dos modelos. No próximo Capítulo serão apresentados os descritores propostos e os classificadores que serão utilizados nos experimentos.

Capítulo 5

DESCRITORES E CLASSIFICADORES

Objetos em imagens possuem características próprias, como: forma, cor e textura. Por meio dessa abordagem, as propriedades desses objetos podem ser mensuradas em vetores de características que têm como finalidade representar os aspectos visuais relevantes de uma imagem.

Os vetores de características de uma imagem são úteis para diversas aplicações na área de visão computacional, sendo amplamente utilizados em processamento de imagens digitais, como ferramentas de reconhecimento de objetos, texturas, recuperação de imagens, recuperação e classificação de imagens (FERRAZ, 2016). Por meio de descritores é possível levantar informações sobre o conteúdo de uma imagem que podem ser relevantes para classificar e identificar objetos na imagem (PENATTI, 2009).

Descritores são divididos em dois tipos, globais e locais. As metodologias globais ignoram as características locais da imagem, enquanto as metodologias locais visam extrair características mais discriminantes e robustas. Dentro desses tipos existem vários descritores com técnicas diferentes, há os que usam a frequência das cores predominantes, os que comparam formas utilizando modelos ou pontos de controle e os que exploram a relação da vizinhança entre os pixels (SANTOS, 2009). Assim, existem variadas técnicas de reconhecimento e análise de imagens para a extração de padrões.

- **Descritores Globais**: O método global é quando se considera uma informação contida em um imagem de maneira geral e não é preciso nenhum pré-processamento na imagem para a extração de características.

  Normalmente esse tipo de descritores apresentam algoritmos simples e funcionais, porém, são pouco adequados para a identificação de detalhes, pois descrevem a imagem inteira por um único vetor de característica.

- **Descritores Locais**: São métodos que consideram uma informação ao redor de pontos de interesse especifico na imagem.

Existem diversas técnicas para descrever os pontos de interesse em uma imagem. Os descritores locais são computados ao redor de pontos de interesse, esses pontos podem ser encontrados diversas vezes dentro de uma imagem.

Após encontrarem os pontos de interesse da imagem, são calculados os vetores de características para as regiões determinadas pelos pontos de interesse.

5.1 Textura

Embora não tenha uma definição precisa sobre textura, este atributo é fonte rica de informações, sendo que possui características visuais importantes durante o processo de classificação e reconhecimento, tendo grande relevância e sendo amplamente utilizada em aplicações com base em visão computacional.

A textura pode ter definições diferentes, dependendo da maneira que pode ser interpretada ou na forma que for aplicada, por exemplo, na segmentação de rios em mapas, identificação de mancha de óleo em mares, reconhecimento de movimentos, entre outras. Por ser bem subjetivo muitos dos descritores foram desenvolvidos seguindo uma definição.

No entanto, as principais técnicas abordadas no processamento digital de imagens para descrever a textura de uma região são enquadradas em três categorias: estatística, estrutural e espectral (GONZALEZ; WOODS, 2010).

5.1.1 Abordagem Estatística

Nos métodos de abordagem estatística, a textura é descrita por regras que regem a distribuição e a relação entre os níveis de cinza de uma imagem. Sendo que a interação, ou a falta dela, é medido por meio de coeficientes probabilísticos.

A quantidade de pixels utilizadas nesse método classifica qual a sua ordem, sendo os de primeira ordem com um pixel, os de segunda ordem com dois pixels e os de alta ordem com três pixels ou mais. Os coeficientes baseados em estatística de primeira ordem utilizam do histograma para avaliar a distribuição de níveis de cinza na imagem e para extrair as características. Nos coeficientes de segunda ordem é abordado a relação entre um pixel e seus vizinhos, criando assim uma maior significância ao descritor (TRAVAINI, 2015).

Dentre os coeficientes de características que podem ser extraídos de uma textura estão: a variância, segundo momento angular, diferença da entropia, medida de informação da correlação e coeficiente de correlação máxima, energia, contraste, correlação, homogeneidade, soma da entropia, entre outros.

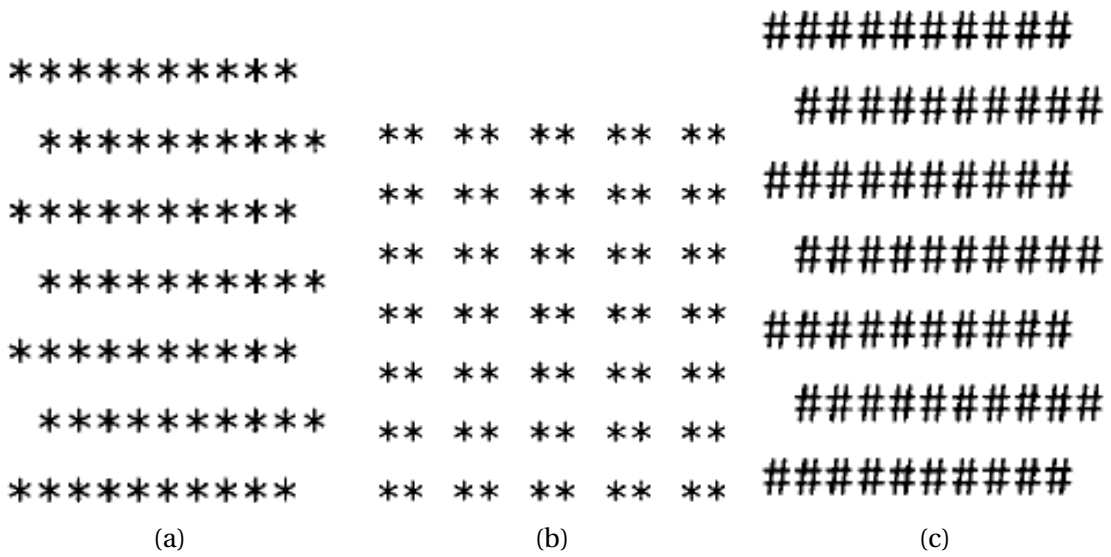

Figura 5.1 – Exemplo de primitivas de textura

5.1.2 Abordagem Estrutural

O foco da abordagem estrutural é buscar primitivas e padrões bidimensionais que podem ser construídos utilizando de um conjunto de regras. A primitiva é a forma e a estrutura geométrica básica que forma a textura.

As relações espaciais entre as primitivas podem ser semelhantes ou distintas como mostra a Figura 5.1, onde (a) e (b) possuem o mesmo número e o mesmo tipo de primitivas mas não possuem a mesma forma, logo não são a mesma textura, assim como, (a) e (c) possuem semelhanças no formato espacial e a mesma quantidade de primitivas, apenas essas características similares não é possível afirmar que a textura seja a mesma, sendo assim, esses modelos não são suficientes para descreverem texturas (NASCIMENTO, 2003).

No método de abordagem estruturais, a intenção é extrair de uma imagem um conjunto de primitivas de textura. A descrição é feita por estatística de propriedade da primitiva em questão, podendo ser o desvio padrão dos níveis de cinza, a média, área, orientação, entre outros.

5.1.3 Abordagem Espectral

O método de abordagem espectral é baseado no domínio espacial que se refere ao próprio plano da imagem, sendo a análise diretamente nos pixels. O espectro de Fourier é indicado para descrever padrões semi periódicos ou periódicos em uma imagem.

Na transformada de Fourier, o domínio de uma imagem passa de espacial para o domínio de frequência, decompondo seus componentes em seno e cosseno. A saída da transformada representa a imagem no domínio da frequência, onde cada ponto significa uma frequência contida no domínio espacial da imagem. De forma que, o sistema de coordena-

das do plano de domínio de frequência proporciona uma interpretação relacionada com a característica de textura.

Para descrever texturas através dessa abordagem são utilizadas três características: (1) Picos proeminentes no espectro que fornece o padrão de textura; (2) a posição dos picos no plano de frequência, para identificar o padrão de textura; (3) eliminação de componentes periódico com o uso de filtros para o fornecimento de resultados não periódicos e que possam ser descritos por técnicas estatísticas (CHIERICI, 2015).

O espectro de uma imagem real é simétrico em torno da origem, de maneira que apenas metade do plano das frequências é considerado, sendo que, para propósito de análise, cada padrão é associado a apenas um pico no espectro.

5.2 Medidas de similaridade

As medidas de similaridades são elementos que comparam os vetores de características e apresentam a proximidade desses vetores, ou seja, se a imagem possui características que são similares. A similaridade é determinada pelo inverso da distância, no qual zero determina o maior grau de proximidade, e valores maiores representam a diferença entre os objetos, quanto maior a distância mais distintos eles são.

As medidas que calculam as similaridades são bem tradicionais, como a distância L1, também conhecida como distância Manhattan ou *City-Block*, ela calcula a distância entre dois vetores de características e é definido pela soma da diferença absoluta dos elementos dos vetores de característica, como mostra a equação 5.1.

$$L1(P,Q) = \sum_{i=1}^{l} |p_i - q_i| \tag{5.1}$$

Onde P e Q são dois vetores e p_i e q_i pontos pertencentes a P e Q, l o tamanho dos vetores. Outra função de distância comumente usada é a L2, ou a distância Euclidiana, nessa função é calculado a distância entre os vetores de características, como mostra a equação 5.2.

$$L2(P,Q) = \sqrt{\sum_{i=1}^{l} (p_i - q_i)^2} \tag{5.2}$$

Entretanto, as funções de distâncias apresentadas só podem ser utilizadas quando o número de características dos vetores é idêntico, ou seja, os vetores P e Q precisam ter o mesmo tamanho.

5.3 Descritores Utilizados

Os descritores locais utilizados no estudo serão apresentados nesta seção.

5.3.1 *Color Moments* (CM)

O descritor CM (*Color Moments*) permite a comparação e diferenciação entre imagens com base na análise probabilística da distribuição de cores. Característica como a cor de uma imagem é frequentemente utilizada dado a sua robustez e por serem invariantes à rotação (SHIH; CHEN, 2002). O descritor CM obtém informação de cada pixel da imagem e não envolve uma relação local entre os vizinhos. Uma das vantagens é que não é preciso armazenar a distribuição de cor completa, apenas os momentos de cores são suficientes.

Normalmente uma imagem colorida está definida como um modelo RGB, porém o RGB não é um modelo uniforme, logo, a primeira tarefa é alterar o espaço da cor para HSV (ou HSB). Para cada canal da imagem, seja ela RGB ou HSV, os momentos de cor são calculados separadamente. A imagem é dividida em matrizes de $M \times M$, em seguida são extraídos os momentos de cor e agrupado em componentes de cor (MOURATO, 2013). Os momentos de cor são:

- Primeiro momento de cor: **Média**. A fórmula usada para calcular a média de cor na imagem é mostrada em 5.3.

$$\alpha = \frac{1}{N}\sum_{i=1}^{N} P_{i,j} \tag{5.3}$$

  Onde α é o valor da média, N é o número de pixels da imagem e $P_{i,j}$ é o valor do pixel da imagem no ponto *I(x,y)*.

- Segundo momento de cor: **Desvio Padrão**.

  O desvio padrão é simplesmente a raiz quadrada da variância da distribuição e cor. E é calculada em 5.4.

$$\sigma = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(P_{i,j} - \alpha)^2} \tag{5.4}$$

  Em que o σ é o desvio padrão, o α é o valor da média, N é o número de pixels da imagem e $P_{i,j}$ é como antes.

- Terceiro momento de cor: **Obliquidade**.

A obliquidade dá informações sobre a simetria da distribuição, a formula utilizada é apresentada em 5.5.

$$o = \frac{\sum_{i=1}^{N} \frac{(P_{i,j}-\alpha)^3}{N}}{\sigma^3} \tag{5.5}$$

Em que $\boldsymbol{o}$ é a obliquidade, σ é o desvio padrão, o α é o valor da média, N é o número de pixels da imagem e $P_{i,j}$ é como antes.

- Quarto momento de cor: **Curtose**.

  A curtose compara o formato da distribuição analisada com o formato da distribuição normal. E é calculada em 5.6.

$$c = \frac{\sum_{i=1}^{N} \frac{(P_{i,j}-\alpha)^4}{N}}{\sigma^4} \tag{5.6}$$

Onde $\boldsymbol{c}$ é a curtose, σ é o desvio padrão, o α é o valor da média, N é o número de pixels da imagem e $P_{i,j}$ é como antes.

5.3.2 *Gray Level Co-ocurrence Matrix* – GLCM

O GLCM (*Gray Level Co-ocurrence Matrix*) é um método estatístico para a descrição de textura proposto em 1973 por Haralick e ainda é empregado com sucesso em diferentes domínios de aplicação. Com o GLCM é possível descrever os seguintes atributos que existem dentro de uma imagem: rugosidade, aspereza, suavidade, granularidade, entre outros.

A matriz de co-ocorrência é uma matriz com o resultado da quantidade de combinações não semelhante de valores da intensidade entre os pixels de uma imagem, sendo possível extrair medidas relacionadas a textura. O principal uso do GLCM é caracterizar a textura em uma imagem através de métodos estatísticos para a ocorrência de cada nível de cinza em pixels diferentes (VASCONCELOS, 2010).

Dois parâmetros estão diretamente relacionados ao método, sendo, a distância (d) entre os pixels e o ângulo θ. O GLCM pode ser especificado por uma matriz de frequências relativas P(i,j; d, θ), na qual dois elementos de textura vizinhos, separados por uma distância d em uma orientação θ ocorrem na imagem. Em geral, utiliza-se distância $d = 1$, e os ângulos mais comumente avaliados são: 0°, 45°, 90° e 135° (GONÇALVES, 2014).

Para representar a textura foram extraídas algumas das medidas proposta inicialmente por Haralick et al., o conjunto total corresponde a 14 características, porém, alguns estudos demostraram que algumas dessas 14 características eram correlacionadas, sendo que o uso simultâneo não agrega valores na maioria dos casos (MARTINS *et al.*, 2011). As características usadas foram: a energia, contraste, homogeneidade e correlação.

- **Energia:** Pode ser encontrada como Segundo Momento Angular, e avalia a uniformidade da textura em uma imagem. Sua fórmula é descrita em 5.7.

$$Energia = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (P(i,j))^2 \tag{5.7}$$

  Para P(i, j) representa o conteúdo da coordenada (i, j) da GLCM normalizada, N_g representa o número dos diferentes níveis de cinza da imagem.

- **Contraste:** É o calculo que mede a presença de uma abrupta de níveis de cinza na imagem. É dado em 5.8.

$$Contraste = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i-j)^2 P(i,j) \tag{5.8}$$

  Para P(i, j) e N_g são como antes.

- **Homogeneidade:** A fórmula que mede a regularidade presente na imagem é mostrada em 5.9.

$$Homogeneidade = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{P(i,j)}{1+(i-j)^2} \tag{5.9}$$

  P(i, j) e N_g continuam como antes.

- **Correlação:** É a fórmula que mede a dependência no nível de cinza do pixel de interesse em relação a seus vizinhos é apresentada em 5.10.

$$Correlação = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} \frac{(i-\mu_i)(j-\mu_j)}{\sigma_i^2 \sigma_j^2} P(i,j) \tag{5.10}$$

Onde P(i, j) representa o conteúdo da coordenada (i, j) da GLCM normalizada, N_g representa o número dos diferentes níveis de cinza da imagem e $\sigma_i^2 \sigma_j^2$ representam a variância de i e j, a variância mede a heterogeneidade da textura. Quanto maior a diferença entre os valores dos tons de cinza e sua média, maior a variância.

5.3.3 *Histogram of Oriented Gradients* – HOG

O Hog (*Histogram of Oriented Gradients*), é um descritor local de forma que calcula o histograma da orientação dos gradientes na imagem, proposto por (DALAL; TRIGGS, 2005).

Para a extração de características a imagem é dividida em células (pequenas janelas) não sobreposta e então é calculado o histograma de gradiente (CERNA, 2014).

O primeiro passo do método é normalizar a imagem de acordo com a iluminação, depois, são calculados os gradientes da imagem aplicando um detector de bordas, cuja máscara em x e y é de $[-1,0,1]$ e $[-1,0,1]^T$. O próximo passo é a divisão da imagem em pequenas regiões chamadas células. Para cada célula é calculado um histograma de direções de gradiente, as células são agrupadas em blocos e cada bloco é normalizado de forma separada. O descritor final consiste em um vetor com todos os componentes normalizados das células de todos os blocos, de acordo com a Figura 5.2.

Figura 5.2 – Exemplo HOG.

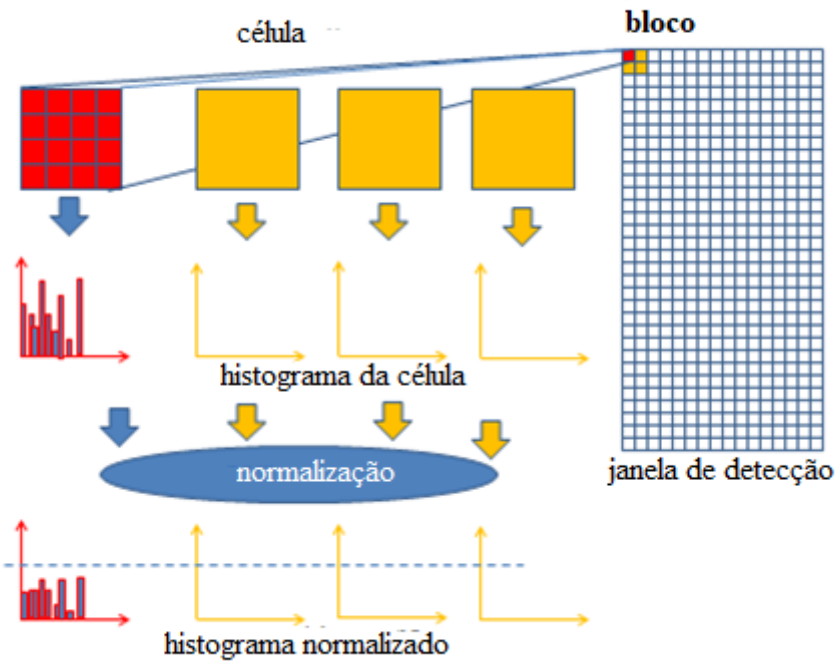

Demostração do esquema da implementação do HOG. Adaptado de (INTEL, 2016).

5.3.4 *Local Binary Patterns* – LBP

O LBP (*Local Binary Patterns*) propõe um método de análise por micro padrões, que busca realizar a comparação do pixel central com seus oito vizinhos, com o intento de adquirir um código que caracterize a micro região selecionada.

Nesse método uma vizinhança de 3×3 é limiarizada pelo valor do pixel central, então é gerado um código para substituir o valor do ponto central (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002). A limiarização do descritor LBP é obtido em 5.11.

$$E_i = \begin{cases} 1, V_i \geq V_0 \\ 0, casocontrário. \end{cases} \tag{5.11}$$

Onde V_0 representa o valor do nível de cinza do pixel central e V_i (1≤i≤8) o valor de sua vizinhança, como ilustra a Figura 5.3.

Figura 5.3 – Exemplo de vizinhança 3 × 3.

V_1	V_2	V_3
V_8	V_0	V_4
V_7	V_6	V_5

Fonte: (CHIERICI, 2015).

Os valores dos pixels vizinhos são multiplicados pelos pesos dados aos pixels correspondentes, após essa etapa, é realizado a soma dos valores no que resulta o valor do código, como mostra a equação 5.12.

$$N_{LBP} = \sum_{i=1}^{8} E_i \times 2^{i-1} \tag{5.12}$$

Onde E_i é o valor obtido pela limiarização, e i a posição do pixel na vizinhança. Pela equação, o descritor LBP gera valores inteiros contidos na faixa [0,255] (2^8 = 256 códigos resultantes). Posteriormente, é criado um histograma com os dados das ocorrências dos diferentes códigos LBP de todos os pixels da imagem, formando assim, um vetor que caracteriza a imagem de textura (BRAVO, 2016).

Entretanto, o método original apresenta o inconveniente de não ser a variação de rotação. Para contornar essa dificuldade duas versões foram proposta, a LBP *ri* (*"rotation invariant"*) e o LBP *riu* (*"rotation invariant uniform"*) (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002).

Ambas as versões modificadas são muito similares ao LBP original, porém, tornaram a definição mais abrangentes em relação a vizinhanças circulares, adequando-as para a análise multi escalar.

A Figura 5.4 apresenta a vizinhança do pixel central que é indexado circularmente, sendo que o número de vizinhos P e o valor do raio da vizinhança R podem ser definidos de acordo com o problema.

Para exemplificar a geração do código LBP, a Figura 5.5, mostra o descritor com uma vizinhança de 3 × 3 pixel ou $LBP_{8,1}$.

Figura 5.4 – Padrões Locais Binários (LBP).

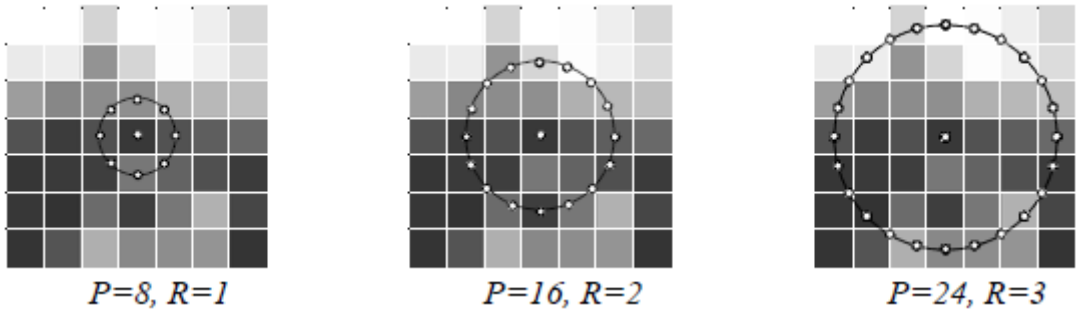

Alterando-se os valores de P e R é possível representar a textura em outras escalas. Fonte: (MUSCI *et al.*, 2011).

Figura 5.5 – Exemplo $LBP_{8,1}$.

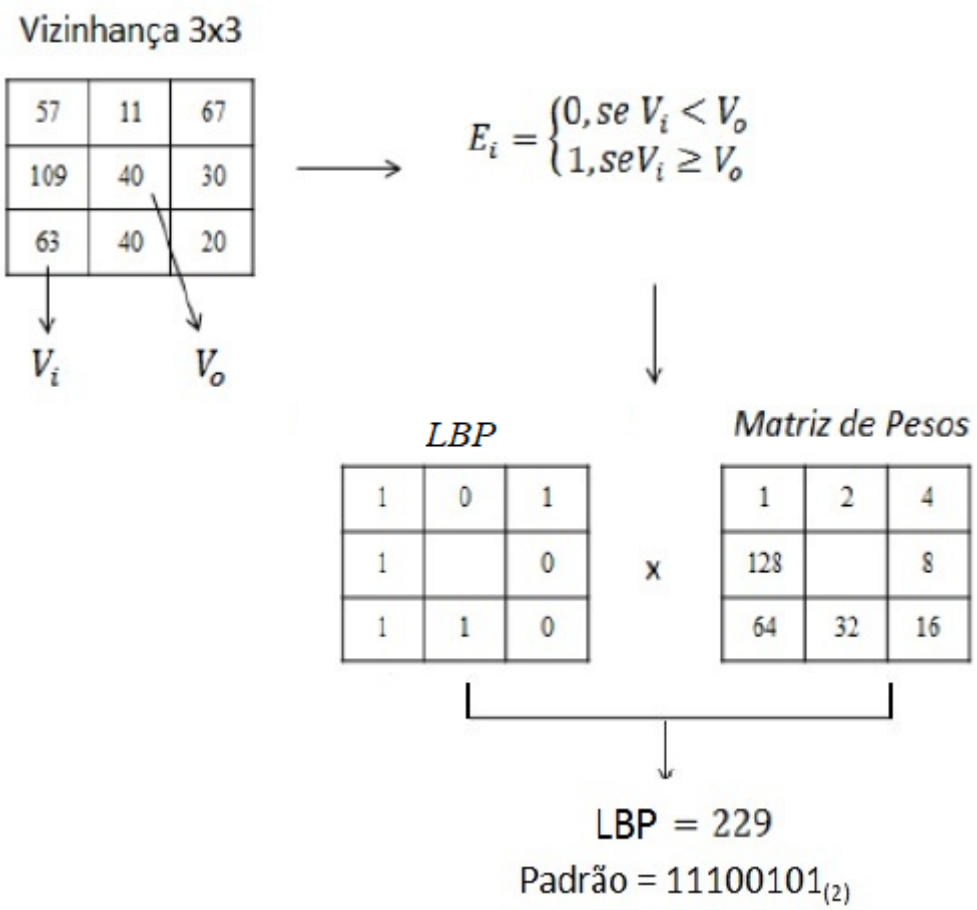

Cálculo do *Local Binary Pattern*. Fonte: (TRAVAINI, 2015).

5.3.5 *Local Phase Quantization* – LPQ

O LPQ (*Local Phase Quatization*) é um método local para a descrição de textura. Ele foi concebido para complementar e até superar o LBP, sua principal característica é a robustez para aplicação em imagens afetadas por iluminação não uniforme, com falta de foco e borradas, descrito por (OJANSIVU; HEIKKILA, 2008). O LPQ tem como base a fase quanti-

zada da transformada discreta de Fourier (*Discrete Fourier Transform* - DFT). A informação da fase local de uma imagem é obtida por uma Transformada de Fourier de Curto prazo (*Short-Term Fourier Transform* - STFT). De modo análogo ao LBP, para cada pixel na posição w é computado um código para representar a textura em uma vizinhança N_w, centrada em w, com tamanho de $M \times M$.

O LPQ considera apenas quatro coeficientes complexos que correspondem às frequências de um plano bidimensional. São eles: (0,a), (a,a), (a,0) e (a,a), indicados como pontos branco na imagem B da Figura 5.6, onde a=1/M. Gerando assim 8 bits que assumem o valor 0 caso o valor seja negativo e 1 caso contrário. Esses 8 bits são concatenados e representa a textura em N_w. Este procedimento é feito para todos os pixels da imagem formando a imagem correspondente LPQ_M.

Figura 5.6 – Exemplo LPQ.

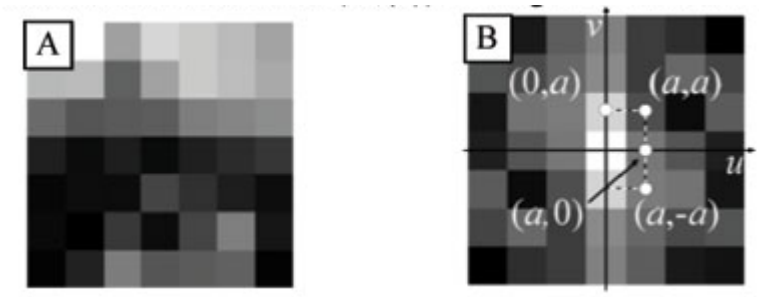

Imagem de entrada (A) e o módulo da Transformada de Fourier (B). Fonte: (MUSCI *et al.*, 2011).

Embasado na propriedade que a fase e não a magnitude possui a maior parte das informações da Transformada de Fourier, é feito um processo de redução da dimensão com relação aos 8 valores encontrados (GONÇALVES, 2014). Assim, os 8 valores complexos que foram obtidos podem ser reduzidos a 4 sem perda de informação, sabendo que os valores da Transformada de Fourier em posições simétricas são conjugados.

Por fim, as etapas de decorrelação e quantização são aplicadas. O procedimento de decorrelação tem como objetivo maximizar a informação retida no código de textura. O vetor de característica gerado através do LPQ é um histograma com 256 posições.

5.4 Classificadores

Classificadores são algoritmos utilizados para as tarefas de identificar objetos e atribuí-los a uma classe conhecida. Cada imagem é formada por um padrão de atributos. Sendo assim, cabe ao classificador por meio de modelagens matemáticas, estatísticas e relacionais identificar imagens similares, que contenham características semelhantes, e agrupá-las numa mesma classe.

Para o aprendizado dos classificadores são fornecidos conjuntos de dados para serem analisados, com cada registro já contendo a indicação à qual classe pertence, e a classe, ou seja, o rótulo, determina o significado do objeto. Fazendo com que o método "aprenda" como classificar um novo registro, esse tipo de aprendizagem é considerado aprendizado supervisionado. Métodos supervisionados precisam de uma quantidade de exemplos já rotulados para treinar um classificador e gerar um modelo capaz de prever as classes de um conjunto de dados onde suas classes não são conhecidas (CAMILO; SILVA, 2009).

As próximas subseções descrevem os classificadores individualmente que foram utilizados nos experimentos.

5.4.1 *Naive Bayes* – NB

O *Naive Bayes* (NB) é um classificador probabilístico baseado no teorema de Bayes, é considerado ingênuo (naive) por tratar todas as variáveis de predição proposta como sendo independentes umas das outras (FERREIRA, 2010).

A partir dos dados de treinamento, uma probabilidade independente é estabelecida. Essa probabilidade fornece a verossimilhança de cada classe de destino, dada a ocorrência de cada categoria de valor a partir de cada variável de entrada. A partir do teorema de Bayes dado pela probabilidade temos a equação 5.13 (MITCHELL, 1997).

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \tag{5.13}$$

Onde *P(A|B)* é a probabilidade da classe *A* dado o vetor *B, P(B|A)* a probabilidade do vetor *B* dada a classe *A, P(A)* a probabilidade a priori da classe *A* e *P(B)* a probabilidade a priori do vetor de treinamento *B*.

O classificador Bayesiano calcula a probabilidade por meio de um caso de testes de cada classe é dado pela equação 5.14.

$$P(c|X_1,...,X_p) = \frac{P(c)P(X_1,...,X_p|c)}{P(X_1,...,X_p)} \tag{5.14}$$

Para c sendo a classe e X_1,..., X_p sendo os valores observados pelos preditores para o caso de teste, a probabilidade *P(c)* pode ser vista como uma expectativa a priori de se obter a classe.

Esta decisão depende somente do numerador da equação, sendo que o denominador será constante para todas as classes (FERREIRA, 2010). Usando apenas definições da estatística na probabilidade condicional e assumindo de forma ingênua a independência

condicional dos preditores, os numeradores da fração serão reduzidos para a equação 5.15.

$$P(c)(P(c)P(X_1,...,X_p|c) = P(c)\prod P(X_i|c) \tag{5.15}$$

De forma que o classificador *Naive Bayes* implementa estimativa de probabilidades de exemplos de treinamento por meio de frequências relativas e a partir disso o método produz classes de probabilidades para todos os casos de teste.

5.4.2 *Ramdom Forest* – RF

O algoritmo de *Random Forest* (RF) é muito usado em problemas que necessitem classificar instâncias desconhecidas. E é um método de ensemble que utiliza classificadores do tipo árvore. A RF constrói uma grande quantidade de árvores de decisão para fora do subconjunto de dados a partir de um treinamento único definido (MOTTA, 2016).

Para construir uma árvore que irá compor a RF, todo o conjunto de treinamento é considerado na raiz, onde o teste de decisão que particionará os dados será definido, selecionando assim, o atributo que tem grande relação com a classe em questão para realizar a partição. Este processo segue de forma recursiva para os outros nós da árvore, utilizando a partição dos dados vinda dos nós pai, até as folhas da árvore que indicarão os rótulos da classificação (MARQUES, 2015). A Figura 6.1 exemplifica o classificador *Random Forest*.

Figura 5.7 – Exemplo de *Random Forest*.

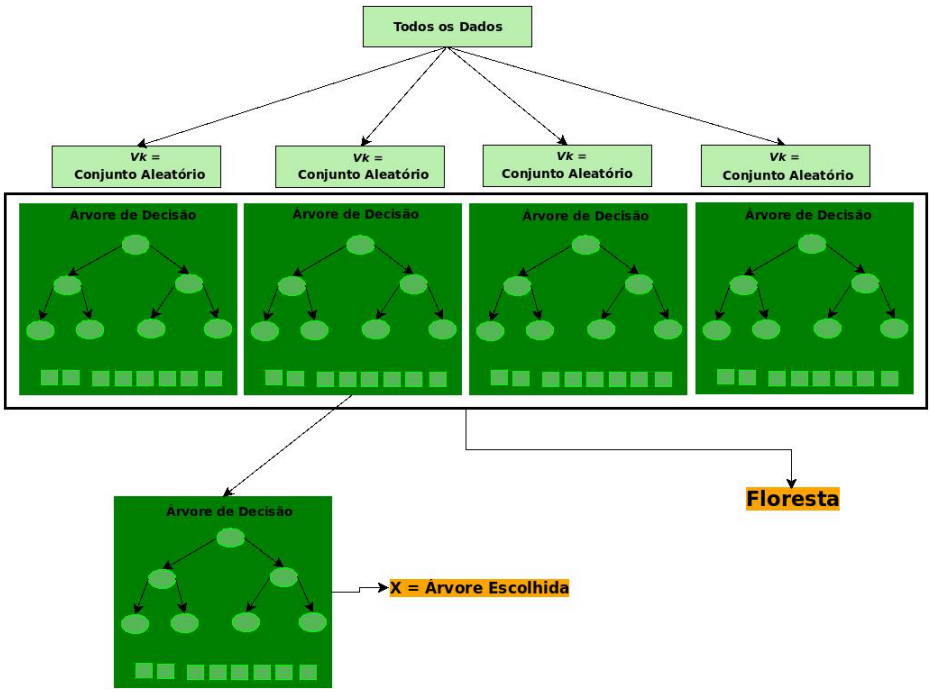

Exemplo da criação de árvores de decisão que compõem a RF. Fonte: (IBANEZ, 2016).

A utilização de bagging no treinamento extrai casos aleatoriamente a partir de conjuntos de dados de treinamento originais. O bagging é um meta-algoritmo para melhorar a classificação e a regressão de modelos de acordo com a estabilidade e a precisão da classificação (LOPES *et al.*, 2017).

Este capítulo apresentou os conceitos dos descritores e classificadores que serão analisados. Os resultados do experimento são mostrados no capítulo seguinte.

Capítulo 6

EXPERIMENTOS E RESULTADOS

Neste capítulo serão apresentados os experimentos assim como seus respectivos resultados.

6.1 Base de Dados

O banco de dados para o experimento foi formado através do banco de imagens da PlantVillage, que é uma plataforma que se dedica a pesquisa e ao estudo de doenças nas plantas. É um projeto sem fins lucrativos, e foi elaborado com colaboração entre a Penn State University e a EPFL (École Polytechnique Fédérale de Lausanne) e parte da ideia que todo o conhecimento que ajuda as pessoas a cultivarem alimentos devem ser acessíveis. Atualmente é mantida por diversos pesquisadores e profissionais tanto das áreas de agricultura como de tecnologia, sendo seu conteúdo validado por biólogos, agrônomos, botânicos, especialistas em assuntos relacionados além de toda a comunidade do fórum (HUGHES; SALATHÉ, 2015).

No total foram obtidas 12.315 imagens de folhas de soja, sendo o conteúdo validado por especialistas em patologias de plantas, botânicos, agrônomos e por toda a comunidade presente, sendo 1508 imagens de folhas de soja sofrendo com a doença de míldio, 4028 imagens da doença de olho-de-rã, 1689 imagens de folhas de soja com mancha parda e 5090 imagens de folhas de soja saudáveis. As imagens das folhas doentes foram coletadas sob a luz do sol ainda na lavoura, já as imagens das folhas saudáveis foram obtidas após colhidas e sobre um fundo branco. Para todas as fotografias foi utilizado a mesma câmera digital, uma Sony DSC - Rx100 de 2 megapixels e com uma dimensão de 800×533 pixels.

Alguns exemplos de imagens adquiridas do Álbum da PlantVillage são apresentados na Figura 6.1.

Figura 6.1 – Folhas de soja.

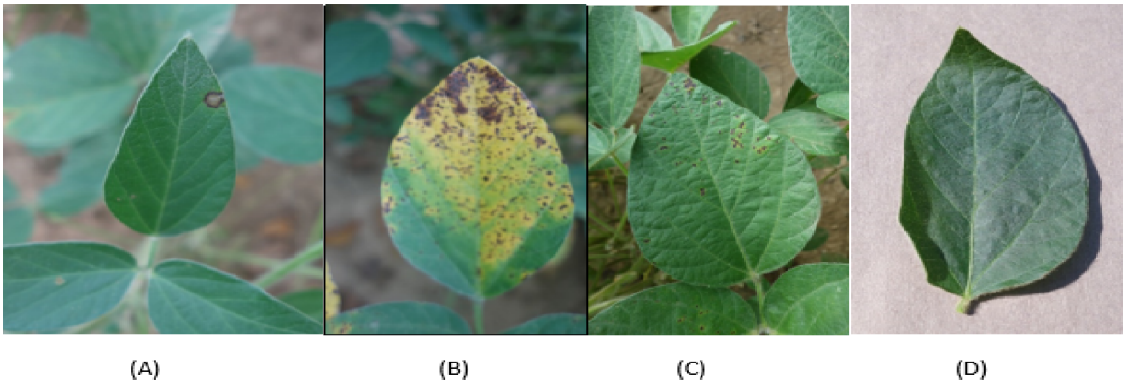

(A)Olho-de-rã (B) Mancha Parda (C) Míldio (D) Folha saudável. Fonte: PlantVillage.

Após a obtenção da base de imagens os dados passaram por um pré-processamento onde foram postos a parte imagens que eram repetidas, as que não poderiam agregar algum valor ao experimento ou que tinham pouca representatividade para a extração de características. Como resultado do pré-processamento, que foi feito manualmente, a quantidade de imagens passaram para: 378 imagens de folhas de soja com a doença do míldio, 555 imagens de olho-de-rã, 893 imagens com folhas doentes com a mancha parda e 1987 imagens de folhas saudáveis. No pré-processamento as imagens foram redimensionadas para 200 × 200 pixels, como mostra a Figura 6.2.

6.2 Experimento

O experimento utilizando os descritores propostos no Seção 5.3 foi executado no banco de dados criado a partir das imagens disponibilizadas pela PlantVillage. Os objetivos do experimento são analisar e comparar os descritores, bem como comparar as técnicas de classificações utilizados.

A implementação dos descritores para a extração da matriz de características de cada imagem do banco, foi feito no Matlab. A quantidade de características extraídas foram: 145 atributos para o descritor baseado em *Color Moments* (CM), 9 atributos para o descritor baseado em Matriz de Co-Ocorrência (COOC), 1025 atributos extraídos pelo GLCM, 577 extraídos pelo HOG, 257 pelo LBP e 257 atributos extraídos pelo LPQ.

Os primeiros testes utilizaram os descritores individualmente e, em seguida, foram testadas combinações, para tentar obter uma taxa de classificação maior, e a que houve a melhor taxa de acurácia foi a combinação entre os descritores de momento de cor e o LPQ invariante a rotação, com 401 atributos extraídos.

Após obter a matriz com as características, os dados foram submetidos ao *Weka* (*Waikato Environment for Knowledge Analysis*) para serem classificados. O *Weka* é um conjunto

Figura 6.2 – Imagens após o pré-processamento.

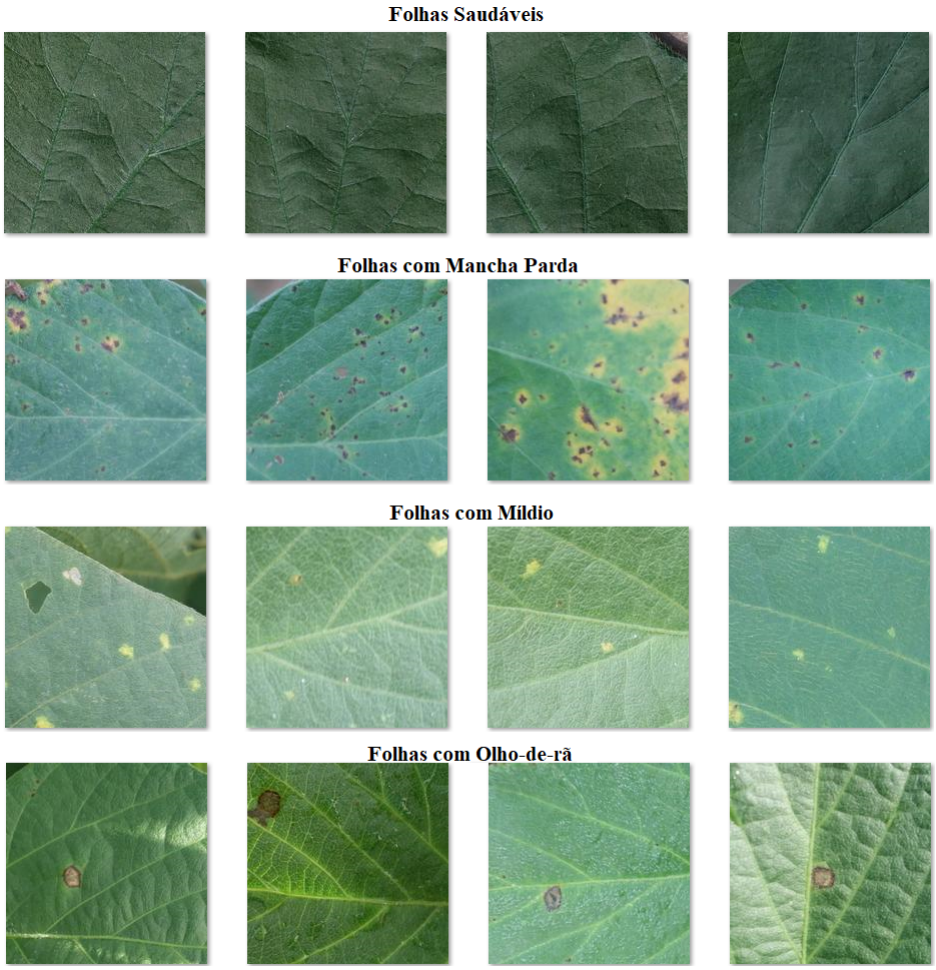

Fonte: o Autor.

de programas com diversas técnicas de mineração de dados, e começou a ser desenvolvido em 1993 na Universidade de Waikato, Nova Zelândia. E por ser um software GPL (*General Public License*), é mantido por uma comunidade de entusiastas (DAMASCENO, 2010).

Os métodos de classificações utilizados no *Weka* foram: *Ramdom Forest* (RF) e *Naive Bayes* (NB). O aprendizado das técnicas, ou o treinamento, tem como objetivo apresentar os dados processados para os métodos de mineração, que "aprendem" as características ou padrões úteis para as classificações das imagens. Após o treinamento ter sido realizado é aplicado uma avaliação, onde são apresentadas medidas estatísticas dos resultados alcançados. Entretanto, esse tipo de aprendizagem é supervisionado, ou seja, são utilizados dados com classes especificadas, no caso a imagem contém um atributo classe que especificará a qual classe ela pertence, se é a imagem de uma folha sadia ou doente, caso doente, qual o tipo da doença. Ambas técnicas usadas são preditivas, pois tentam predizer qual a classe de uma folha não vista, baseando nos exemplos de imagens utilizadas em seu treinamento. E cada classe de imagens foram divididos em dois diferentes conjuntos: o de treinamento e de

teste. A proporção para a divisão é: 70% das imagens para treinamento, 30% para testes.

6.3 Resultados

Após o pré-processamento o banco de imagens ficou composto por 3813 imagens de 200 × 200 pixels, sendo elas divididas em quatro classes distintas, 378 imagens de folhas de soja com a doença do míldio, 555 imagens de olho-de-rã, 893 imagens com folhas doentes com a mancha parda e 1987 imagens de folhas sadias.

O experimento teve como intento avaliar o desempenho das técnicas propostas e realizar uma comparação com as técnicas de classificação. A Tabela 6.1 apresenta as acurácias obtidas pelos métodos proposto, para o reconhecimento das folhas na base de dados. Como pode ser observado a combinação entre os descritores *Color Moments* (CM), LPQ-RI (*Local Phase Quantization - Rotation Invariance*) obteve a maior taxa de acerto, com 93.05%, usando o classificador *Ramdom Forest* (RF).

Os detalhes da acurácia usando os métodos CM + LPQ-RI são apresentados na Tabela 6.2 usando o classificador *Ramdom Forest* (RF) e a Tabela 6.3 apresenta os detalhes usando o classificador *Naive Bayes* (NB).

Tabela 6.2 – Detalhes da Acurácia por Classe usando RF - Método CM_LPQ-RI

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,780	0,020	0,815	0,780	0,797	Míldio
	0,814	0,027	0,835	0,814	0,825	Olho-de-Rã
	0,923	0,024	0,923	0,923	0,923	Mancha Parda
	0,995	0,022	0,980	0,995	0,988	Saudável
Média:	0,931	0,023	0,929	0,931	0,930	

Fonte: o autor.

Tabela 6.3 – Detalhes da Acurácia por Classe usando NB - Método CM_LPQ-RI

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,799	0,061	0,590	0,799	0,679	Míldio
	0,757	0,078	0,622	0,757	0,683	Olho-de-Rã
	0,693	0,038	0,847	0,693	0,762	Mancha Parda
	0,914	0,043	0,958	0,914	0,936	Saudável
Média:	0,828	0,049	0,847	0,828	0,833	

Fonte: o autor.

Observando as Tabelas 6.2 e 6.3 é a nítida diferença entre as precisões dos dois métodos de classificação.

Com relação às técnicas, os métodos que usaram o *Color Moments* (CM) para extrair as características foram os que obtiveram melhores resultados estando a média acima de

Tabela 6.1 – Resultados da Acurácia

Descritor	*Ramdom Forest*	*Naive Bayes*
CM	89.38	61.60
CM-COOC	89.70	64.67
CM-HOG	88.70	69.59
CM-LBP	89.39	60.94
CM-LPQ	89.58	61.87
CM-LBP-RI	88.72	25.63
CM-LPQ-RI	**93.05**	**61.55**
COOC	69.02	52.11
COOC-HOG	75.23	56.73
COOC-LBP	77.73	60.92
COOC-LPQ	78.20	52.11
COOC-LBP-RI	68.54	25.45
COOC-LPQ-RI	89.12	52.11
GLCM	73.31	41.31
GLCM-CM	87.64	41.32
GLCM-COOC	74.63	41.31
GLCM-HOG	76.10	41.31
GLCM-LBP	77.86	51.92
GLCM-LPQ	78.45	41.30
GLCM-LBP-RI	72.47	41.65
GLCM-LPQ-RI	86.69	41.30
HOG	72.44	53.53
HOG-LBP	76.12	60.93
HOG-LPQ	76.66	53.55
HOG-LBP-RI	72.74	25.73
HOG-LPQ-RI	87.11	53.33
LBP	76.21	60.92
LBP-LPQ	77.37	60.92
LBP-RI-LBP	73.76	55.25
LBP-RI-LPQ	88.88	60.92
LBP-RI	59.02	25.45
LBP-RI-LPQ-RI	87.87	25.46
LPQ	76.65	52.11
LPQ-RI-LBP	75.36	25.45
LPQ-RI-LPQ	88.87	52.11
LPQ-RI	88.67	52.11

Fonte: o autor.

89.77% com o classificador *Ramdom Forest* (RF). As Tabela 6.4 e a Tabela 6.5 apresenta os detalhes da acurácia, com os classificadores *Ramdom Forest* (RF) e *Naive Bayes* (NB) respectivamente, para o descritor *Color Moments* (CM).

Tabela 6.4 – Detalhes da Acurácia por Classe usando RF - Método CM

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,825	0,105	0,465	0,825	0,595	Míldio
	0,683	0,084	0,580	0,683	0,627	Olho-de-Rã
	0,624	0,035	0,847	0,624	0,718	Mancha Parda
	0,900	0,023	0,977	0,900	0,937	Saudável
Média:	0,796	0,043	0,838	0,796	0,807	

Fonte: o autor.

Tabela 6.5 – Detalhes da Acurácia por Classe usando NB - Método CM

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,032	0,000	1,000	0,032	0,062	Míldio
	0,000	**0,000**	**0,000**	**0,000**	**0,000**	**Olho-de-Rã**
	0,396	0,019	0,866	0,396	0,544	Mancha Parda
	0,997	0,773	0,584	0,997	0,737	Saudável
Média:	0,616	0,407	0,606	0,616	0,517	

Fonte: o autor.

É possível observar que a linha em destaque, referente a classe olho-de-Rã, está zerada pois o classificador não conseguiu identificar os atributos característicos da classe. Não houve nenhuma imagem classificada certa, bem como nenhuma imagem classificada como sendo olho-de-rã, assim como nenhuma imagem foi classificada erroneamente como sendo míldio. A Tabela 6.6 mostra que apenas 12 imagens do total foram classificadas como míldio (corretamente) o restante ou foram classificadas como mancha parda ou como sendo saudável. Observando a taxa de falsos positivos (FP Rate), faz notável que grade parte das imagens foram classificadas como sendo da classe saudável.

Tabela 6.6 – Matriz confusão NB - Método CM

Míldio	Olho-de-Rã	Mancha Parda	Saudável	
12	0	4	362	Míldio
0	0	45	510	Olho-de-Rã
0	0	354	539	Mancha Parda
0	0	6	1981	Saudável

Fonte: o autor.

Os métodos baseados em Co-Ocorrência obtiveram uma taxa média de 76.30% de acerto para o classificador *Ramdom Forest* (RF) e uma taxa de acerto de 49.9% com o classificador *Naive Bayes* (NB). Os detalhes apresentados na Tabela 6.7 são os dados do descritor base, sem concatenação com nenhum outro descritor, já a Tabela 6.8 apresenta o melhor resultado, que é a junção do COOC com o LPQ-RI, ambas classificadas pelo *Ramdom Forest* (RF).

Tabela 6.7 – Detalhes da Acurácia por Classe usando RF - Método COOC

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,336	0,041	0,472	0,336	0,393	Míldio
	0,231	0,058	0,403	0,231	0,293	Olho-de-Rã
	0,673	0,145	0,587	0,673	0,627	Mancha Parda
	0,891	0,237	0,803	0,891	0,845	Saudável
Média:	0,689	0,170	0,662	0,689	0,669	

Fonte: o autor.

Tabela 6.8 – Detalhes da Acurácia por Classe usando RF - Método COOC-LPQ-RI

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,720	0,026	0,753	0,720	0,736	Míldio
	0,719	0,032	0,792	0,719	0,754	Olho-de-Rã
	0,880	0,027	0,909	0,880	0,894	Mancha Parda
	0,981	0,073	0,936	0,981	0,958	Saudável
Média:	0,894	0,052	0,891	0,894	0,891	

Fonte: o autor.

Como os resultados não foram satisfatório usando o classificador *Naive Bayes* (NB), com a média das taxas de acertos usando o NB abaixo do 50%, não serão mais apresentados as tabelas contendo os detalhes da acurácia.

A taxa de acerto usando apenas o GLCM foi de 73.31%, como mostra a Tabela 6.9 já a melhor taxa encontrada foi a concatenação entre o GLCM e o CM, a taxa foi de 87.64%, apresentado na Tabela 6.10, ambos classificados pelo RF.

Tabela 6.9 – Detalhes da Acurácia por Classe usando RF - Método GLCM

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,489	0,032	0,625	0,489	0,549	Míldio
	0,243	0,029	0,590	0,243	0,344	Olho-de-Rã
	0,648	0,089	0,690	0,648	0,669	Mancha Parda
	0,958	0,299	0,777	0,958	0,858	Saudável
Média:	0,735	0,184	0,714	0,735	0,708	

Fonte: o autor.

Tabela 6.10 – Detalhes da Acurácia por Classe usando RF - Método GLCM-CM

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,714	0,026	0,754	0,714	0,734	Míldio
	0,546	0,022	0,806	0,546	0,651	Olho-de-Rã
	0,912	0,062	0,818	0,912	0,862	Mancha Parda
	0,991	0,063	0,945	0,991	0,967	Saudável
Média:	0,880	0,053	0,876	0,880	0,874	

Fonte: o autor.

Comparando os dois métodos pela Tabela 6.1, o GLCM-CM tem uma taxa de acerto de 3356 imagens classificadas corretamente, já apenas o GLCM sem a adição de outros métodos, apenas 2802 das 3813 foram classificadas certas. O que deixa notável que no uso geral os métodos conjugados obtêm um resultado melhor que os métodos sem nenhuma união.

Para o descritor HOG a taxa de acerto é de 72.44% com RF e 53.53% com o NB. A melhor taxa encontrada usando o HOG, foi ajuntando o LPQ-RI, com uma taxa de 87.11% de acerto. Os detalhes são apresentados na Tabela 6.11 para o HOG e na Tabela 6.12 para o HOG-LPQ-RI, ambos classificados pelo RF.

Tabela 6.11 – Detalhes da Acurácia por Classe usando RF - Método HOG

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,190	0,015	0,585	0,190	0,287	Míldio
	0,279	0,047	0,502	0,279	0,359	Olho-de-Rã
	0,676	0,145	0,588	0,676	0,629	Mancha Parda
	0,965	0,238	0,815	0,965	0,884	Saudável
Média:	0,721	0,167	0,693	0,721	0,689	

Fonte: o autor.

Tabela 6.12 – Detalhes da Acurácia por Classe usando RF - Método HOG-LPQ-RI

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,664	0,024	0,749	0,664	0,704	Míldio
	0,643	0,035	0,760	0,643	0,697	Olho-de-Rã
	0,858	0,040	0,867	0,858	0,862	Mancha Parda
	0,975	0,102	0,912	0,975	0,943	Saudável
Média:	0,869	0,070	0,863	0,869	0,864	

Fonte: o autor.

Com o descritor local LBP o desempenho foi de 76.21% com o RF, apresentado os detalhes na Tabela 6.13 e uma taxa de 60.92% com o NB. A melhor taxa foi encontrado usando o LBP-RI com o LPQ, a taxa de acerto foi de 88.88% classificado pelo RF, os detalhes são apresentados na Tabela 6.14.

Tabela 6.13 – Detalhes da Acurácia por Classe usando RF - Método LBP

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,437	0,028	0,635	0,437	0,517	Míldio
	0,405	0,041	0,630	0,405	0,493	Olho-de-Rã
	0,781	0,127	0,653	0,781	0,711	Mancha Parda
	0,921	0,163	0,860	0,921	0,890	Saudável
Média:	0,765	0,123	0,756	0,765	0,753	

Fonte: o autor.

Tabela 6.14 – Detalhes da Acurácia por Classe usando RF - Método LBP-RI-LPQ-RI

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,312	0,066	0,343	0,312	0,327	Míldio
	0,344	0,155	0,274	0,344	0,305	Olho-de-Rã
	0,585	0,146	0,551	0,585	0,567	Mancha Parda
	0,750	0,183	0,816	0,750	0,782	Saudável
Média:	0,609	0,159	0,628	0,609	0,617	

Fonte: o autor.

O descritor LPQ apresentou uma taxa de acerto de 76.65% quando classificado pelo RF, os detalhes são mostrados na Tabela 6.15. A melhor taxa encontrada foi com a junção do CM como classificados pelo RF e apresentado na Tabela 6.2.

Tabela 6.15 – Detalhes da Acurácia por Classe usando RF - Método LBP

	TP Rate	FP Rate	Precision	Recall	F-Measure	Classe
	0,415	0,026	0,636	0,415	0,502	Míldio
	0,400	0,044	0,607	0,400	0,482	Olho-de-Rã
	0,766	0,116	0,668	0,766	0,714	Mancha Parda
	0,943	0,165	0,861	0,943	0,900	Saudável
Média:	0,770	0,122	0,757	0,770	0,756	

Fonte: o autor.

Analisando a Tabela 6.16, onde é apresentado as matrizes confusões do método RF, com base nos descritores sem concatenação é notável que grande parte das imagens classificadas de maneira errada da classe míldio, foram atribuídas como sendo da classe mancha parda.

Para o CM, o maior erro foi classificar as imagens como sendo da classe olho-de-rã e o resultado do método baseado no descritor GLCM as classificou como saudáveis.

Tabela 6.16 – Matriz confusão dos descritores base (Usando RF)

		CM		
Míldio	Olho-de-Rã	Mancha Parda	Saudável	
312	34	23	9	Míldio
119	379	50	7	Olho-de-Rã
120	190	557	26	Mancha Parda
120	51	28	1788	Saudável
		GLDM		
Míldio	Olho-de-Rã	Mancha Parda	Saudável	
185	36	57	100	Míldio
51	135	154	215	Olho-de-Rã
39	44	579	231	Mancha Parda
21	14	49	1903	Saudável
		HOG		
Míldio	Olho-de-Rã	Mancha Parda	Saudável	
72	79	141	86	Míldio
32	155	240	128	Olho-de-Rã
12	56	604	221	Mancha Parda
7	19	43	1918	Saudável
		LBP		
Míldio	Olho-de-Rã	Mancha Parda	Saudável	
165	50	93	70	Míldio
38	225	183	109	Olho-de-Rã
20	58	697	118	Mancha Parda
37	24	95	1831	Saudável
		LPQ		
Míldio	Olho-de-Rã	Mancha Parda	Saudável	
157	59	95	67	Míldio
45	222	186	102	Olho-de-Rã
23	53	684	133	Mancha Parda
22	32	59	1874	Saudável

Fonte: o autor.

E com a exceção de apenas um descritor, os maiores erros da classificação da classe olho-de-rã foram como sendo mancha parda. Para os descritores HOG, GLCM e o COOC, a taxa de imagens classificadas como mancha parda que eram da classe olho-de-rã superaram as imagens que foram classificadas corretamente. A exceção, o descritor CM, classificou mais folhas olho-de-rã como sendo míldio.

Os maiores erros da classe mancha parda, é que foram classificadas como olho-de-rã pelos descritores CM e COOC, inclusive para o COOC a quantidade de imagens erradas foram superiores às que foram classificadas corretamente. Para os descritores GLCM, HOG, LBP e LPQ a maior taxa de erro foi classificar as imagens como sendo saudáveis. Já para a classe saudável as folhas foram erroneamente classificadas, como sendo mancha parda,

apenas o descritor CM que a classificou mais como sendo míldio. Uma analise mais aprofundada será feita na próxima seção.

6.4 Discussão

Este trabalho avaliou a efetividade do uso de diversos descritores com dois classificadores. Os resultados experimentais demonstram que as técnicas propostas têm aplicação em ambientes reais, já que as imagens obtidas para o banco de imagens foram capturadas no campo e obtiveram taxa de acerto satisfatórias, com resultado superior a 90%.

As classificações geradas apresentaram desempenhos diferentes, tanto em relação ao algoritmo de classificação, quanto pelos descritores empregados. O algoritmo de classificação *Ramdom Forest* (RF) foi superior e apresentou os melhores resultados com todos os descritores utilizados comparado com o classificador *Naive Bayes*, que obteve resultados insignificantes.

Para os testes realizados, a métrica de avaliação adotada foi a porcentagem de acerto obtida pela quantidade de amostras classificadas corretamente. Analisando a matriz confusão na Tabela 6.17, do melhor resultado (CM-LPQ-RI), é possível encontrar as imagens que foram classificadas de maneira errônea. Algumas das imagens que são da classe míldio e foram classificadas erradas são mostradas pela Figura 6.3.

Tabela 6.17 – Matriz confusão - CM-LPQ-RI (Usando RF)

Míldio	Olho-de-Rã	Mancha Parda	Saudável	
295	41	21	21	Míldio
50	452	47	6	Olho-de-Rã
11	45	824	13	Mancha Parda
6	3	1	1977	Saudável

Fonte: o autor.

A segunda coluna apresenta imagens de folhas de sua respectiva classe. É nítida a aparente semelhança entre as imagens de folhas com míldio que foram classificadas como sendo de outra classe. No geral, a classe míldio foi que houve a pior acurácia, classificando em torno de 10.8% das imagens como sendo olho-de-rã, e 11.15% como sendo das outras classes.

Figura 6.3 – Folhas com míldio.

Exemplo de Imagens da classe míldio e como foram classificadas. Fonte: o autor.

A Figura 6.4 apresenta algumas das imagens de folhas da classe olho-de-rã que foram classificadas como míldio, mancha parda e saudável.

Figura 6.4 – Folhas doentes com olho-de-rã.

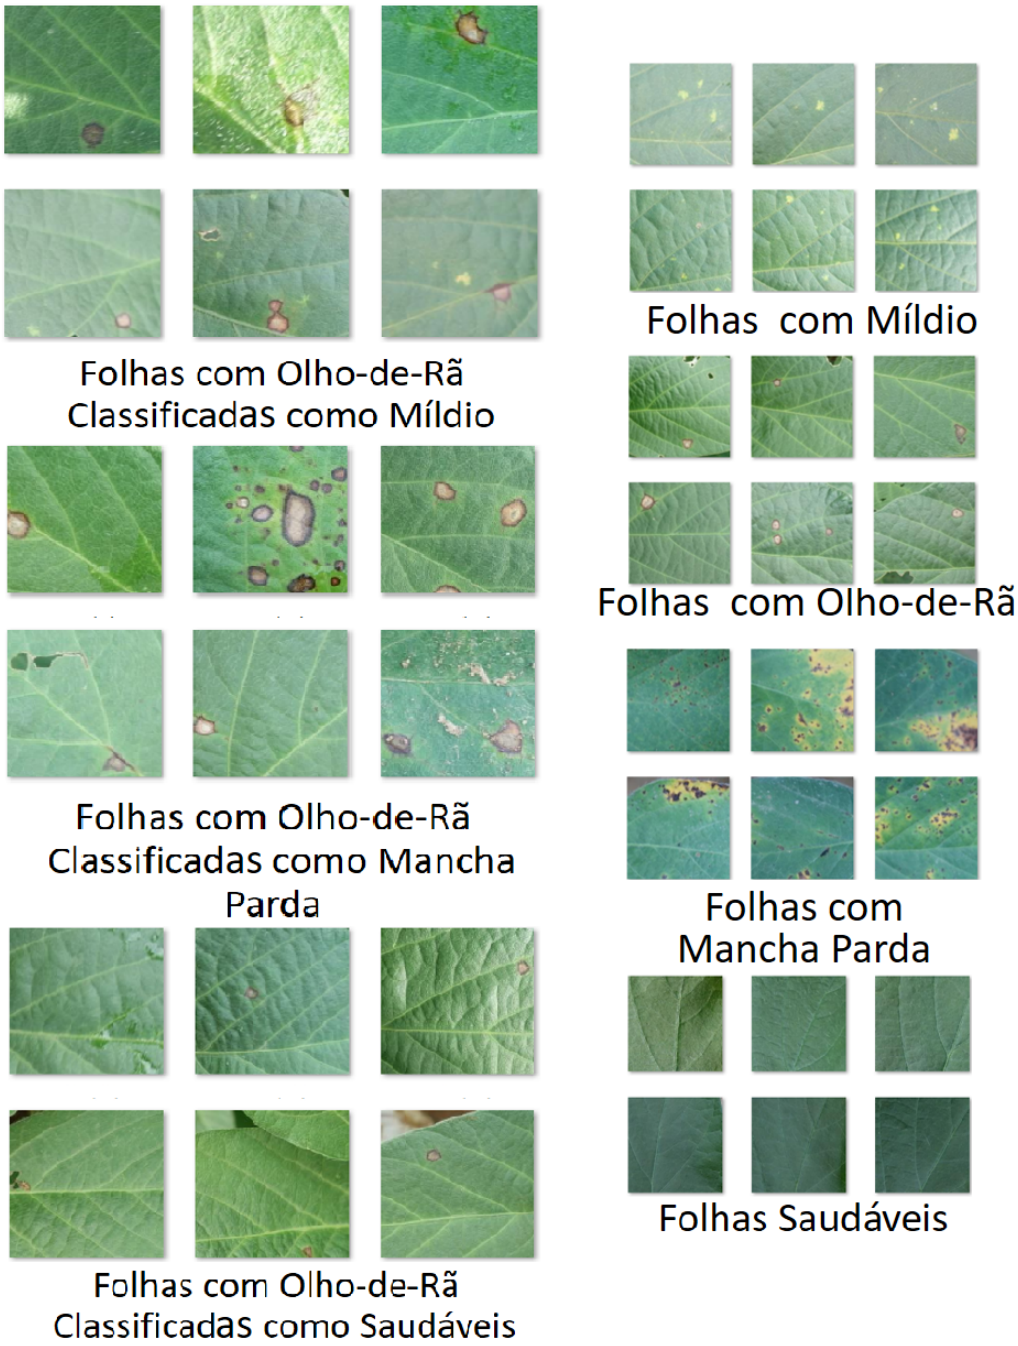

Exemplo de Imagens da classe olho-de-rã e como foram classificadas. Fonte: o autor.

Das três classes doentes, a classe olho-de-rã, foi a que menos classificou como sendo da classe saudável, com apenas aproximadamente 6% das imagens classificadas erradas (apenas as 6 mostradas), ou seja, a classe saudável é a que tem maior diferença. A diferença entre as imagens que foram catalogadas como da classe míldio e mancha parda foi de 3,16%, ou seja, a quantidade de imagens classificadas como sendo de uma das duas classes é bem próximo, 48,54% para a classe míldio e 45,28% para a classe mancha parda, isto é, a

maior parte das imagens que foram classificadas de maneira errada se parecem com uma das duas classes. Observando as imagens apresentadas é possível notar que há a presença de uma descoloração na folha que se assemelha a doença do míldio.

A Figura 6.5 mostra um exemplo das imagens de folhas da classe mancha parda que foram classificadas de forma errada.

Figura 6.5 – Folhas com mancha parda.

Exemplo de Imagens da classe mancha parda e como foram classificadas. Fonte: o autor.

Ao classificar corretamente as imagens da classe mancha parda a taxa de acerto foi de 92,30%. Apenas 45 imagens foram classificadas como sendo olho-de-rã, 13 como saudável e 11 como sendo míldio. Essa taxa se dá por conta de algumas folhas terem um ponto escuro, como é possível perceber, que está relacionado ao estágio da doença, parecendo com a doença do olho-de-rã. E o motivo das imagens terem sido classificadas como saudáveis é que, elas não aparentam estar doentes, podendo ser por um corte da imagem onde não havia a constatação da doença. Na Figura 6.6 apresentam as imagens de folhas saudáveis que não foram classificadas corretamente.

Figura 6.6 – Folhas saudáveis.

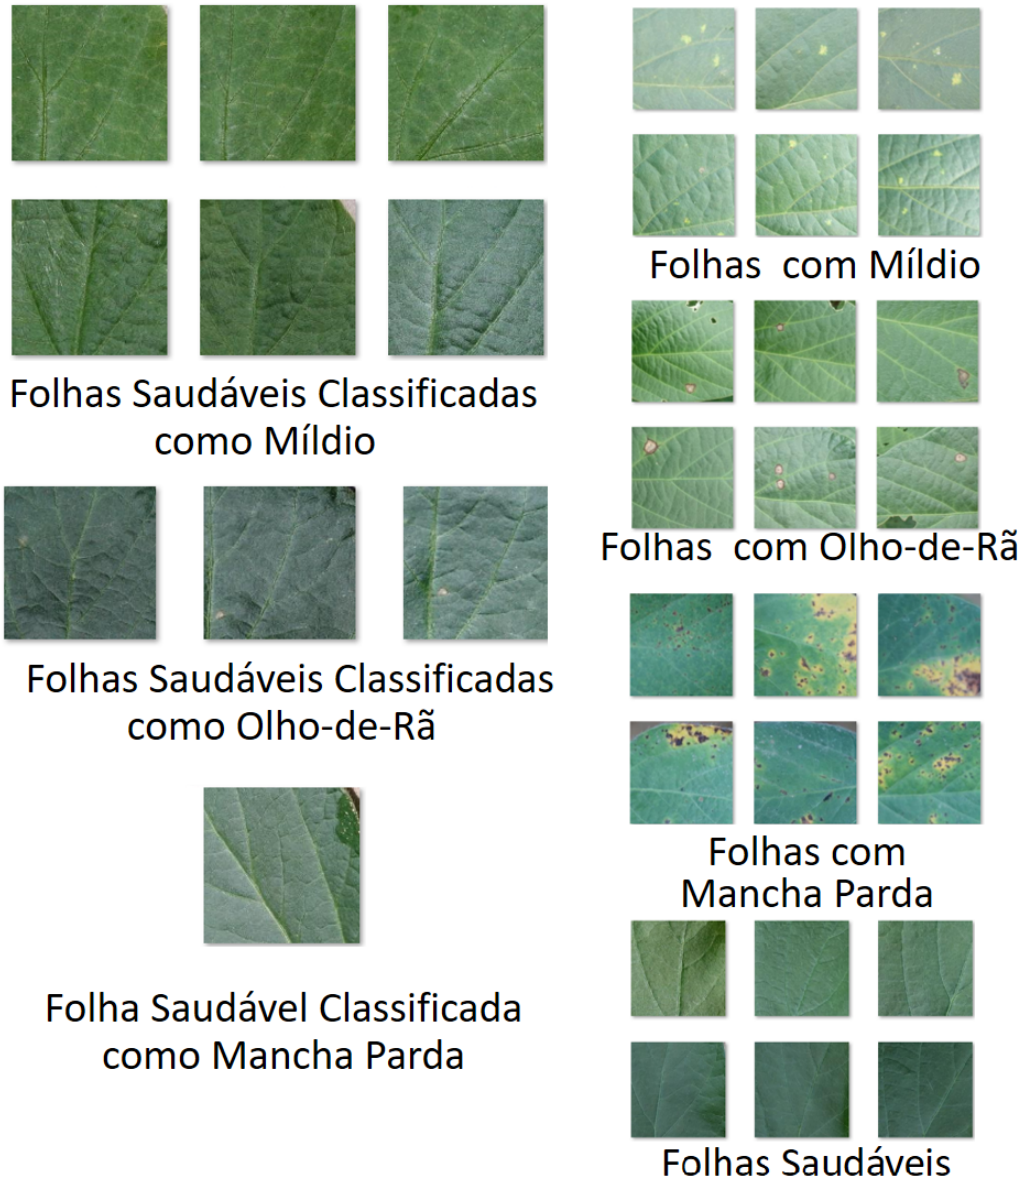

Exemplo de Imagens da classe saudável e como foram classificadas. Fonte: o autor.

É possível visualizar todas as imagens de folhas saudáveis que foram classificadas

como míldio, mancha parda e olho-de-rã. No caso das seis imagens classificadas como sendo míldio, a olho nu não é possível distinguir uma característica que se pareça com a doença. Nas imagens classificadas como olho-de-Rã, as três possuem peculiaridades que se assemelham com as folhas doentes.

Em um trabalho similar, (PIRES, 2017) usou técnicas baseadas em visão computacional baseadas em descritores e histograma de palavras visuais para identificar e classificar imagens de folhas de soja doentes. No trabalho é descrito uma abordagem que permite a atribuição de um descritor a mais do que uma palavra visual, através do cálculo de peso que o descritor exerce sobre a palavra. Foram propostas três variáveis baseado no VLAD. O VLAD é de um vetor que agrega descritores de uma imagem com base a sua localidade, e as técnicas propostas são: VLAD-F que realiza a atribuição de cada descritor para todos os centroides, VLAD-PNC que atribui cada descritor a um conjunto P de centroides e VLAD-VNNC que atribui cada descritor a um conjunto variável de centroides. Os descritores que foram utilizados são o SIFT e o SIFT Denso e o classificador utilizado foi o SVM emph Support Vector Machine. E foram utilizados dois bancos de imagens. Um próprio e construído dentro de um ambiente controlado, para as folhas que contêm a doença da ferrugem asiática em vários estágios, e o segundo banco de imagens baseado nas imagens disponibilizadas pelo PlantVillage, as imagens também sofreram cortes e fora redimensionadas para 199 × 201 pixels . Os resultados encontrados para a base de imagens do PlantVillage é apresentado na Figura 6.7.

Figura 6.7 – Resultados PlantVillage.

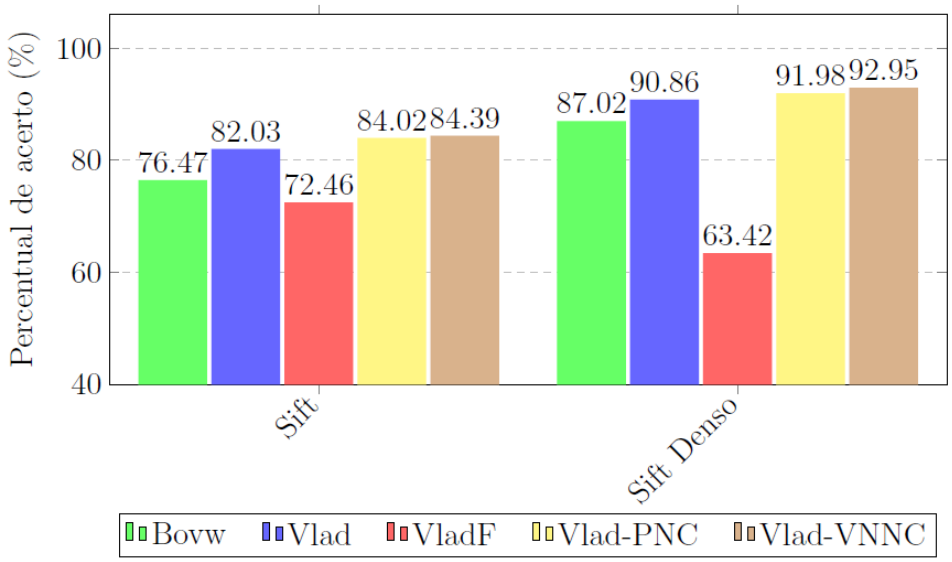

Taxa de classificação correta na base de imagens Plant Village, obtida pelas técnicas propostas utilizando os descritores SIFT e SIFT Denso. Fonte: (PIRES, 2017).

O melhor resultado obtido foi através da combinação do descritor local SIFT Denso, com VLAD-VNNC que obteve uma taxa de acerto de 92:95%. Se comparado com o resultado

do nosso trabalho, a nossa taxa de acerto usando os descritores CM-LPQ-RI e o classificador RF se mostrou melhor. Assim como as taxas de acertos de todos os descritores baseados em CM se comparados com os resultados do SIFT.

Neste capítulo foi apresentado a criação da base de imagens a maneira como a análise dos descritores foram feitas e os resultados do experimento. O próximo capítulo trará a conclusão dos resultados.

Capítulo 7

CONCLUSÃO

Neste trabalho foi analisado a aplicação de algoritmos de descrição e classificação de imagens com doenças foliares da cultura de soja. Foram analisados propostas com base em descritores locais para a extração de características das imagens, e a comparação entre os classificadores *Ramdom Forest* e *Naive Bayes*.

As técnicas foram avaliadas sobre o banco de dados contendo imagens de folhas de soja doente e sadias. No total foram analisadas 3813 imagens, sendo 378 imagens de folhas de soja com a doença do míldio, 555 imagens de olho-de-rã, 893 imagens com folhas doentes com a mancha parda e 1987 imagens de folhas saudáveis. A principio foram usado os descritores CM, COOC, GLCM, HOG, LBP e LPQ para obter e descrever os pontos de interesse nas imagens, entretanto, para tentar melhorar os descritores foram concatenados. Em seguida as técnicas de classificação foram aplicadas para a avaliação.

Os experimentos demostraram que o classificador *Ramdom Forest* foi superior de maneira geral comparado com o classificador *Naive Bayes*, do resultado de 36 experimentos apenas 02 resultados ficaram abaixo da taxa de 70% de acerto, foram os: COOC, com 69,02% e o LBP-RI com 59,02%. Com o classificador *Naive Bayes*, não houve nenhuma taxa de acerto acima de 70% e apenas 23 com taxas acima de 50%. Os resultados também mostraram que a concatenação entre dois descritores apresentaram o melhor resultado, no caso, o CM+LPQ-RI, com taxa de acerto de 93,05% (usando o classificador RF). Porém, nem todas as junções com de mais de um descritor é necessariamente melhor que o resultado obtido por um descritor que não foi concatenado, como é o exemplo das junções com o LBP-RI, onde apenas a junção com o descritor HOG, ficou acima (0,30%) da média entre o descritor básico (usando RF).

Com base nos resultados obtidos é possível concluir que as técnicas tem aplicações para problemas reais, uma vez que a base de imagens simula fielmente as condições encontradas nos cultivos e que dificultam o processo de reconhecimento das doenças.

7.1 Trabalhos Futuros

As propostas para trabalhos futuros são:

- Comparar e avaliar o desempenho de outros classificadores, como o SVM e o K-means, além de testar outros descritores de imagem, como o SIFT (*scale-invariant features transform*) e o SURF (*Speeded Up Robust Features*).
- Ampliar a base de imagens com novas culturas de plantas tais como: milho, cana-de-açucar, laranja, cacau e feijão. Para poder aplicar e avaliar os métodos propostos.
- Desenvolver uma plataforma que seja capaz de identificar e classificar as doenças nas plantas.

REFERÊNCIAS

ABREU, K. Contribuição da soja no pib brasileiro e seu vínculo com o japão. 2016. Citado na página 23.

ALBANEZ, D. de O. *REDES NEURAIS ARTIFICIAIS (RNA'S) APLICADAS À SEGMENTAÇÃO DE IMAGENS*. Dissertação (Mestrado) — Universidade Federal de Goiás, Catalão - GO, 2016. Citado na página 39.

ALBUQUERQUE, M. P.; ALBUQUERQUE, M. P. *Processamento de Imagens: Métodos e Análises*. Rio de Janeiro, 2001. Citado na página 34.

____. *Processamento Digital de Imagens para Aplicação ao Diagnóstico e Controle do Plasma no JET*. Rio de Janeiro, 2010. Citado na página 40.

ALVES, M. O.; FERREIRA, R. V.; GALLIS, R. B. de A. Otimização da identificação de falhas de plantio na cana-de-açúcar com uso de geoprocessamento. *X SBIAGRO - X Congresso Brasileiro de Agroinformática*, 2015. Citado na página 45.

ARAÚJO, V. M. de; JR, A. de S. B.; FALATE, R. Combinação de classificadores para identificação de plantas a partir da imagem da folha. *X Congresso Brasileiro de Agroinformática*, 2015. Citado na página 30.

BACKHAUS, W. G. K. *Physiological and psychological simulations of color vision in humans and animals*. Berlin: Berlin: de Gruyter, 1998. Citado na página 36.

BALAN, W. C. *A imagem digital*. Bauru-SP, 2009. Citado na página 34.

BALLARD, D. H.; BROWN, C. M. *Computer Vision*. New York: Prentice Hall, 1982. Citado na página 33.

BARBOSA, D. P. *Avaliação de descritores textuais geoestatísticos e de haralick para o reconhecimento de plantas daninhas*. Dissertação (Mestrado) — UFV - Universidade Federal de Viçosa, Viçosa - MG, Fevereiro 2009. Citado na página 29.

BATISTA, G. T.; DIAS, N. W. *INTRODUÇÃO AO SENSORIAMENTO REMOTO E PROCESSAMENTO DE IMAGENS*. 2005. Citado 2 vezes nas páginas 43 e 44.

BORDIGNON, L. A. *Identificação de Sementes Utilizando Visão Computacional*. Dissertação (Mestrado) — Universidade Federal do Paraná, Curitiba - PR, 2015. Citado na página 39.

BRAVO, M. J. A. *Análise do Descritor de Padrões Mapeados Localmente em Multiescala para Classificação de Textura em Imagens Digitais*. Dissertação (Mestrado) — UNESP, São José do Rio Preto - SP, 2016. Citado na página 57.

CAMERA, J. N.; DEUNER, C. C.; REIS, E. M. Diferentes concentrações do inóculo de cercospora sojina na intensidade da mancha foliar "olho-de-rã"em soja. *Summa Phytopathologica*, v. 38, n. 3, p. 235–238, 2012. Citado na página 25.

CAMILO, C. O.; SILVA, J. C. da. *Mineração de Dados: Conceitos, Tarefas, Métodos e Ferramentas*. Goiânia - GO, 2009. Citado na página 60.

CASSOL, C. L.; AGOSTI, C. Detecção de ferrugem asiática na soja analisando a imagem da folha utilizando redes neurais. *X SBIAGRO - X Congresso Brasileiro de Agroinformática*, 2015. Citado na página 30.

CERNA, L. R. *Fusão de descritores de histogramas de gradientes para a detecção de faces baseado em uma cascata de classificadores*. Dissertação (Mestrado) — UNiversidade Federal de Ouro Preto, Ouro Preto, Novembro 2014. Citado na página 55.

CHIERICI, C. E. de O. *Classificação de texturas com diferente orientações baseada em descritores locais*. Dissertação (Mestrado) — Escola de Engenharaia e São Carlos - USP, São Carlos - SP, 2015. Citado 2 vezes nas páginas 52 e 57.

CHOUCHOT, E. *A tecnologia na arte, da fotografia à realidade virtual*. Porto Alegre: UFRGS editora, 2003. Citado na página 34.

CUNHA, D. da S. *et al.* Soja para o consumo humano: Breve abordagem. *AGRARIAN ACADEMY, Centro Científico Conhecer*, v. 02, n. 03, p. 7, 2015. Citado na página 22.

DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2005. Citado na página 55.

DAMASCENO, M. Introdução a mmineração de dados utilizando o weka. *CONNEPI*, p. 14, 2010. Citado na página 65.

DEBIASI, H. *et al.* Práticas culturais na entressafra da soja para o controle de pratylenchus brachyurus. *Pesquisa Agropecuária Brasileira*, v. 51, n. 10, p. 9, Outubro 2016. Citado na página 26.

FERRAZ, C. T. *Novos descritores de textura para Localocali e identificação de objetos em imagem usando "Bag-of-Features"*. Tese (Doutorado) — Universidade de São Paulo, São Carlos - SP, 2016. Citado na página 49.

FERREIRA, P. M. da S. *Aplicação de Algoritmos de Aprendizagem Automática para a Previsão de Cancro de Mama*. Dissertação (Mestrado) — Universidade do Porto, Porto - PT, 2010. Citado na página 60.

FIALLOS, F. R. G. A ferrugem asiática da soja causada por phakopsora pachyrhizi sydowferrugem. *Revista Ciencia y Tecnología*, 2011. Citado na página 27.

FORMAGIO, A. R. *et al. O sensoriamento remoto na agricultura: conceitos básicos, metodologia e aplicações*. Rio de Janeiro, 1989. Citado na página 44.

FREITAS, M. K.; LOMBARDO, M. A. O uso de imagem termal gerada pelos satélites da série la andsat e noaa para estudo de ilha de calor: Estudo de caso de são paulo. *Geografia (Rio Claro), v. 32, p. 645-656*, 2007. Citado na página 46.

FURLANETTO, R. *et al.* Potencial de utilização de sensores multiespectral e hiperespectral no estudo de diferentes alvos agrícolas. *XII Jornada Acadêmica da Embrapa Soja*, 2017. Citado na página 47.

GODOY, C. V. *et al.* Doenças da soja (glycine max (l.) merrisoja). *Sociedade Brasileira de Fitopatologia (SBF)*, 2014. Citado na página 28.

GONÇALVES, D. B. *Identificação e Verificação de Descritores Usando Características Texturais e Dissimilaridade*. Tese (Doutorado) — Universidade Federal do Paraná - UFP, Curitiba - PR, 2014. Citado 2 vezes nas páginas 54 e 59.

GONZALEZ, R. C.; WOODS, R. C. *Processamento Digital de Imagens*. 3. ed. São Paulo: Person Prentice Hall, 2010. Citado 2 vezes nas páginas 39 e 50.

GRAVINA, G. de A. *et al.* Diallel analysis for frogeye leaf spot resistance in soybean. *Pesquisa Agropecuária Brasileira*, v. 38, n. 6, p. 673–680, June 2003. Citado na página 29.

GRIGOLLI, J. F. J. Tecnologia e produção: Soja 2014/2015. In: ____. Campo Grande: Fundação MS, 2015. cap. 8 Manejo de Doenças na Cultura da Soja, p. 134–156. Citado 2 vezes nas páginas 24 e 27.

GUIMARÃES, L. S. *Mancha parda (Septoria glycines Hemmi) da soja (Glycine max L.): As pectos etiológicos e de controle*. Tese (Doutorado) — Universidade de Brasília - Instituto de Ciências Biológicas - Departamento de Fitopatologia, Brasília - DF, 2008. Citado 2 vezes nas páginas 26 e 28.

HENNING, A. A. *et al. Manual de Identificação de Doenças de Soja*. Londrina, 2005. Citado 4 vezes nas páginas 25, 26, 27 e 28.

HENNO, J. H. *A cor como fonte luminosa e a inserção do receptor*. Dissertação (Mestrado) — USP - Universidade de São Paulo, 2010. Citado na página 36.

HOFFMANN-CAMPO, C. B. *et al. Pragas da soja no Brasil e seu manejo integrado*. Brasília: EMRAPA, 2000. Citado na página 21.

HUGHES, D.; SALATHÉ, M. *An open access repository of images on plant health to enable the development of mobile disease diagnostics*. 2015. Citado na página 63.

IBANEZ, M. M. *Uso de Redes Neurais Nebulosas e Florestas Aleatórias na Cassificação de Imagens em um Projeto de Ciência Cidadã*. Dissertação (Mestrado) — Curso de Pós-Graduação em Computação Aplicada - INPE, São José dos Campos, 2016. Citado na página 61.

INTEL. *Histogram of Oriented Gradients (HOG) Descriptor*. [S.l.], 2016. Citado na página 56.

JORGE, L. A. de C.; INAMASU, R. Y. Ferramenta para agricultura de precisão. In: ____. Brasília: Embrapa Instrumentação, 2014. cap. 8 Uso de veículos aéreos não tripulados (VANT) em Agricultura de Precisão, p. 109–134. Citado 2 vezes nas páginas 46 e 47.

JORGE, L. A. de C.; SILVA, D. J. da C. B. *AFSoft: Manual de Utilização*. Brasília, 2009. Citado na página 30.

KIRT, B. B. Anuário brasileiro da soja 2003. *Editora Gazeta Santa Cruz*, 2003. Citado na página 24.

LOPES, T. D. *et al.* Aplicação do algoritimo random forest como classificador de padrões de falha em rolamento de motores de indução. *XIII Simpósio Brasileiro de Automação Inteligente*, Outubro 2017. Citado na página 62.

MANGINI, B. da S.; SANTOS, J. L. S. dos. Evolução do sistema diagnose virtual. *V Mostra de Trabalhos de Estagiários e Bolsista*, 2009. Citado na página 29.

MARQUES, Y. B. *Mirnacle : aprendizagem de máquina utilizando SMOTE e Random Forest para prover aumento da seletividade na predição ab initio de pre-miRNAs*. Dissertação (Mestrado) — Universidade Federal de Viçosa - UFV, 2015. Citado na página 61.

MARTINS, J. G. *et al.* Uso de descritores de textura extraídos de glcm para o reconhecimento de padrões em diferentes domínios de aplicação. *Electronic Notes in Theoretical Computer Science*, p. 16, 2011. Citado na página 54.

MELO, E. R.; DANELLI, A. L. D.; CASA, R. T. Ciclo do míldio da soja. *Revista Plantio Direto*, 2010. Citado na página 27.

MENESES, P. R. *et al. Introdução ao Processamento de Imagens de Sensoriamento Remoto*. Brasília: Embrapa, 2012. Citado 4 vezes nas páginas 35, 44, 45 e 46.

MITCHELL, T. M. *Machine Learning*. NY: McGraw-Hill Science/Engineering/Math, 1997. Citado na página 60.

MORAES, E. C. de. *Fundamentos de sensoriamento remoto*. São José dos Campos, 2002. Citado 3 vezes nas páginas 43, 44 e 45.

MOTTA, P. R. de A. *Estudo Exploratório do Uso de Classificadores para a Predição de Desempenho e Abandono em Universidades*. Dissertação (Mestrado) — Instituto de Informática da Universidade Federal de Goiás - UFG, Goiânia - GO, 2016. Citado na página 61.

MOURATO, A. S. B. C. *Aplicação dpara pesquisa de Clip Arts em Dispositivos Móveis Baseada em Esboços*. Dissertação (Mestrado) — Instituto Superior de Engenharia de Lisboa, Lisboa - PT, 2013. Citado na página 53.

MUSCI, M. *et al.* Uma avaliação de descritores de textura baseados em códigos binários locais para classificação de imagens de sensoriamento remoto. *Boletim de Ciências Geodésicas*, 2011. Citado 2 vezes nas páginas 58 e 59.

NASCIMENTO, J. P. R. do. *Análise e Classificação de Imagens Baseadas em Características de Textura utilizando Matrizes de Co-ocorrência*. Dissertação (Mestrado) — Universidade Federal do Paraná, Curitiba-PR, 2003. Citado na página 51.

NUNES, C. D. M. *Avaliação da Eficiência Agronômica dos Fungicidas no Controle da Ferrugem Asiática na Cultura da Soja*. Brasília, 2009. Citado 2 vezes nas páginas 23 e 26.

OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002. Citado 2 vezes nas páginas 56 e 57.

OJANSIVU, V.; HEIKKILA, J. Blur insensitive texture classification using local phase quantization. *Proceedings Image and Signal Processing (ICISP 2008)*, n. 5099, p. 236–243, 2008. Citado na página 58.

PEDRINI, H.; SCHWARTZ, W. R. *Análise de Imagens Digitais*. [S.l.]: Thomson Learning, 2008. Citado 4 vezes nas páginas 33, 35, 38 e 41.

PENATTI, O. A. B. *Estudo Comparativo de Descritores para Recuperação de Imagens por Conteúdo na Web*. Dissertação (Mestrado) — Instituto de Computação - Unicamp, Campinas - SP, 2009. Citado na página 49.

PICININI, E. C.; FERNANDES, J. M. *Doenças de Soja - Diagnose, epidemiologia e controle*. 3. ed. [S.l.]: EMBRAPA, 2003. Citado na página 27.

PIRES, R. D. L. *Reconhecimento de Doenças da Cultura da Soja usando Vetores Localmente Agregados e Atribuições Leves*. Dissertação (Mestrado) — UFMS - Universidade Federal de Mato Grosso do Sul, Campo Grande - MS, 2017. Citado na página 78.

PIRES, R. D. L. *et al*. Local descriptors for soybean disease recognition. *Computers and Electronics in Agriculture*, 2016. Citado na página 30.

QUEIROZ, J. E. R. de; GOMES, H. M. *Introdução ao Processamento Digital de Imagens*. 2006. Magazine. Citado na página 38.

REINEHR, C. L.; SOUTES, D. O. Tecnologia e inovaÇÃo: Um estudo de caso na agricultura familiar. *V Congresso Nacional de Pesquisa em Ciências Sociais Aplicadas*, Outubro 2016. Citado na página 29.

REIS, E. M.; DANELLI, A. L. D.; CASA, R. T. Ciclo da mancha foliar olho-de-rã, na soja. *Revista Plantio Direto*, Novembro 2012. Citado na página 25.

SANTOS, A. P. de O. *Desenvolvimento de descritores de imagens para reconhcimento de padrões de plantas invasoras (folhas largas e folhas estreitas)*. Dissertação (Mestrado) — Universidade Federal de São Carlos, São Carlos-SP, 2009. Citado 2 vezes nas páginas 29 e 49.

SANTOS, D. F. D. dos. *Recuperação de Imaens: Similaridade Parcial Baseada em Espectro de Grafo e Cor*. Dissertação (Mestrado) — Universaidade Federal de Uberlândia - UFU, Uberlândia, Minas Gerais, 2012. Citado na página 38.

SARAN, P. E. *Manual de identificação das doenças da soja*. 1. ed. [S.l.], 2014. Citado 2 vezes nas páginas 26 e 28.

SELFRIDGE, O. *Proceedings of the IRE*. New York: Bell Telephone Laboratories, 1962. Citado na página 33.

SHIH, J. L.; CHEN, L. H. Color image retrieval based on primitives of color moments. *Proceedings of the 5th International Conference on Recent Advances in Visual Information Systems*, v. 02, p. 88–94, 2002. Citado na página 53.

SILVA, O. C. da *et al*. Damage to soyben caused by downy mildew. *Ciência Rural*, 2016. Citado na página 28.

SOUTO, R. P. *Página Dinâmica para Aprendizado do Sensoriamento Remoto*. 2000. Citado na página 37.

STEFFEN, C. A. *Introdução ao Sensoriamento Remoto*. São José dos Campos, 2000. Citado na página 44.

TRAVAINI, J. N. *Descritores de Textura local para Reconhecimento Biométrico da Íris Humana*. Dissertação (Mestrado) — Escola de Engenharaia e São Carlos - USP, São Carlos - SP, 2015. Citado 2 vezes nas páginas 50 e 58.

VASCONCELOS, S. *Matriz de Co-ocorrência*. 2010. Disponível em: <http://www.ic.uff.br/~aconci/coocorrencia.pdf>. Citado na página 54.

VIANA, D. K. M. *Identificação de plantas a partir da análise de suas folhas utilizando o algoritimo SIFT e momentos de cor*. 2017. Monografia, USP (Universidade de São Paulo), São Carlos, Brasil. Citado na página 31.

YORK UNIVERSITY. *Electromagnetic Spectrum*. 2013. Disponível em: <http://www.yorku.ca/eye/spectru.htm>. Citado na página 35.